

**МИНИСТЕРСТВО ПО РАЗВИТИЮ ИНФОРМАЦИОННЫХ
ТЕХНОЛОГИЙ И КОММУНИКАЦИЙ РЕСПУБЛИКИ УЗБЕКИСТАН**

**ТАШКЕНТСКИЙ УНИВЕРСИТЕТ ИНФОРМАЦИОННЫХ
ТЕХНОЛОГИЙ ИМЕНИ МУХАММАДА АЛ-ХОРАЗМИЙ**

**Факультет “Компьютерный инжиниринг”
Кафедра “Компьютерные системы”**

**Методические указания
по выполнению лабораторных работ по курсу
«Интеллектуальный анализ данных»
для бакалавров обучающихся по направлению
5330500 – Компьютерный инжиниринг**

Ташкент 2018

Авторы: д.т.н., профессор, Усманов Р.Н., Кутлымуратов А.Ж, Хабирова Д.Н. /ТУИТ, 56 с., Ташкент, 2018

В условиях развития и реформирования экономики страны стратегической целью государства является подготовка свободно мыслящих, высококвалифицированных молодых кадров. Для достижения поставленной цели требуется разработка и издание учебно-методической литературы на основе поставленных задач «Национальной программы по подготовке кадров».

Цель данного методического указания является определение основных требований по выполнению лабораторных работ по курсу «Интеллектуальный анализ данных».

Напечатано по решению научно-методического совета ТУИТ. (протокол №__ от _____ 201__ г.)

Рецензенты:

заведующий лаборатории
«Геоинформационных технологий»,
ГП «Институт ГИДРОИНГЕО»
к.т.н.

Хушвактов С.Х.

заведующая кафедрой
«Мультимедийные технологии»
ТУИТ имени Мухаммада ал-Хоразмий,
к.т.н., доцент

Назирова Э.Ш.

Ташкентский университет информационных технологий имени Мухаммада ал-Хоразмий. 2018

Введение

Методические указания представляют собой указания для получения базовых знаний по анализам данных на основе математического моделирования в среде Matlab. Здесь приведены основные характеристики для вычисления и анализа матричных данных. Рассматриваются функции аппроксимации и интерполяции данных, линейной и нелинейной регрессионный анализ данных, корреляционный анализ и их построение в среде Matlab. А также, описываются понятие кластеризация данных на основе классификации и алгоритмы кластеризации. Рассматриваются теория нечётких множеств и свойства построения на основе пакета FLT в среде Matlab.

Лабораторная работа №1

Тема: Изучение основных характеристик матриц в среде Matlab

Цель работы: Изучить основных вычислительных характеристик матриц в Matlab

Теоретические сведения

Основные характеристики матрицы:

- детерминант;
- ранг матрицы;
- норма;
- базис ортонормала;

Определитель матрицы, детерминант — число, соответствующее *квадратной матрице* и полученное путем ее преобразования по определенному правилу. Обычное обозначение (для матрицы A) — $\det A$. Например, определитель (второго порядка) матрицы обозначается и вычисляется следующим образом: $\det A = a_{11}a_{22} - a_{12}a_{21}$.

В общем случае (квадратной матрице порядка n) из элементов матрицы A сначала составляют все возможные произведения из n сомножителей каждое, содержащие по одному элементу из каждой строки и по одному элементу из каждого столбца, затем эти произведения складываются по специальному правилу.

Определитель, в котором вычеркнуты произвольная строка, например i -я, и произвольный столбец, например j -й, называется **минором**. Он имеет $(n - 1)$ -й порядок, т.е. порядок на 1 меньше, нежели исходный определитель.

Рангом системы строк (столбцов) матрицы с строк и столбцов называется максимальное число линейно независимых строк (столбцов). Несколько строк (столбцов) называются линейно независимыми, если ни одна из них не выражается линейно через другие. Ранг системы строк всегда равен рангу системы столбцов, и это число называется рангом матрицы.

Ранг матрицы — наивысший из порядков всевозможных ненулевых

миноров этой матрицы. Ранг нулевой матрицы любого размера ноль. Если все миноры второго порядка равны нулю, то ранг равен единице, и т.д.

Обычно ранг матрицы A обозначается $\text{Rank}(A)$

Полный список характеристики по любому из них можно получить в `matlab\matfun`, используя команды `help matfun`

Таблица 1.1 Функции матричных действий

Функция и ее синтаксис	Описание
<code>zeros(m, n)</code>	Возвращает нулевую матрицу (состоящую из одних нулей) размерности $m \times n$.
<code>ones(m, n)</code>	Возвращает матрицу состоящую из одних единиц размерности $m \times n$.
<code>eye(m, n)</code>	Создает единичную матрицу размерности $m \times n$.
<code>rand(m, n)</code>	Возвращает матрицу случайных чисел равномерно распределенных в диапазоне от 0 до 1, матрица имеет размерность $m \times n$.
<code>randn(m, n)</code>	Возвращает матрицу размерности $m \times n$, состоящих из случайных чисел в диапазоне от 0 до 1 и имеющих гауссовское распределение (имеющих нормальный закон распределения).
<code>hadamard(n)</code>	Возвращает матрицу Адамара размерности $n \times n$.
<code>hild(n)</code>	Возвращает матрицу Гильберта размерности $n \times n$.
<code>invhild(n)</code>	Возвращает обратную матрицу Гильберта размерности $n \times n$.
<code>reshape(A, n, m)</code>	Функция образует матрицу размерности $n \times m$ путем выборки элементов заданной матрицы A по столбцам и последующему распределению этих элементов по m столбцам каждый из которых содержит n элементов, при этом матрица A должна иметь размерность $n \times m$.
<code>tril(A)</code>	Выбирает нижнюю треугольную матрицу из матрицы A
<code>triu(A)</code>	Выбирает верхнюю треугольную матрицу из матрицы A
<code>diag(A, n)</code>	Функция создает диагональную матрицу из вектора A , при этом второй параметр необязателен. Если второй параметр присутствует, то создается матрица в которой вектор A помещается в другую диагональ, при этом если $n > 0$, то вектор помещается выше главной диагонали, если $n < 0$ то ниже, если $n = 0$ то на главную диагональ. Если A матрица, то функция выдает вектор

	сформированный из элементов главной ее диагонали, если второй параметр отсутствует или равен нулю. Если второй параметр присутствует, то функция выдает другую диагональ, в соответствии с вторым параметром (см. предыдущий абзац).
' (апостроф)	Оператор производит транспонирование матрицы
+ - * / \ ^	Математические действия над матрицами. Применимы как к выражению вида «матрица-скаляр», так и «матрица-матрица» (за исключением возведения в степень, он применима только к выражению «матрица-скаляр»). Во всех операциях необходимо следить за размерностями матриц.
inv(A)	Возвращает обратную матрицу по отношению к матрице A
det(A)	Подсчет определителя (детерминанта) матрицы
cross(A, B)	Векторное произведение векторов
lu(A)	Производит LU-разложение матрицы A и выдает матрицы в следующем порядке [L U P] (подобное записи обязательна), при этом выполняется следующее соотношение $P^*A=L*U$.
size(A)	Возвращает массив состоящий из числа строк (первый элемент) и числа столбцов (второй элемент).
sum(A)	Возвращает сумму всех элементов по столбцу
std(A)	Возвращает среднеквадратическое отклонение столбца матрицы
min(A) max(A)	Возвращает минимум и максимум соответственно, по столбцу матрицы
sort(A)	Сортирует столбец матрицы по возрастанию
prod(A)	Вычисляет произведение всех элементов столбцов
rank(A)	Ранг матрицы Функция $r = \text{rank}(A)$ возвращает ранг матрицы, который определяется как количество сингулярных чисел, превышающих порог $\max(\text{size}(A))*\text{norm}(A)*\text{eps}$.
sum(A)	Мы подсчитали вектор-строку, содержащую сумму элементов столбцов матрицы A.
fliplr	зеркально отображает матрицу слева направо.
magic(A)	MATLAB на самом деле обладает встроенной функцией, которая создает магический квадрат почти любого размера.
Det(A)	Считает детерминант матрицы

```
>> A = [1 2 3; -3 2 5; 2 4 8]
```

```
A =
```

```
    1    2    3
   -3    2    5
    2    4    8
```

```
>> det(A)
```

```
ans =
```

```
    16
```

Рис.1.1. Детерминант матрицы

```
>> A = [1 2 -1 3 2; 2 -1 3 0 1; 3 1 2 3 3; 1 2 3 1 1]
```

```
A =
```

```
    1    2   -1    3    2
    2   -1    3    0    1
    3    1    2    3    3
    1    2    3    1    1
```

```
>> rank(A)
```

```
ans =
```

```
    3
```

Рис 1.2. Ранг матрицы

```
>> A = [1 3 7; 2 5 8; -1 4 3]
```

```
A =
```

```
    1    3    7
    2    5    8
   -1    4    3
```

```
>> A1 = norm(A, 1)
```

```
A1 =
```

```
    18
```

```

>> A2 = norm(A, 2)

A2 =

    13.0488

>> Ainf = norm(A, inf)

Ainf =

    15

```

Рис 1.3. Норма матрицы

Варианты:

№	Матрица
1.	$\begin{bmatrix} 2 & 3 & -4 & 1 \\ 1 & -3 & -1 & 2 \\ 3 & 3 & -7 & 0 \\ 1 & -12 & 1 & 5 \end{bmatrix}$
2.	$\begin{bmatrix} 1 & -3 & 2 & 5 \\ 4 & 1 & -1 & 3 \\ 2 & 7 & 6 & 1 \\ 5 & -2 & 0 & 4 \end{bmatrix}$
3.	$\begin{bmatrix} 3 & -1 & 1 & -2 \\ 2 & 1 & -2 & 1 \\ 1 & -2 & 3 & -3 \\ 0 & -5 & 8 & -7 \end{bmatrix}$
4.	$\begin{bmatrix} 3 & 4 & -2 & 3 \\ 2 & 7 & -5 & -1 \\ 1 & -3 & 3 & 4 \\ 4 & 1 & 1 & 7 \end{bmatrix}$
5.	$\begin{bmatrix} 1 & 3 & 2 & -1 \\ 2 & -1 & 3 & 2 \\ 3 & -5 & 4 & 5 \\ 1 & 10 & 6 & -6 \end{bmatrix}$
6.	$\begin{bmatrix} 5 & -1 & 2 & -3 \\ 1 & -2 & 1 & -1 \\ 3 & 3 & 0 & -1 \\ 2 & 5 & -1 & 0 \end{bmatrix}$
7.	$\begin{bmatrix} 3 & 4 & 2 & -5 \\ 4 & 1 & -4 & 1 \\ 2 & 7 & 8 & -11 \\ -1 & 3 & 6 & -8 \end{bmatrix}$
8.	$\begin{bmatrix} 1 & 3 & 2 & 1 \\ 4 & -1 & 3 & -1 \\ 2 & -7 & -1 & -3 \\ 6 & 5 & 7 & 1 \end{bmatrix}$
9.	$\begin{bmatrix} 1 & 3 & 5 & 1 \\ 3 & 5 & 3 & 5 \\ 1 & -1 & -4 & 3 \\ 2 & 4 & 4 & 3 \end{bmatrix}$
10.	$\begin{bmatrix} 1 & -4 & 1 & -2 \\ 2 & 3 & -1 & 1 \\ 4 & -5 & 1 & -3 \\ 1 & -15 & 4 & -7 \end{bmatrix}$

11.	3	-1	2	-5
	2	-3	3	-2
	5	-4	5	-7
	1	2	-1	-2
12.	2	-3	4	2
	1	-1	3	-1
	4	-7	11	3
	3	-5	5	5
13.	2	5	3	-4
	2	-1	-1	3
	6	-7	-5	-1
	0	5	-1	-5
14.	1	-3	-5	7
	2	-1	-3	4
	1	2	2	-3
	1	-8	-12	-7
15.	3	-5	-3	1
	2	1	3	2
	4	-11	-9	0
	1	-6	0	-1

v

Порядок выполнения работы

1. Ознакомиться с теоретической частью по приведенным выше материалам;
2. Установить прикладный программный продукт Matlab по характеристике компьютера
3. Выполните задания по каждому варианту в среде Matlab и определить детерминант, ранг, норма матрицы

Контрольные вопросы

1. Основные характеристики матрицы
2. Как найти детерминант матрицы
3. Как найти сумму всех элементов по столбцу
4. Как найти обратную матрицу
5. Как найти норму матрицы

Лабораторная работа №2

Тема: Функции аппроксимации и интерполяции данных

Цель работы: Построить аппроксимации и интерполяции данных

Теоретические сведения

1. Сущность понятия аппроксимации.
2. Интерполяция способ нахождения промежуточных значений функции.

Аппроксимация, или приближение — научный метод, состоящий в замене одних объектов другими, в том или ином смысле близкими к исходным, но более простыми.

Аппроксимация позволяет исследовать числовые характеристики и качественные свойства объекта, сводя задачу к изучению более простых или более удобных объектов (например, таких, характеристики которых легко вычисляются, или свойства которых уже известны).

Интерполяция, интерполирование - способ нахождения промежуточных значений величины по имеющемуся дискретному набору известных значений.

Решение задач аппроксимации

Функция $y = \frac{\sin(x)}{x}$ аппроксимировать, узловые точки распределены равномерно,

использовать 5 порядок многочлена.

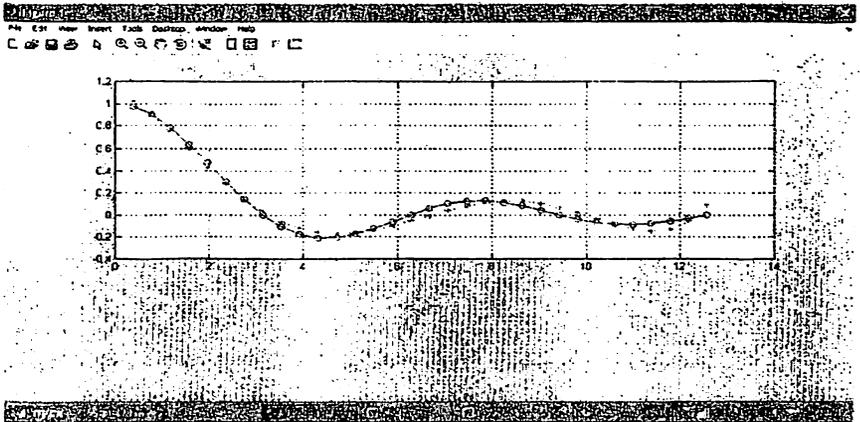
```
>> x=pi/8:pi/8:4*pi; (равномерное распределение узловых точек)
```

```
>> y=sin(x)/x;
```

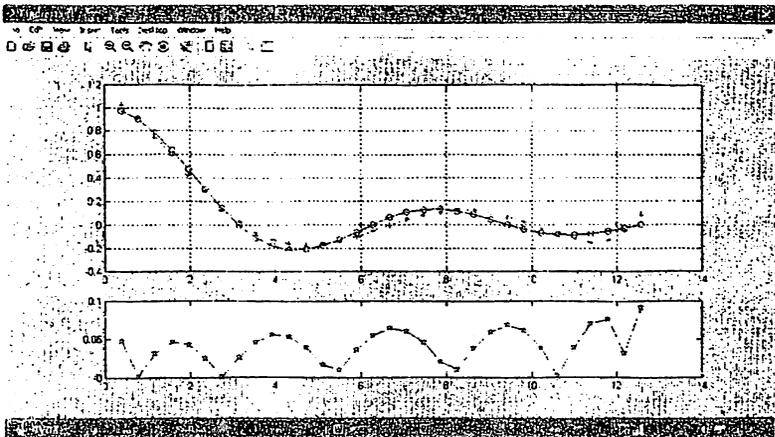
```
>> p=polyfit(x,y,5);
```

```
>> fa=polyval(p,x);
```

```
>> subplot(3,1,1:2), plot(x,y,'-o',x,fa,'-*'), grid, hold on;
```



```
>> error=abs(fa-y); subplot(3,1,3), plot(x,error,'-p')
```



Аппроксимация на основе неравномерных узловых точек

Пример: аппроксимировать функцию $y = \frac{\sin(x)}{x}$ на промежутке $[0.1; 4.5]$ на основе 3-порядка многочлена.

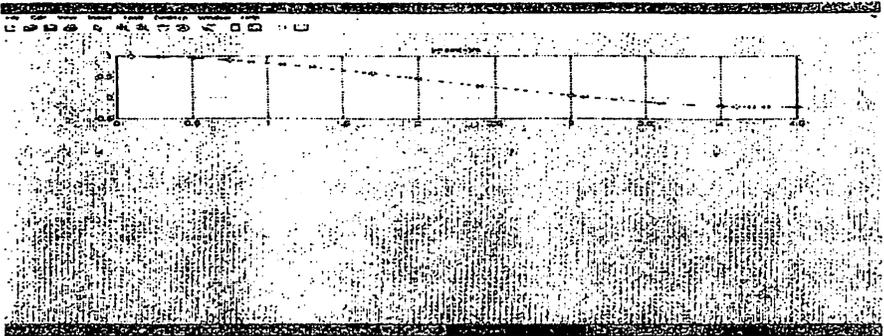
```
>> x=[0.1 0.3 0.5 0.75 0.9 1.1 1.3 1.7 2 2.4 3 3.1 3.6 4 4.1 4.2 4.3 4.5];
```

```
>> y=sin(x)./x;
```

```
>> p=polyfit(x,y,3);
```

```
>> fa=polyval(p,x);
```

```
>>subplot(3,1,1),plot(x,y,'-o'), grid, title('y=sin(x)/x'), hold on;
```



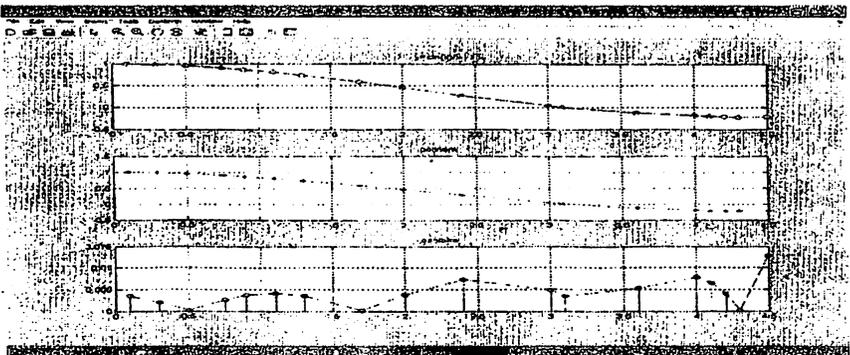
```
>>subplot(3,1,2),plot(x,fa,'-*'), grid, title('polinom'), hold on;
```



```
>> error=abs(fa-y);
```

```
>>subplot(3,1,3),plot(x,error,'-p'), grid, title('oshibka'), hold on;
```

```
>>stem(x,error)
```



Решение задач интерполяции

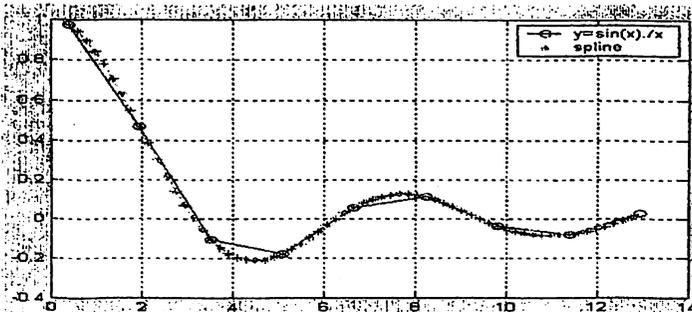
Интерполяция — способ нахождения промежуточных значений величины по имеющемуся дискретному набору известных значений.

На основании этих наборов требуется построить функцию, на которую могли бы с высокой точностью попадать другие получаемые значения. Такая задача называется аппроксимацией кривой. Интерполяцией называют такую разновидность аппроксимации, при которой кривая построенной функции проходит точно через имеющиеся точки данных.

Задача интерполяции — найти данные в окрестности узловых точек. Для этого используются подходящие функции, значения которых в узловых точках совпадают с координатами этих точек.

Выполнить интерполяцию функции $y = \frac{\sin(x)}{x}$ на основе равномерного распределения кубического многочлена и кубического сплайна.

```
X=pi/8:pi/2:(4*pi+pi/2);
Y=sin(x)./x;
Xi=pi/8:pi/16:(4*pi+pi/16);
Fi1=interp1(x,y,xi,'cubic');
Plot(x,y,'-o',xi,fi1,'-*'), grid, hold on
Legend('y=sin(x)./x','cubic')
Figure
Fi2=interp1(x,y,xi,'spline');
Plot(x,y,'-o',xi,fi2,'-*'),grid, hold on
Legend('y=sin(x)./x','spline')
```



Варианты

№	1	2	3	4	5	6	7
x	y	y	y	y	y	y	y
0.25	0.778	2.284	0.247	0.552	1.031	0.444	0.255
0.31	0.758	2.363	0.285	0.615	1.048	0.530	0.320
0.36	0.717	2.433	0.362	0.667	1.066	0.645	0.376
0.39	0.677	2.477	0.390	0.740	1.107	0.771	0.411
0.43	0.650	2.537	0.416	0.642	1.194	0.640	0.458
0.47	0.625	2.100	0.352	0.587	1.233	0.538	0.508
0.52	0.644	1.982	0.339	0.543	1.138	0.477	0.572
0.56	0.661	1.851	0.331	0.589	1.061	0.508	0.626
0.64	0.717	1.896	0.397	0.684	1.021	0.564	0.544
0.66	0.714	1.935	0.513	0.709	1.122	0.578	0.476
0.71	0.691	2.034	0.651	0.771	1.256	0.610	0.559

№	8	9	10	11	12	13	14
x	y	y	y	y	y	y	y
0.24	0.335	1.274	0.586	0.242	1.002	0.544	0.237
0.26	0.254	1.297	0.571	0.262	1.103	0.566	0.257
0.27	0.263	1.310	0.663	0.273	1.203	0.576	0.266
0.29	0.384	1.436	0.648	0.294	1.204	0.598	0.286

0.30	0.491	1.535	0.540	0.304	1.304	0.509	0.295
0.32	0.509	1.437	0.526	0.325	1.255	0.431	0.234
0.37	0.454	1.344	0.590	0.308	1.316	0.387	0.161
0.38	0.363	1.146	0.683	0.289	1.377	0.399	0.170
0.42	0.397	1.252	0.657	0.232	1.409	0.446	0.247
0.49	0.455	1.363	0.612	0.309	1.412	0.533	0.247
0.59	0.533	1.380	0.554	0.324	1.357	0.669	0.206

Порядок выполнения работы

1. Ознакомиться с теоретической частью по приведенным выше материалам;
2. Построить аппроксимация данных в среде Матлаб по варианту
3. Выполните задания по каждому варианту и постройте интерполяция данных в среде Матлаб

Контрольные вопросы

1. Что такое аппроксимация
2. Что такое интерполяция
3. Команды аппроксимация и интерполяции.
4. Что такое одномерная табличная интерполяция
5. Что такое двумерная табличная интерполяция
6. Что такое трехмерная табличная интерполяция

Лабораторная работа №3

Тема: Создание линейных регрессионных моделей в среде Matlab

Цель работы: Построить линейных регрессионных моделей в Matlab

Теоретические сведения

Алгоритм построения линейной регрессионной модели и её реализация на Matlab.

Пусть $X = x_{ij}$ - матрица исходных данных, $Y = y_j$ - вектор зависимой переменной, $i = 1, 2, \dots, n$, $j = 1, 2, \dots, m$. Требуется построить линейную регрессионную модель вида:

$$y^M = Xa + e \quad (1)$$

Здесь y^M - вектор зависимого переменного, X - матрица исходных данных, a - вектор коэффициентов, e - вектор переменной.

Для двухмерного случая регрессионная модель (1) представляется так:

$$y_i^M = a_0 + a_1 x_{i1} + a_2 x_{i2} + e_i \quad (2)$$

$$y_i^M = \begin{bmatrix} 1 & x_{i1} & x_{i2} \\ 1 & x_{21} & x_{22} \\ \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} \end{bmatrix} [a_0, a_1, a_2]^T + e_i \quad (2')$$

Для определения коэффициентов a_0, a_1, a_2 воспользуемся методом наименьших квадратов (МНК), согласно который решается следующая оптимизационная задача:

$$J(a_0, a_1, a_2) = \sum_{i=1}^n a_0 + a_1 x_{i1} + a_2 x_{i2} + y_i^2 \rightarrow \min \quad (3)$$

Решение задачи (3) сводится к решению следующей системы линейных алгебраических уравнений (СЛАУ):

$$\left. \begin{aligned} \frac{\partial J}{\partial a_0} &= 0 \\ \frac{\partial J}{\partial a_1} &= 0 \\ \frac{\partial J}{\partial a_2} &= 0 \end{aligned} \right\} (4) \Leftrightarrow \begin{aligned} 2 \sum (a_0 + a_1 x_{i1} + a_2 x_{i2} + y_i) &= 0 \\ 2 \sum (a_0 + a_1 x_{i1} + a_2 x_{i2} + y_i) x_{i1} &= 0 \\ 2 \sum (a_0 + a_1 x_{i1} + a_2 x_{i2} + y_i) x_{i2} &= 0 \end{aligned}$$

Отсюда:

$$\begin{aligned} n a_0 + a_1 \sum x_{i1} + a_2 \sum x_{i2} &= \sum y_i \\ a_0 \sum x_{i1} + a_1 \sum x_{i1}^2 + a_2 \sum x_{i1} x_{i2} &= \sum x_{i1} y_i \\ a_0 \sum x_{i2} + a_1 \sum x_{i1} x_{i2} + a_2 \sum x_{i2}^2 &= \sum x_{i2} y_i \end{aligned} \quad (5)$$

Решаемая СЛАУ (5) находим коэффициенты уравнение линейной регрессии (a_0, a_1, a_2) . В системах (4) или (5) $\Sigma = \sum_{i=1}^n$

Результаты регрессионного анализа целесообразно организовать в виде следующие таблицы (3.1):

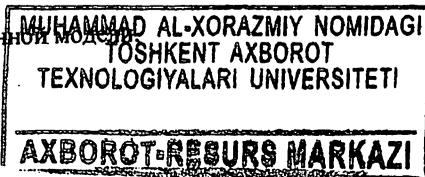
Таблица 3.1.

I	x_{i1}	x_{i2}	y_i	y_i^M	$(y_i - y_i^M)^2$
1	x_{11}	x_{12}	y_1	y_1^M	$(y_1 - y_1^M)^2$
2	x_{21}	x_{22}	y_2	y_2^M	$(y_2 - y_2^M)^2$
...
N	x_{n1}	x_{n2}	y_n	y_n^M	$(y_n - y_n^M)^2$

Результаты ВЭ целесообразно представляет в графическом виде, рассматривая в одном графическом окне графику функций:

$y_i = f_1(x_{i1}, x_{i2})$ - заданные значение

$y_i^M = f_1(x_{i1}, x_{i2})$ - результаты ВЭ по регрессионной модели



Более простой способ определения коэффициентов множественной линейной регрессии основывается на следующем алгоритме:

$Y = X * a$ - искомая уравнение множественной регрессии. Умножив данное матричное уравнение с обеих сторон на X^T имеем:

$$X^T Y = X^T * X * a$$

отсюда, вектор коэффициентов линейной многофакторной регрессии определяется так:

$$a = (X^T Y) * (X^T X)^{-1} \quad (6)$$

Приведем данный алгоритм на конкретном примере. Пусть дана:

$$A = \begin{bmatrix} i & y_i & x_{i1} & x_{i2} \\ 1 & 10 & 2 & 1 \\ 2 & 12 & 2 & 2 \\ 3 & 17 & 8 & 10 \\ 4 & 13 & 2 & 4 \\ 5 & 15 & 6 & 8 \\ 6 & 10 & 3 & 4 \\ 7 & 14 & 5 & 7 \\ 8 & 12 & 3 & 3 \\ 9 & 15 & 9 & 10 \\ 10 & 12 & 10 & 11 \end{bmatrix} \quad y = A(:,2) \quad X = \begin{bmatrix} 1 & 2 & 1 \\ 1 & 2 & 2 \\ 1 & 8 & 10 \\ 1 & 2 & 4 \\ 1 & 6 & 8 \\ 1 & 3 & 4 \\ 1 & 5 & 7 \\ 1 & 3 & 3 \\ 1 & 9 & 10 \\ 1 & 10 & 11 \end{bmatrix}$$

В общем случае:

$$X = \begin{bmatrix} 1 & x_{11} & x_{12} \\ 1 & x_{21} & x_{22} \\ \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} \end{bmatrix}$$

$$X^T X = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_{11} & x_{21} & \dots & x_{n1} \\ x_{12} & x_{22} & \dots & x_{n2} \end{bmatrix} * \begin{bmatrix} 1 & x_{11} & x_{12} \\ 1 & x_{21} & x_{22} \\ \dots & \dots & \dots \\ 1 & x_{n1} & x_{n2} \end{bmatrix} = \begin{bmatrix} n & \sum x_{i1} & \sum x_{i2} \\ \sum x_{i1} & \sum x_{i1}^2 & \sum x_{i1} x_{i2} \\ \sum x_{i2} & \sum x_{i1} x_{i2} & \sum x_{i2}^2 \end{bmatrix}$$

$$X^T Y = \begin{bmatrix} 1 & 1 & \dots & 1 \\ x_{11} & x_{21} & \dots & x_{n1} \\ x_{12} & x_{22} & \dots & x_{n2} \end{bmatrix} * \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_n \end{bmatrix} = \begin{bmatrix} \sum y_i \\ \sum x_{i1} y_i \\ \sum x_{i2} y_i \end{bmatrix}$$

Результаты расчетов:

$$X^T X = \begin{pmatrix} 10 & 50 & 60 \\ 50 & 336 & 398 \\ 60 & 398 & 480 \end{pmatrix}$$

$$(X^T X)^{-1} = \begin{pmatrix} 0.4018 & -0.01676 & -0.03631 \\ -0.01676 & -0.16760 & -0.13687 \\ -0.03631 & -0.13687 & 0.12011 \end{pmatrix}$$

$$X^T y = (137,756,908)^T$$

$$a = (X^T X)^{-1} * (X^T y) = (0.3872, 0.1285, 0.6117)^T$$

$$y_i^M = 9.3872 + 0.1285 x_{i1} + 0.6117 x_{i2}$$

Построение линейной регрессионной модели в среде Матлаб

```
>> X=[19 17 58 26; 18 16 58 24; 15 17 54 28; 16 16 56 26; 14 17 53 25; 17 17 52 25]
X =
    19    17    58    26
    18    16    58    24
    15    17    54    28
    16    16    56    26
    14    17    53    25
    17    17    52    25
>> x1=X(:,1);
>> x2=X(:,2)
x1 =
    19
    18
    15
    16
    14
    17
>> x2=X(:,2)
x2 =
    17
    16
    17
    16
    17
    17
>> y=X(:,3)
```

```

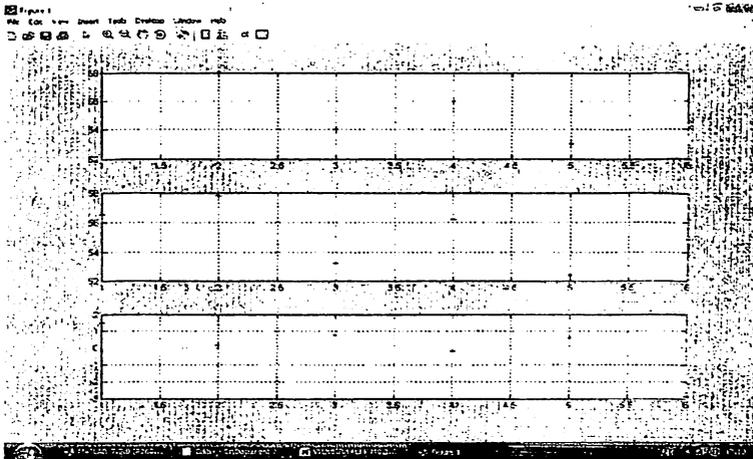
y =
  58
  58
  54
  56
  53
  52
>> XX=[1 1 1 1 1 1]'
XX =
  1
  1
  1
  1
  1
  1
>> AX=[XX x1 x2]
AX =
  1 19 17
  1 18 16
  1 15 17
  1 16 16
  1 14 17
  1 17 17
>> a=inv(AX'*AX)*(AX'*y)
a =
  77.1940
  0.8209
 -2.1343
>> Ym=a(1)+a(2)*x1+a(3)*x2
Ym =
  56.5075
  57.8209
  53.2239
  56.1791
  52.4030
  54.8657
>> tab1=[x1 x2 y Ym y-Ym]
tab1 =
  19.0000 17.0000 58.0000 56.5075 1.4925
  18.0000 16.0000 58.0000 57.8209 0.1791
  15.0000 17.0000 54.0000 53.2239 0.7761
  16.0000 16.0000 56.0000 56.1791 -0.1791
  14.0000 17.0000 53.0000 52.4030 0.5970

```

```

17.0000 17.0000 52.0000 54.8657 -2.8657
>>subplot(3,1,1),plot(y,'*'),grid
>>subplot(3,1,2),plot(Ym,'*'),grid
>>subplot(3,1,3),plot(y-Ym,'*'),grid

```



Порядок выполнения работы

1. Ознакомиться с теоретической частью по приведенным выше материалам;
2. Освоить алгоритмы для линейный регрессионный анализ в среде Матлаб
3. Построить линейной регрессионной модели в среде Матлаб

Контрольные вопросы

1. Что такое регрессионный анализ данных
2. Что такое линейный регрессионный анализ данных
3. Алгоритмы для выполнение линейный регрессионный анализ в среде Матлаб

Лабораторная работа №4

Тема: Создание нелинейных регрессионных моделей в среде Matlab

Цель работы: Построить нелинейных регрессионных моделей в среде Matlab

Теоретические сведения

Связь между аргументом и функцией может иметь нелинейный характер. Аппроксимация кривой выполняется тем же путем с использованием метода наименьших квадратов, что и в случае прямой линии. Линия регрессии должна удовлетворять условию минимума суммы квадратов расстояний до каждой точки корреляционного поля. В данном случае в уравнении (1) y представляет собой расчетное значение функции, определенное при помощи уравнения выбранной криволинейной связи по фактическим значениям x_j .

В общем случае нелинейной зависимости

$$y'(x) = a_0 + a_1x + a_2x^2 + \dots + a_kx^k.$$

По методу наименьших квадратов находим частные производные по коэффициентам регрессии и приравняем их к нулю. Получаем систему уравнений:

$$\begin{cases} \frac{\partial S^2}{\partial a_0} = -2 \sum_{j=1}^m (y_j - a_0 - a_1x_j - a_2x_j^2 - \dots - a_kx_j^k) = 0; \\ \frac{\partial S^2}{\partial a_1} = -2 \sum_{j=1}^m (y_j - a_0 - a_1x_j - a_2x_j^2 - \dots - a_kx_j^k) x_j = 0; \\ \dots \\ \frac{\partial S^2}{\partial a_k} = -2 \sum_{j=1}^m (y_j - a_0 - a_1x_j - a_2x_j^2 - \dots - a_kx_j^k) x_j^k = 0. \end{cases}$$

Оценкой тесноты связи при криволинейной зависимости служит теоретическое корреляционное отношение η_{xy} , представляющее собой корень квадратный из соотношения двух дисперсий: среднего квадрата σ_p^2 отклонений расчетных значений y' функции по найденному уравнению регрессии от среднеарифметического значения \bar{Y} величины y к среднему квадрату отклонений σ_y^2 фактических значений функции y от ее среднеарифметического значения:

$$\eta_{\sigma} = \sqrt{\frac{\sigma_p^2}{\sigma_y^2}} = \sqrt{\frac{\sum_{j=1}^m (y'_j - \bar{Y})^2}{\sum_{j=1}^m (y_j - \bar{Y})^2}}$$

```
>> x=[1 20 25; 1 22 33; 1 25 28; 1 22 25; 1 17 27; 1 24 27; 1 25 37; 1 29 38; 1 22 34;
1 23 28]
```

```
x =
```

```
1 20 25
1 22 33
1 25 28
1 22 25
1 17 27
1 24 27
1 25 37
1 29 38
1 22 34
1 23 28
```

```
>>> y=[76 83 74 64 62 73 84 93 89 71]'
```

```
y =
```

```
76
83
74
64
62
73
84
93
89
71
```

```
>> a=inv(x'*x)*(x'*y)
```

```
a =
```

```
16.2555
0.5375
1.6005
```

```
>> x1=x(:,2)
```

```
x1 =
20
22
25
```

```
22
17
24
25
29
22
23
```

```
>> x2=x(:,3)
```

```
x2 =
```

```
25
33
28
25
27
27
37
38
34
28
```

```
>> F=16.2555+0.5375*x1+1.6005*x2
```

```
F =
```

```
67.0180
80.8970
74.5070
68.0930
68.6065
72.3690
88.9115
92.6620
82.4975
73.4320
```

```
>> z1=x1;
```

```
>> z2=x2;
```

```
>> z3=x1.*x2;
```

```
>> z4=x1.^2;
```

```
>> z5=x2.^2;
```

```
>> z=[z1 z2 z3 z4 z5]'
```

z =

Columns 1 through 6

20	22	25	22	17	24
25	33	28	25	27	27
500	726	700	550	459	648
400	484	625	484	289	576
625	1089	784	625	729	729

Columns 7 through 10

25	29	22	23
37	38	34	28
925	1102	748	644
625	841	484	529
1369	1444	1156	784

>> zz=z'

zz =

20	25	500	400	625
22	33	726	484	1089
25	28	700	625	784
22	25	550	484	625
17	27	459	289	729
24	27	648	576	729
25	37	925	625	1369
29	38	1102	841	1444
22	34	748	484	1156
23	28	644	529	784

>> p=zz;

>> a=inv(p'*p)*(p'*y)

a =

5.3786
-0.6625
0.3947
-0.3728
-0.1110

>> ym=5.3786*z1-0.6625*z2+0.3947*z3-0.3728*z4-0.1110*z5

ym =

69.8645

81.7047

72.1810

69.0415

66.0578

71.3127

90.0910

91.9550

82.2886

75.1094

```
>> tab=[x1 x2 y ym y-ym]
```

```
tab =
```

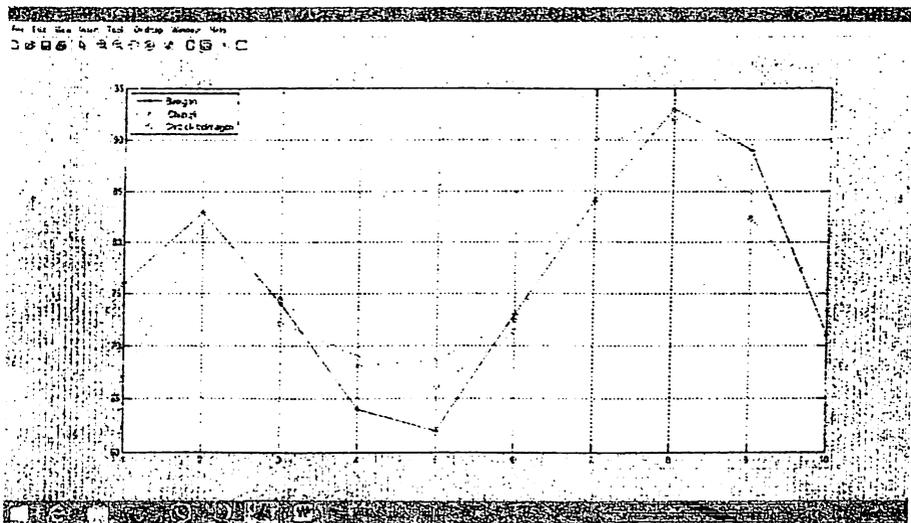
20.0000	25.0000	76.0000	69.8645	6.1355
22.0000	33.0000	83.0000	81.7047	1.2953
25.0000	28.0000	74.0000	72.1810	1.8190
22.0000	25.0000	64.0000	69.0415	-5.0415
17.0000	27.0000	62.0000	66.0578	-4.0578
24.0000	27.0000	73.0000	71.3127	1.6873
25.0000	37.0000	84.0000	90.0910	-6.0910
29.0000	38.0000	93.0000	91.9550	1.0450
22.0000	34.0000	89.0000	82.2886	6.7114
23.0000	28.0000	71.0000	75.1094	-4.1094

```
>> x=[1:1:10];
```

```
>> plot(x,y,'-*',x,F,'p',x,ym,'o'),grid on;
```

```
>> legend('Berilgan','Chiziqli','Chiziqli bolmagan')
```

```
>> legend('Location','northwest')
```



Порядок выполнения работы

1. Ознакомиться с теоретической частью по приведенным выше материалам;
2. Освоить алгоритмы для линейный регрессионный анализ в среде Матлаб
3. Построить нелинейной регрессионной модели в среде Матлаб

Контрольные вопросы

1. Что такое регрессионный анализ данных
2. Что такое нелинейный регрессионный анализ данных
3. Алгоритмы для выполнение нелинейный регрессионный анализ в среде Матлаб

Лабораторная работа №5

Тема: Корреляционный анализ статических данных

Цель работы: Изучить основных вычислительных характеристик матриц в Matlab

Теоретические сведения

Данные обычно представляется в виде матрицы определенного размера, т.е. N – строк и M – столбцов, при этом строки обозначают объекты (транзакции), а столбцы атрибуты данных. Например, успеваемость студентов определенной группы можно представить в виде таблицы (5.1.):

Таблица 5.1.

Предмет/ № студента	Математика	Информатика	История Узбекистана	Физика	Физическая культура
1	a_{11}	a_{12}	a_{13}	a_{14}	a_{15}
2	a_{21}	a_{22}	a_{23}	a_{24}	a_{25}
3	a_{31}	a_{32}	a_{33}	a_{34}	a_{35}
...
...
20	$a_{20,1}$	$a_{20,2}$	$a_{20,3}$	$a_{20,4}$	$a_{20,5}$

Наличие взаимосвязи между двумя случайными величинами X и Y определяется с помощью корреляционного момента.

$\mu_{xy} = M\{(x - M(x)) * (y - M(y))\}$, при этом если $\mu_{xy} \neq 0$ то между X и Y существует корреляционная зависимость, при этом, если $\mu_{xy} > 0 \Rightarrow x \uparrow \Rightarrow y \uparrow$ – прямая корреляционная связь; если $\mu_{xy} < 0 \Rightarrow x \uparrow \Rightarrow y \downarrow$ – обратное корреляционная связь; если $\mu_{xy} = 0$ то между X и Y отсутствует корреляционная связь.

μ_{xy} – размерная случайная величина, для расчета силы корреляционной связи μ_{xy} преобразуется в безразмерный вид:

$$r_{xy} = \frac{\mu_{xy}}{\sigma_x \sigma_y}, \text{ где } \sigma_x = \sqrt{D(x)}, \sigma_y = \sqrt{D(y)}$$

$|r_{xy}| < 1$, при этом если $r_{xy} \geq 0.6$ – то корреляционная связь называется прямой и существенной. Если $-1 < r_{xy} \leq 0$ – то корреляционная связь называется обратной и существенной.

Организация процессии корреляционного анализа данных.

Процесс корреляционного анализа по матрице походных данных целесообразно организовать так:

1. все столбцы матрицы проверяется на принадлежность основным законам распределению по критерию χ^2 .
2. если определенный столбцы матрицы не подчиняется к какому то определенному закону, то этот столбце данных анализируется на наличие случайных ошибок, шумов, фильтруется и после этого заново приводится по критерию χ^2 .
3. во возможности для всех столбцов строится их гистограммы с дополнительными числовыми характеристиками $M(a_{ij}), \sigma(a_{ij})$
4. далее, с применением функции Matlab `corr(A)` вычисляется матрица корнях коэффициентов корреляции.
5. Приводится анализ корреляционной матрицы и определяется задачи регрессии с выделение наиболее существенных факторов на результирующий фактор.

```
a=[ 2 8 80 ; 4 12 112 ; 6 15 95 ; 8 12 56 ; 9 6 88 ; 11 25 65 ]
```

```
x1=a(:,1); x2=a(:,2); y=a(:,3);
```

```
subplot(3,1,1),plot(x1,'*'),grid;
```

```
subplot(3,1,2),plot(x2,'*'),grid;
```

```
subplot(3,1,3),plot(y,'*'),grid
```

$ar=cov(a)$ - коверация матрицы

$acr=corrcoef(a)$ - корреляция матрицы

$R_{xy}=std(a)$ - ўртача квадратик четлиниш

```
New to MATLAB? Watch this Video, see Demos, or read Getting Started.
>> a=[2 8 80 ; 4 12 112 ; 6 15 95 ; 8 12 56 ; 9 6 88 ; 11 25 65]

a =

     2     8    80
     4    12   112
     6    15    95
     8    12    56
     9     6    88
    11    25    65

>> x1=a(:,1)

x1 =

     2
     4
     6
     8
     9
    11

>> x2=a(:,2)

x2 =

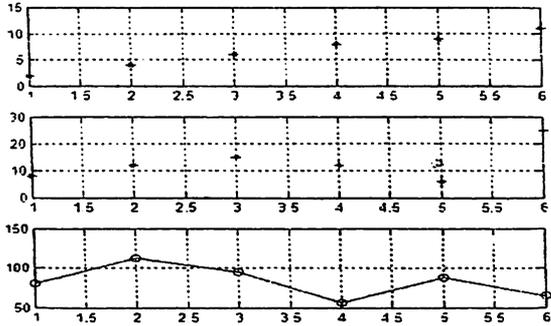
     8
    12
    15
    12
     6
    25

>> y=a(:,3)

y =

    80
   112
    95
    56
    88
    65

>> subplot(3,1,1), plot(x1,'*'), grid
>> subplot(3,1,2), plot(x2,'*'), grid
>> subplot(3,1,3), plot(y,'*'), grid
>> |
```



```

>> ai=cov(a)

ai =

    11.0667    11.8000   -34.7333
    11.8000    44.8000   -42.8000
   -34.7333   -42.8000    114.2667

>> acor=corrcoef(ai)

acor =

    1.0000    0.5259   -0.5130
    0.5259    1.0000   -0.3142
   -0.5130   -0.3142    1.0000

>> Pxy=std(a)

Pxy =

    3.3267    6.6933    20.3535

```

Порядок выполнения работы

1. Ознакомиться с теоретической частью по приведенным выше материалам;
2. Освоить операторы для выполнения корреляционный анализ в среде Матлаб
3. Построить корреляционный анализ модели в среде Матлаб

Контрольные вопросы

1. Что такое корреляционный анализ данных
2. Операторы для выполнение корреляционный анализ данных в среде Матлаб
3. Коэффициентные значения корреляционного анализа данных

Лабораторная работа №6

Тема: Кластеризация на основе классификации

Цель работы: Изучить основных вычислительных характеристик матриц в Matlab

Теоретические сведения

Кластерный анализ позволяет рассматривать достаточно большой объем информации и резко сокращать, сжимать большие массивы информации, делать их компактными и наглядными.

Задачи кластеризации состоят в разделении исследуемой множеств объектов на группы «похожих» объектов называемых кластером.

Решением задачи кластеризации является отнесение каждого объектов данных к одному (или нескольким) из заранее определённых классов и построение модели данных определённого разбиение множество объектов данных на классы.

В задачи кластеризации отнесение каждого из объектов данных осуществляет к одному (или нескольким) из заранее неопределённых классов. Определение кластеров и разбиение по ним объектов данных выражается в итоговой модели данных, которая является решением задачи кластеризации.

Постановка задачи кластеризации.

Дано: Набор данных следующими свойствами:

- Каждый экземпляр данных выражается чётким числовым значением;
- Класс для каждого конкретного экземпляра данных неизвестен.

Найти:

- Способ сравнение данных между собой (меру сходство);
- Способ кластеризации;
- Разбиение данных по кластером.

Дано множество объектов данных I , каждый из которых представлен набором атрибутов. Требуется настроить множество кластеров C и отображение F множества I на множество C т.е. $F: I \rightarrow C$

Отображение F задаёт модель данных, являющем решением задачи. Множество I определим следующим образом:

$I = \{i_1, i_2, \dots, i_j, \dots, i_n\}$ где i_j - исследуемый объект.

Задача кластеризации состоит в построение множества:

$C = \{C_1, C_2, \dots, C_k, \dots, C_r\}$

Здесь C_k - кластер, содержащий похожие друг на друге объекты из множества I :

$C_k = \{i_j, i_p \mid i_j, i_p \in I \cup d(i_j, i_p) < \sigma\}$

где σ - величина определяющие меру близости для включение объектов в один кластер;

$d(i_j, i_p)$ - мера близости между объектами, называемая расстояние.

При этом:

1^o $d(i_j, i_p) \geq 0$ для $\forall i_j, i_p$

2^o $d(i_j, i_p) = 0 : i_j = i_p$

3^o $d(i_j, i_p) = d(i_p, i_j)$

4^o $d(i_j, i_p) \leq d(i_j, i_r) + d(i_r, i_p)$

Если $d(i_j, i_p) < \sigma \Rightarrow i_j, i_p$ близки и помещается в один кластер.

Алгоритм кластеризации.

Большинство алгоритмов кластеризации используют в качестве входящих данных матрицу D :

$$D = \begin{bmatrix} 0 & d(e_1, e_2) & \dots & d(e_1, e_n) \\ d(e_2, e_1) & 0 & \dots & d(e_2, e_n) \\ \dots & \dots & \dots & \dots \\ d(e_n, e_1) & d(e_n, e_2) & \dots & 0 \end{bmatrix}$$

Меры близости кластеров.

Приведем наиболее известные меры близости:

1) Евклидово расстояние:

$$d_2(x_i, x_j) = \sqrt{\sum_{l=1}^m (x_{il} - x_{jl})^2}$$

2) Хемминга расстояние:

$$d_H(x_i, x_j) = \sum_{l=1}^m |x_{il} - x_{jl}|$$

3) Расстояние Чебишов:

$$d_\infty(x_i, x_j) = \max_{1 \leq l \leq m} |x_{il} - x_{jl}|$$

Синтаксис

Y = pdist(X)

Y = pdist(X,'metric')

Y = pdist(X,distfun,p1,p2,...)

Y = pdist(X,'minkowski',p)

МИСОЛ 1.

```
>> X=normrnd(0,1,7,3)
```

```
X =
```

```
0.6353 0.4620 -0.1132
-0.6014 -0.3210 0.3792
0.5512 1.2366 0.9442
-1.0998 -0.6313 -2.1204
0.0860 -2.3252 -0.6447
-2.0046 -1.2316 -0.7043
-0.4931 1.0556 -1.0181
```

```
>> Y = pdist(X)
```

```
Y =
```

```
Columns 1 through 11
```

```
1.5444 1.3134 2.8696 2.8902 3.1917 1.5635 2.0183 2.5677 2.3532
1.9930 1.9646
```

```
Columns 12 through 21
```

```
3.9505 3.9277 3.9168 2.2302 2.5404 1.7845 2.1045 2.3601 3.4504
2.7595
```

```
>> S = squareform(Y)
```

```
S =
```

```
0 1.5444 1.3134 2.8696 2.8902 3.1917 1.5635
1.5444 0 2.0183 2.5677 2.3532 1.9930 1.9646
1.3134 2.0183 0 3.9505 3.9277 3.9168 2.2302
```

2.8696	2.5677	3.9505	0	2.5404	1.7845	2.1045
2.8902	2.3532	3.9277	2.5404	0	2.3601	3.4504
3.1917	1.9930	3.9168	1.7845	2.3601	0	2.7595
1.5635	1.9646	2.2302	2.1045	3.4504	2.7595	0

При помощи функции `squareform` вектор Y можно конвертировать в квадратную матрицу. Элемент (i, j) полученной матрицы, при $i < j$, будет соответствовать расстоянию между i -м и j -м объектами исходного множества данных:

$Y = \text{pdist}(X, 'metric')$ входной параметр `'metric'` определяет вид расстояния. Предусмотрены следующие виды расстояний между объектами:

Виды парных расстояний между объектами, используемые в `pdist`:

1. Евклидово расстояние:

$$d_{rs}^2 = (x_r - x_s)(x_r - x_s)'$$

2. Стандартизованное Евклидово расстояние:

$$d_{rs}^2 = (x_r - x_s)D^{-1}(x_r - x_s)'$$

где D - диагональная матрица. Диагональными элементами D являются выборочные дисперсии признаков многомерной случайной величины $X_j, j=1..m$.

3. Расстояние Махаланобиса:

$$d_{rs}^2 = (x_r - x_s)V^{-1}(x_r - x_s)'$$

где V - ковариационная матрица, рассчитанная по выборке X .

4. Расстояние по Манхеттену:

$$d_{rs} = \sum_{j=1}^m |x_{rj} - x_{sj}|$$

5. Метрика Минковского:

$$d_p = \left[\sum_{j=1}^n |x_j - x_y|^p \right]^{\frac{1}{p}}$$

6. Расстояние Хэмминга:

$$d_{xz} = (\#(x_{ij} = x_{ij})/n)$$

Пример 1

1. Расчет парных расстояний между объектами исходного множества данных. В качестве исходного множества данных используется двумерная случайная величина. Количество объектов в множестве исходных данных равно 7.

```
>> X = [3 1.7; 1 1; 2 3; 2 2.5; 1.2 1; 1.1 1.5; 3 1]
```

```
X =
```

```
3.0000 1.7000
1.0000 1.0000
2.0000 3.0000
2.0000 2.5000
1.2000 1.0000
1.1000 1.5000
3.0000 1.0000
```

```
>> Y = pdist(X)'
```

```
Y =
```

```
2.1190
1.6401
1.2806
1.9313
1.9105
0.7000
2.2361
1.8028
0.2000
0.5099
2.0000
0.5000
2.1541
1.7493
2.2361
1.7000
1.3454
1.8028
```

0.5099
1.8000
1.9647

Пример 2

```
>> X = [3 1.7; 1 1; 2 3; 2 2.5; 1.2 1; 1.1 1.5; 3 1]
```

```
X =
```

```
3.0000 1.7000  
1.0000 1.0000  
2.0000 3.0000  
2.0000 2.5000  
1.2000 1.0000  
1.1000 1.5000  
3.0000 1.0000
```

```
>> Y1 = pdist(X, 'euclidean');
```

```
>> Y2 = pdist(X, 'seuclidean');
```

```
>> Y3 = pdist(X, 'mahalanobis');
```

```
>> Y4 = pdist(X, 'cityblock');
```

```
>> Y5 = pdist(X, 'minkowski');
```

```
>> Y6 = pdist(X, 'cosine');
```

```
>> Y7 = pdist(X, 'hamming');
```

```
>> Y8 = pdist(X, 'jaccard');
```

```
>> Y = [Y1'; Y2'; Y3'; Y4'; Y5'; Y6'; Y7'; Y8']
```

```
Y =
```

```
2.1190 2.4992 2.3879 2.7000 2.1190 0.0362 1.0000 1.0000  
1.6401 2.0036 2.1983 2.3000 1.6401 0.1072 1.0000 1.0000  
1.2806 1.5399 1.6946 1.8000 1.2806 0.0715 1.0000 1.0000  
1.9313 2.2815 2.1684 2.5000 1.9313 0.0160 1.0000 1.0000  
1.9105 2.2378 2.2284 2.1000 1.9105 0.0879 1.0000 1.0000  
0.7000 0.8757 0.8895 0.7000 0.7000 0.0187 0.5000 0.5000  
2.2361 2.7621 2.6097 3.0000 2.2361 0.0194 1.0000 1.0000  
1.8028 2.2115 2.0616 2.5000 1.8028 0.0061 1.0000 1.0000  
0.2000 0.2341 0.2378 0.2000 0.2000 0.0041 0.5000 0.5000  
0.5099 0.6363 0.6255 0.6000 0.5099 0.0116 1.0000 1.0000  
2.0000 2.3408 2.3778 2.0000 2.0000 0.1056 0.5000 0.5000  
0.5000 0.6255 0.6353 0.5000 0.5000 0.0038 0.5000 0.5000  
2.1541 2.6713 2.5522 2.8000 2.1541 0.0412 1.0000 1.0000  
1.7493 2.1518 2.0153 2.4000 1.7493 0.0010 1.0000 1.0000  
2.2361 2.7621 2.9890 3.0000 2.2361 0.2106 1.0000 1.0000  
1.7000 2.0970 1.9750 2.3000 1.7000 0.0202 1.0000 1.0000  
1.3454 1.6354 1.5106 1.9000 1.3454 0.0009 1.0000 1.0000  
1.8028 2.2115 2.4172 2.5000 1.8028 0.1604 1.0000 1.0000  
0.5099 0.6363 0.6666 0.6000 0.5099 0.0295 1.0000 1.0000  
1.8000 2.1067 2.1400 1.8000 1.8000 0.0688 0.5000 0.5000
```

1.9647 2.3101 2.4517 2.4000 1.9647 0.1840 1.0000 1.0000

Пример 3

```
>> X = [3 1.7; 1 1; 2 3; 2 2.5; 1.2 1; 1.1 1.5; 3 1]
```

```
X =
```

```
3.0000 1.7000
1.0000 1.0000
2.0000 3.0000
2.0000 2.5000
1.2000 1.0000
1.1000 1.5000
3.0000 1.0000
```

```
>> Y1 = pdist(X,'minkowski',1)';
```

```
>> Y2 = pdist(X,'minkowski',2)';
```

```
>> Y3 = pdist(X,'minkowski',3)';
```

```
>> Y = [Y1'; Y2'; Y3]'
```

```
Y =
```

```
2.7000 2.1190 2.0282
2.3000 1.6401 1.4732
1.8000 1.2806 1.1478
2.5000 1.9313 1.8346
2.1000 1.9105 1.9007
0.7000 0.7000 0.7000
3.0000 2.2361 2.0801
2.5000 1.8028 1.6355
0.2000 0.2000 0.2000
0.6000 0.5099 0.5013
2.0000 2.0000 2.0000
0.5000 0.5000 0.5000
2.8000 2.1541 2.0418
2.4000 1.7493 1.6010
3.0000 2.2361 2.0801
2.3000 1.7000 1.5723
1.9000 1.3454 1.2002
2.5000 1.8028 1.6355
0.6000 0.5099 0.5013
1.8000 1.8000 1.8000
2.4000 1.9647 1.9115
```

LINKAGE DENDROGRAM

```
Z = linkage(Y)
```

```
Z = linkage(Y,'method')
```

$Z = \text{linkage}(Y)$ функция позволяет сформировать иерархическое дерево бинарных кластеров с использованием алгоритма <ближайшего соседа>.

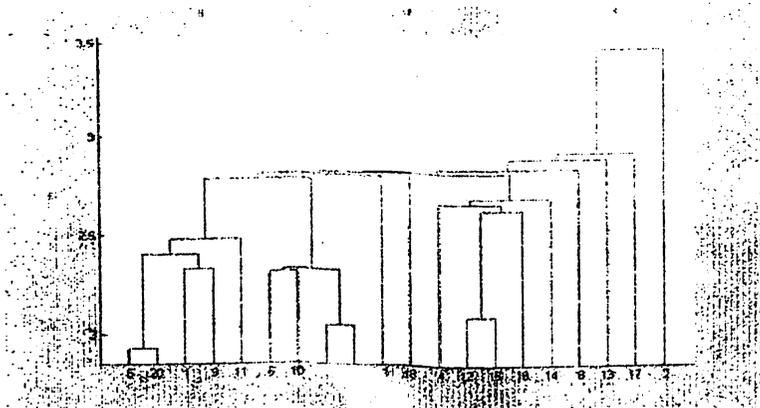
$Z = \text{linkage}(Y, 'method')$ входной аргумент *'method'* позволяет задать алгоритм кластеризации.

Алгоритмы кластеризации

Примеры использования функции формирования иерархического дерева бинарных кластеров

1. Количество объектов в множестве исходных данных равно 20. Графическое представление дерева бинарных кластеров выполняется с помощью функции `dendrogram`.

```
>> X=normrnd(0,1,20,10);
>> Y = pdist(X);
>> Z = linkage(Y)
Z =
  5.0000  20.0000  1.9330
  7.0000  19.0000  2.0429
 12.0000  15.0000  2.0979
  6.0000  10.0000  2.3100
 24.0000  22.0000  2.3239
  1.0000   9.0000  2.3283
 26.0000  21.0000  2.4018
 27.0000  11.0000  2.4800
 23.0000  16.0000  2.6409
  4.0000  29.0000  2.6727
 30.0000  14.0000  2.7020
 28.0000  25.0000  2.7839
 32.0000   3.0000  2.8100
 33.0000  18.0000  2.8246
 34.0000  31.0000  2.8279
 35.0000   8.0000  2.8495
 36.0000  13.0000  2.9005
 37.0000  17.0000  2.9329
 38.0000   2.0000  3.4541
>> H = dendrogram(Z);
```



2. Формирование иерархического дерева бинарных кластеров для 2-х мерной случайной величины. Количество объектов в множестве исходных данных равно 7. Сравниваются различные алгоритмы кластеризации. Графическое представление результатов кластеризации выполняется с помощью функции `dendrogram`.

2.1. Исходные данные:

```
>> X = [3 1.7; 1 1; 2 3; 2 2.5; 1.2 1; 1.1 1.5; 3 1]
```

```
X =
```

```
3.0000 1.7000
1.0000 1.0000
2.0000 3.0000
2.0000 2.5000
1.2000 1.0000
1.1000 1.5000
3.0000 1.0000
```

```
>> Y = pdist(X);
```

```
Y =
```

```
Columns 1 through 11
2.1190 1.6401 1.2806 1.9313 1.9105 0.7000 2.2361 1.8028 0.2000
0.5099 2.0000
Columns 12 through 21
0.5000 2.1541 1.7493 2.2361 1.7000 1.3454 1.8028 0.5099 1.8000
1.9647
```

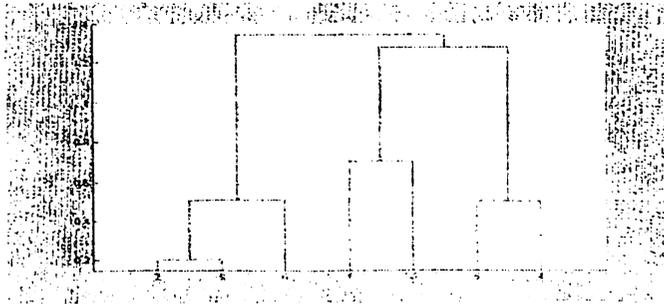
2.2. Кластеризация при помощи алгоритма <ближайшего соседа>

```
>> Z = linkage(Y, 'single')
```

```

Z =
  2.0000  5.0000  0.2000
  3.0000  4.0000  0.5000
  8.0000  6.0000  0.5099
  1.0000  7.0000  0.7000
 11.0000  9.0000  1.2806
 12.0000 10.0000  1.3454
>> dendrogram(Z);

```

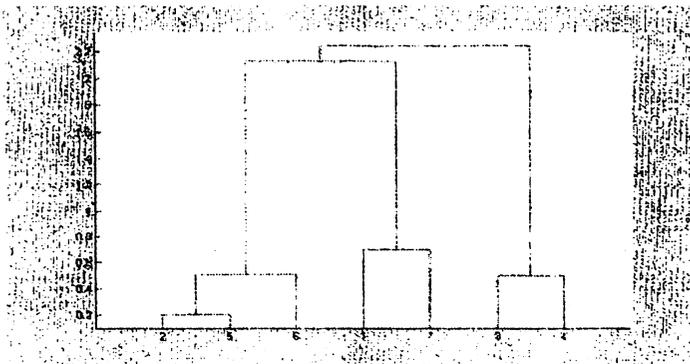


2.3. Кластеризация при помощи алгоритма <дальнего соседа>

```

>> Z = linkage(Y, 'complete')
Z =
  2.0000  5.0000  0.2000
  3.0000  4.0000  0.5000
  8.0000  6.0000  0.5099
  1.0000  7.0000  0.7000
 11.0000 10.0000  2.1190
 12.0000  9.0000  2.2361
>> dendrogram(Z);

```



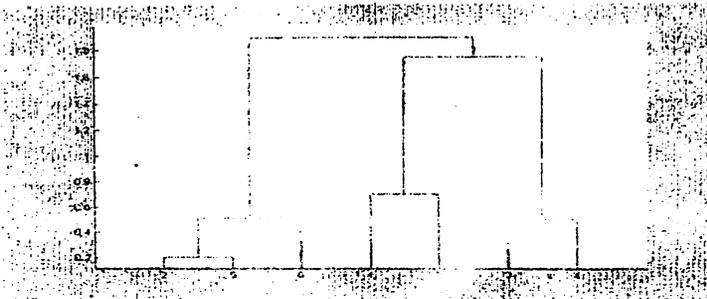
2.4. Кластеризация при помощи алгоритма <средней связи>

```
>> Z = linkage(Y, 'average')
```

```
Z =
```

```
2.0000 5.0000 0.2000  
3.0000 4.0000 0.5000  
8.0000 6.0000 0.5099  
1.0000 7.0000 0.7000  
11.0000 9.0000 1.7399  
12.0000 10.0000 1.8928
```

```
>> dendrogram(Z);
```



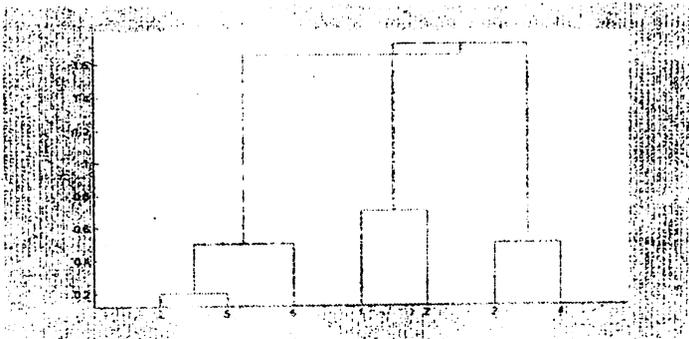
2.5. Кластеризация при помощи алгоритма центроидного алгоритма

```
>> Z = linkage(Y, 'centroid')
```

```
Z =
```

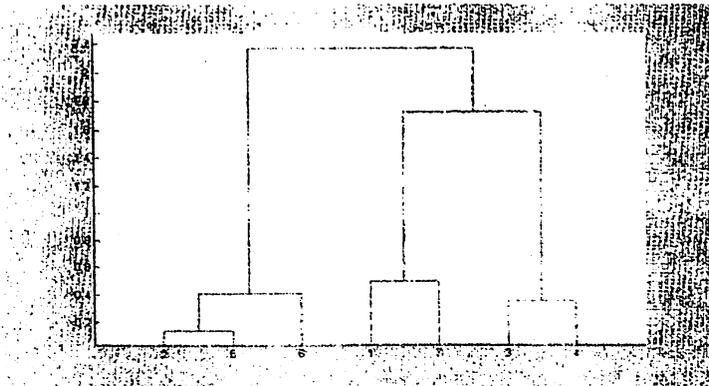
```
2.0000 5.0000 0.2000  
8.0000 6.0000 0.5000  
3.0000 4.0000 0.5000  
1.0000 7.0000 0.7000  
11.0000 10.0000 1.7205  
12.0000 9.0000 1.6554
```

```
>> dendrogram(Z);
```



2.6. Кластеризация при помощи алгоритма пошагового алгоритма

```
>> Z = linkage(Y, 'ward')
Z =
    2.0000    5.0000    0.1414
    3.0000    4.0000    0.3536
    8.0000    6.0000    0.4082
    1.0000    7.0000    0.4950
    11.0000   9.0000    1.7205
    12.0000  10.0000    2.1674
>> dendrogram(Z);
```



Порядок выполнения работы

1. Ознакомиться с теоретической частью по приведенным выше материалам;
2. Ознакомиться с операторами кластеризации данных Матлаб
3. Освоить алгоритмы кластеризации
4. Построить кластеризация данных модели в среде Матлаб

Контрольные вопросы

1. Что такое кластеризация
2. Что такое классификация
3. Алгоритмы кластеризации
4. Операторы для выполнение кластеризации данных в среде Матлаб

Лабораторная работа №7

Тема: Изучение нечётких множеств на основе пакета FLT в среде Matlab

Цель работы: Изучить основных вычислительных характеристик матриц в Matlab

Теоретические сведения

Понятие нечеткого множества - это попытка математической формализации нечеткой информации для построения математических моделей. В основе этого понятия лежит представление о том, что составляющие данное множество элементы, обладающие общим свойством, могут обладать этим свойством в различной степени и, следовательно принадлежать к данному множеству с различной степенью. При таком подходе высказывания типа "такой-то элемент принадлежит данному множеству" теряют смысл, поскольку необходимо указать "насколько сильно" или с какой степенью конкретный элемент удовлетворяет свойствам данного множества.

Определение 1. *Нечетким множеством (fuzzy set) \tilde{A} на универсальном множестве U называется совокупность пар $(\mu_A(u), u)$, где $\mu_A(u)$ - степень принадлежности элемента $u \in U$ к нечеткому множеству \tilde{A} . Степень принадлежности - это число из диапазона $[0, 1]$. Чем выше степень принадлежности, тем в большей мерой элемент универсального множества соответствует свойствам нечеткого множества.*

Определение 2. *Функцией принадлежности (membership function) называется функция, которая позволяет вычислить степень принадлежности произвольного элемента универсального множества к нечеткому множеству.*

Если универсальное множество состоит из конечного количества элементов

$U = \{u_1, u_2, \dots, u_k\}$, тогда нечеткое множество \tilde{A} записывается в виде $\tilde{A} = \sum_{i=1}^k \mu_A(u_i) / u_i$. В

случае непрерывного множества U используют такое обозначение $\tilde{A} = \int_U \mu_A(u) / u$

Примечание: знаки Σ и \int в этих формулах означают совокупность пар $\mu_A(u)$ и u .

Определение 3. *Лингвистической переменной* (linguistic variable) называется переменная, значениями которой могут быть слова или словосочетания некоторого естественного или искусственного языка.

Определение 4. *Терм-множеством* (term set) называется множество всех возможных значений лингвистической переменной.

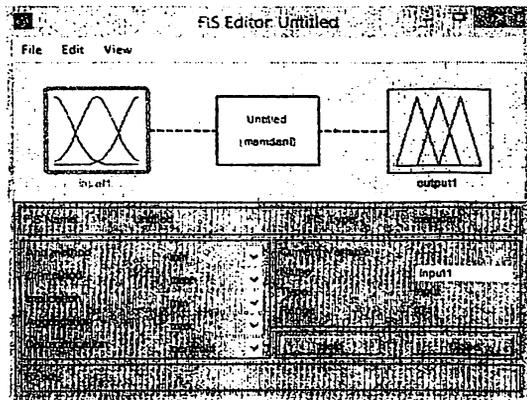
Определение 5. *Термом* (term) называется любой элемент терм-множества. В теории нечетких множеств терм формализуется нечетким множеством с помощью функции принадлежности.

Пример 2. Рассмотрим переменную “*скорость автомобиля*”, которая оценивается по шкале “*низкая*”, “*средняя*”, “*высокая*” и “*очень высокая*”.

В этом примере лингвистической переменной является “*скорость автомобиля*”, термами - лингвистические оценки “*низкая*”, “*средняя*”, “*высокая*” и “*очень высокая*”, которые и составляют терм-множество.

Вводим команда *fuzzy*

```
| f >> fuzzy |
```



Пример: Урожай хлопка-производство. Для достижения эффективного урожая приводится несколько взаимосвязанных факторов. По естественный эффективности таблица 7.1.

таблица 7.1

Температура \ Влажность	холода	Сред.холод	нормал	жара	знойный
низкий	низкий	низкий	удовлетво о	удовлетво	низкий
Низко влажно	низкий	низкий	средний	средний	средний
средний	низкий	удовлетво	средний	хороший	хороший
высокий	низкий	удовлетво	средний	хороший	хороший
мокрый	низкий	удовлетво	хороший	хороший	отлично

По искусственной эффективности таблица 7.2

минерализация \ Ishlan.lik	плохо	удовлетво	средний	хороший	высокий
неудовлетво	низкий	низкий	удовлетво	удовлетво	низкий
удовлетво	низкий	удовлетво	средний	средний	средний
средний	низкий	удовлетво	средний	хороший	хороший
хороший	низкий	удовлетво	средний	хороший	хороший
отлично	удовлетво	средний	хороший	хороший	отлично

Температура: $X(1) = \{ \text{холода, сред.холод, нормал, жара, знойный} \}$

Влажность: $X(2) = \{ \text{низкий, низко влажно, средний, высокий, мокрый} \}$

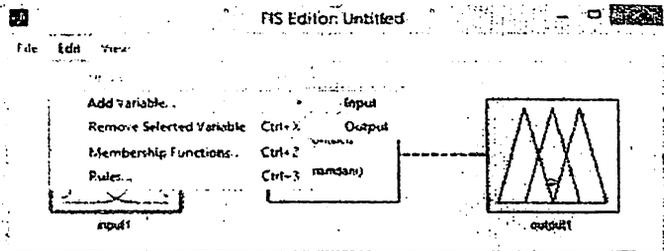
Минерализация: $X(3) = \{ \text{плохо, удовлетво, средний, хороший, высокий} \}$

Ishlanganlik: $X(4) = \{ \text{неудовлетво, удовлетво, средний, хороший, отлично} \}$

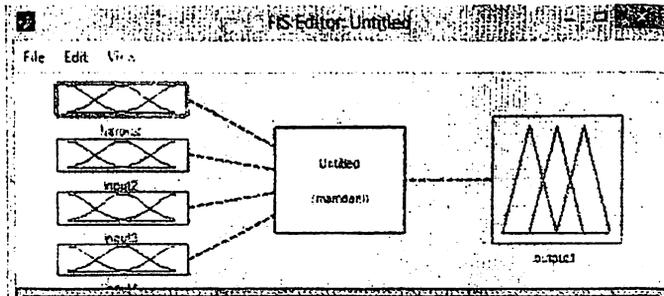
Естественная эффективность: $y(1) = \{ \text{низкий, удовлетво, средний, хороший, отлично} \}$

Искусственная эффективность: $y(2) = \{ \text{низкий, удовлетво, средний, хороший, отлично} \}$

1. Добавления входные переменные

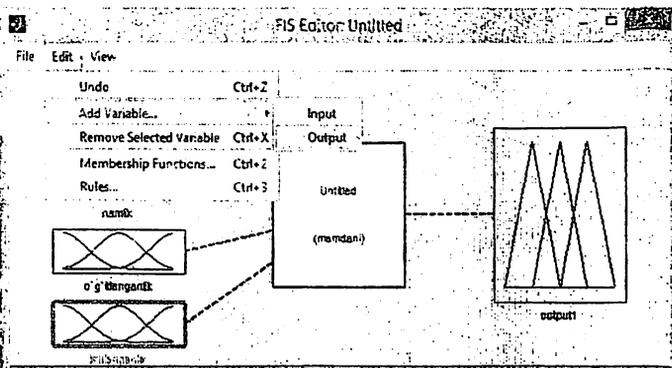


Четыре переменные x1,x2,x3,x4 и наименование

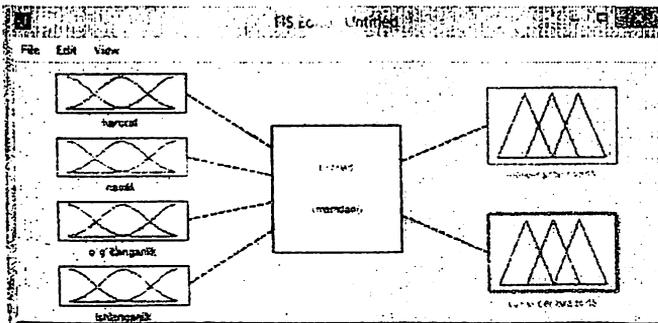
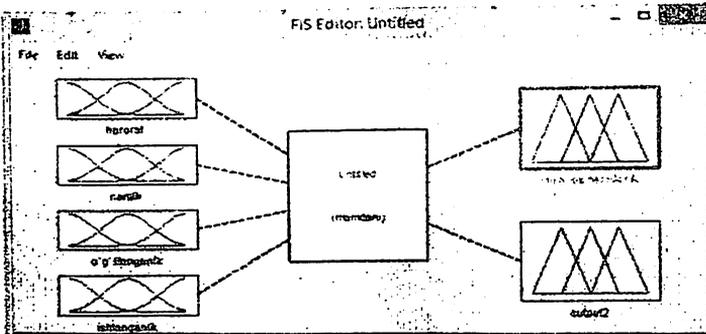


Вводится две выходные параметры

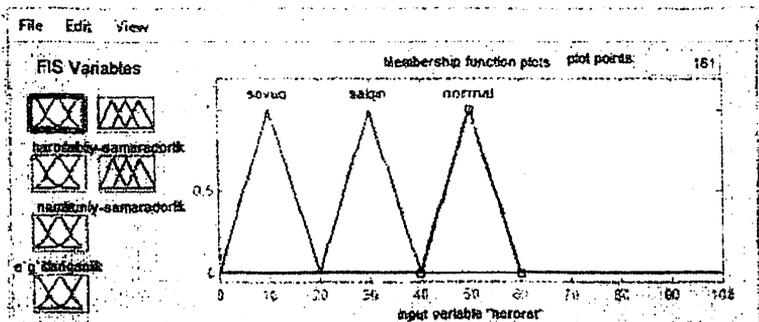
2. Добавится выходные переменные



наименование

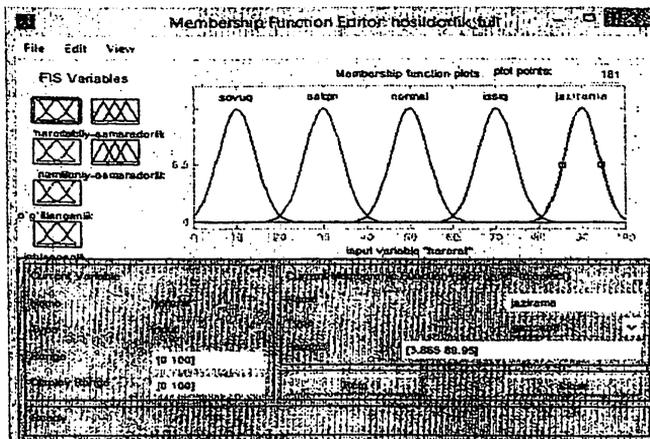
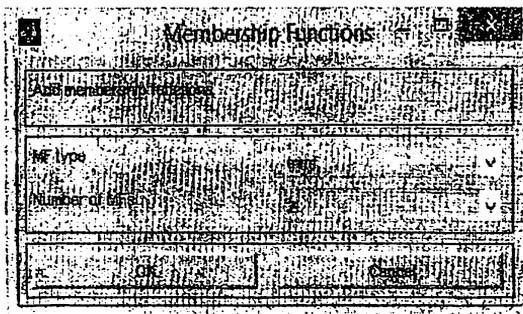
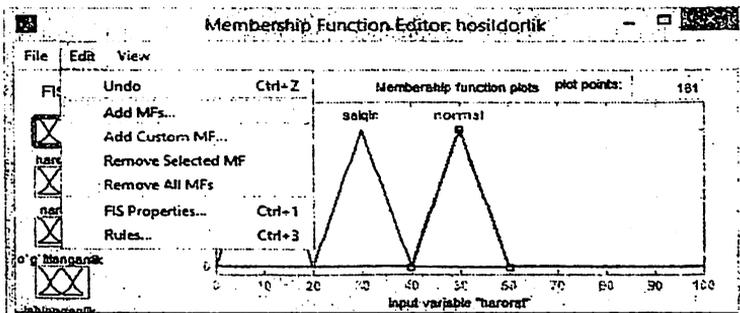


3. В следующем этапе вводятся x_1, x_2, x_3, x_4 принимающие параметры

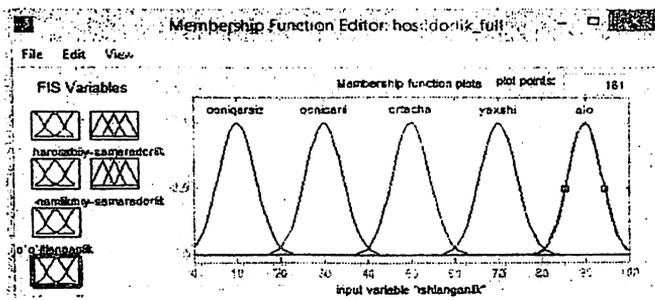
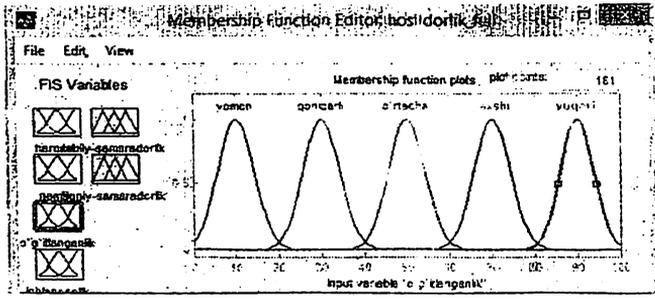
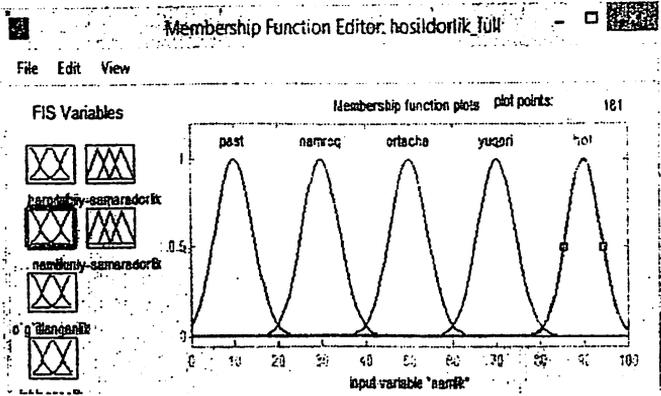


Задается интервал (0 - 100), (gaussmf).

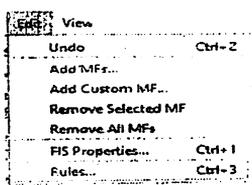
Добавления нового параметра



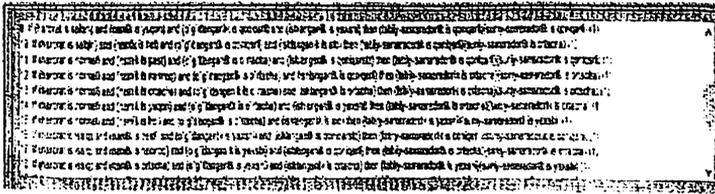
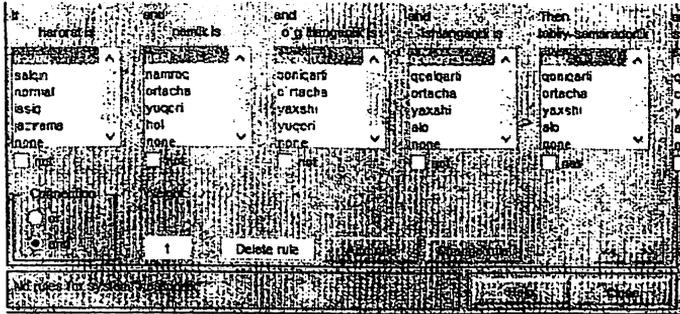
После добавления все параметров



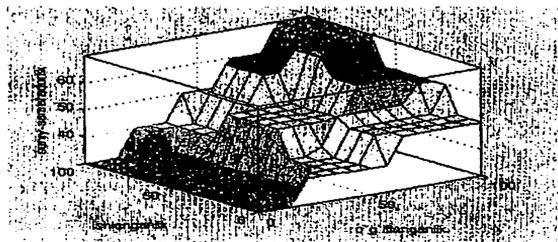
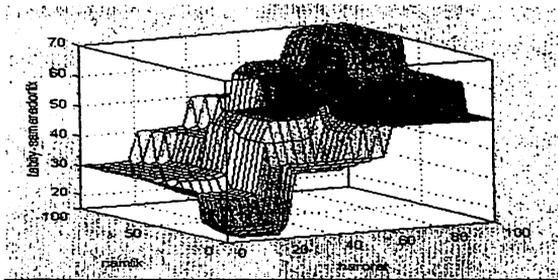
4. После добавления все параметров, создается база знаний

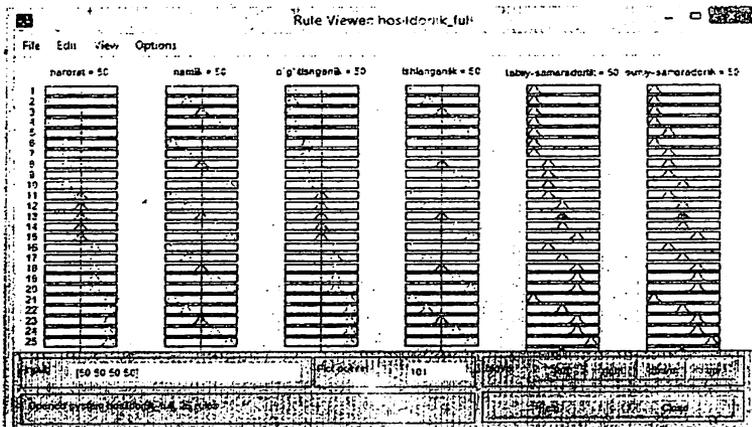


С помощью Add rule создается 25 правил.



Последовательность визуализация база знаний View->Surface.





Порядок выполнения работы

1. Ознакомиться с теоретической частью по приведенным выше материалам;
2. Ознакомиться с возможностью Fuzzy Logic Toolbox
3. Построить нечёткая модель данных с помощью Fuzzy Logic Toolbox в среде Матлаб

Контрольные вопросы

1. Что такое нечёткая множества
2. Что такое функция принадлежности
3. Что такое *term*
4. Возможности Fuzzy Logic Toolbox

Список использованной литературы:

1. Ўзбекистон Республикасини янада ривожлантириш бўйича ҳаракатлар стратегияси тўғрисида. Ўзбекистон республикаси Президентининг ПФ-4947-сон фармони. Тошкент, 2017 йил 7-феврал.
2. Мирзиёев Ш.М. Қонун устуворлиги ва инсон манфаатларини таъминлаш – юрт таракқиёти ва халқ фаровонлигининг гарови. Тошкент. «Ўзбекистон», НМИУ, 2017. – 48 б.
3. R.N. Usmanov, A.N. Mirzayev, K.K. Seitnazarov. Sonli usullar va dasturlash. – Т.: «Fan va texnologiya», 2016, 192 bet.
4. А.А. Барсегян, М.С.Куприянов, В.В. Степаненко, И.И. Холод. Методы и модели анализа данных: OLAP и Data Mining. Москва, 2013
5. Ю.Д. Макленен, Ч. Танг, Б. Криват. Data Mining — интеллектуальный анализ данных. 2013
6. Программирование, численные методы СП.б. БХВ-Питербург 2005.
7. MATLAB асослари. Тўлан Дадажонов, Мухсин Мухитдинов, “Фан” нашриёти – 2008, 640 бет.
8. Лазарев Юрий Федорович, “Начала программирования в среде MatLAB”: Учебное пособие. - К.: НТУУ "КПИ", 2003. - 424 с.

Интернет источники и портал Знёт

1. Matlab.exponenta.ru
2. Math.com
3. gov.uz

ЗАКЛЮЧЕНИЕ

В методическом указании рассмотрены базовые знания по анализам данны на основе математического моделирования в среде Matlab. Приводятся основные характеристики для вычисления и анализа матричных данных. Это позволяет рассматривать функции аппроксимации и интерполяции данных, линейный и нелинейный регрессионный анализ данных, корреляционный анализ. Приводятся понятия кластеризации данных на основе классификации, теория нечетких множеств на основе FLT в среде Matlab.

СОДЕРЖАНИЕ

Введение.....	3
Лабораторная работа №1. Изучение основных характеристик матриц в среде Matlab.....	4
Лабораторная работа №2. Функции аппроксимации и интерполяции данных.....	10
Лабораторная работа №3. Создание линейных регрессионных моделей в среде Matlab.....	16
Лабораторная работа №4. Построение нелинейных регрессионных моделей в среде Matlab.....	22
Лабораторная работа №5. Корреляционный анализ статических данных.....	28
Лабораторная работа №6. Кластеризация на основе классификации.....	32
Лабораторная работа №7. Изучение нечётких множеств на основе пакета FLT в среде Matlab.....	44
Список использованной литературы.....	53
Заключение.....	54

Формат 60x84 1/16. Печ. лист 3,5.

Заказ № 315. Тираж 80.

Отпечатано в «Редакционно издательском»
отделе при ТУИТ.

Ташкент ул. Амир Темур, 108.

Методические указания по выполнению лабораторных работ по курсу «Интеллектуальный анализ данных» для бакалавров обучающихся по направлению 5330500 – «Компьютерный инжиниринг»

Рассмотрены на заседании кафедры «Компьютерные системы»
от «16» 05 2018
Протокол № 22

Рассмотрены на заседании факультета «Компьютерный инжиниринг»
от «22» 05 2018
Протокол № 34

Рассмотрены и рекомендованы к изданию на заседании научно-методического Совета ТУИТ
от «23» 05 2018
Протокол № 10(111)

Составители:

д.т.н., профессор, «Компьютерные системы» ТУИТ Усманов Р.Н.,
ассистент кафедры «Компьютерные системы» ТУИТ Кутлымуратов А.Ж.,
старший преподаватель кафедры «Компьютерные системы» ТУИТ
Хабирова Д.Н.

Рецензенты:

Хушвактов С.Х.,
Назирова Э.Ш.

Ответственный редактор: д.т.н. Джуманов Ж.Х.

Корректор: Шукуров К.Э.