

1. Формулировка исследовательской задачи и подготовка данных**1.1. Выбор переменных**

Задача состоит в объяснении способа построения результирующих признаков по имеющимся данным. В качестве результирующего признака V_s выберем переменную, обозначенную как «индекс человеческого развития» (V 8.35 Human Development Index).











В качестве же детерминантов выберем следующие переменные:

V_1	V 8.01	Население
V_2	V 8.02	Относительный показатель числа иждивенцев
V_3	V 8.05	Средняя продолжительность жизни человека
V_4	V 8.16	Занятость (% населения)
V_5	V 8.17	Среднее количество часов работы в год
V_6	V 8.18	Безработица (% рабочей силы)
V_7	V 8.21	Кол-во школьников (%)
V_8	V 8.22	Кол-во студентов (%)
V_9	V 8.26	Неграмотность (% населения от 15 лет)
V_{10}	V 8.34	Доля собственников (%)

1.2. Параметры стандартизации признаков - детерминант:

ПРИЗНАК	СРЕДНЕЕ	СТАНДАРТНОЕ ОТКЛОНЕНИЕ	МИНИМУМ	МАКСИМУМ
V_1	89.01	223.83	0.27	1231.00
V_2	53.67	8.23	40.40	71.80
V_3	73.26	4.77	60.40	79.50
V_4	42.32	7.31	23.06	56.29
V_5	1.92	0.22	1.33	2.40
V_6	9.16	8.45	1.79	50.00
V_7	80.11	22.54	33.00	121.00
V_8	31.85	17.72	2.00	99.00
V_9	6.58	9.05	0.00	48.00
V_{10}	61.75	13.89	16.60	80.50

Дальше представляются диаграммы плотностей признаков:



2. Построение интегральных показателей

Здесь мы используем Метод Главных Компонент (МГК). Он позволяет определить те признаки в многомерном признаковом пространстве, которые обнаруживают наибольшую изменчивость при переходе от одного объекта к другому.

2.1. Построение интегральных показателей для всей совокупности признаков

Далее представлен протокол вычислительного эксперимента с применением МГК ко всей совокупности признаков - детерминант $\{V_1, \dots, V_{10}\}$ и на всей совокупности объектов:

EXPLAINED VARIANCE:

PC	Variance	%	Cumul.
PC_1	4.17	41.67	41.67
PC_2	1.67	16.74	58.41
PC_3	1.28	12.79	71.21

LOADS:

Variable	PC_1	PC_2	PC_3
V ₁	0.28	0.31	0.48
V ₂	0.35	-0.32	-0.24
V ₃	-0.43	-0.01	-0.01
V ₄	-0.19	0.60	0.10
V ₅	0.22	0.25	-0.50
V ₆	0.24	-0.44	0.48
V ₇	-0.39	-0.22	0.22
V ₈	-0.35	-0.22	0.08
V ₉	0.43	0.12	0.25
V ₁₀	0.10	-0.28	-0.32

CORRELATIONS OF VARIABLES AND PRINCIPAL COMPONENTS:

Variable	PC_1	PC_2	PC_3
V ₁	0.57	0.40	0.54
V ₂	0.72	-0.41	-0.26
V ₃	-0.87	-0.02	-0.02
V ₄	-0.39	0.78	0.10
V ₅	0.46	0.32	-0.58
V ₆	0.49	-0.57	0.54
V ₇	-0.80	-0.29	0.24
V ₈	-0.71	-0.29	0.08
V ₉	0.88	0.16	0.27
V ₁₀	0.21	-0.36	-0.39

Из протокола видно, что наибольшее влияние на первую главную компоненту PC_1 имеют признаки V₃ и V₉, на PC_2 - V₄, на PC_3 - V₁, V₅ и V₆. Заметим также, что общий объясненный разброс равен 71.21%, что является неплохим результатом.

2.2. Построение блочных интегральных показателей

Попытаемся разделить признаки на несколько блоков: $\{V_1, V_2, V_3, V_{10}\}$ - блок, посвященный характеристикам населения; $\{V_4, V_5, V_6\}$ --- рабочей силы; $\{V_7, V_8, V_9\}$ --- образования. Можно вычислить главные компоненты блоков: Population1-3 (общий объясненный разброс составил 92.6%), Labour1-2 (84.65%), Education1-2 (88.57%). Затем построим надблочный интегральный показатель Overbloc_1. Ниже предоставлен протокол:

EXPLAINED VARIANCE:

PC	Variance	%	Cumul.
Overb_1	2.28	32.51	32.51
Overb_2	1.33	18.98	51.48
Overb_3	1.22	17.37	68.85

LOADS:

Variable	Overb_1	Overb_2	Overb_3
Population1	0.61	0.01	0.06
Population2	0.05	0.39	-0.56
Population3	-0.02	0.72	0.17
Labour1	-0.32	0.32	-0.44
Labour2	-0.41	0.04	0.11
Education1	-0.57	-0.07	0.34
Education2	-0.16	-0.47	-0.58

3. Применение метода линейной регрессии для исследования зависимости между результирующим признаком и признаками-детерминантами.

Используем метод линейной регрессии на всем признаковом пространстве. Вот протокол:

REGRESSION QUALITY:

R*2 (Determination coeff.) = 0.93
 R (Correlation) = 0.97
 SEE* (St. Error of Estimate) = 0.027
 MAE (Mean Absolute Error) = 0.016
 MAPE (Mean Abs. Perc. Error) = 1.99 %

LINEAR REGRESSION FORMULA:

$V_s = 0.306 + -1.35E-4 \cdot V_1 + -0.001 \cdot V_2 + 0.011 \cdot V_3 + -0.001 \cdot V_4 + -0.04 \cdot V_5 + -0.001 \cdot V_6 + -3.80E-4 \cdot V_7 + 3.918E-4 \cdot V_8 + -0.002 \cdot V_9 + 0.001 \cdot V_{10}$
 (2.11) (-4.81) (-1.78) (7.06) (-1.69) -1.67 (-1.46)
 (-1.17) (1.19) (-2.42) (1.74)

COEFFICIENTS OF LINEAR REGRESSION:

Variable	Coeff.	StErr	t-Stat	Var.Mean	Var.StDev
V_s				0.86	0.10
INTERCEPT	0.306	0.145	2.11		
V_1	0.000	0.000	-4.81	89.01	223.83
V_2	-0.001	0.001	-1.78	53.67	8.23
V_3	0.011	0.002	7.06	73.26	4.77
V_4	-0.001	0.001	-1.69	42.21	7.18
V_5	-0.040	0.024	-1.67	1.93	0.21
V_6	-0.001	0.001	-1.46	9.16	8.45
V_7	0.000	0.000	-1.17	80.43	22.34
V_8	0.000	0.000	1.19	31.80	17.70
V_9	-0.002	0.001	-2.42	6.58	9.05
V_{10}	0.001	0.000	1.74	61.87	13.61

Degrees of freedom for t-Statistic = 35

Это лучший результат (если брать в качестве критерия функционал качества R^2) который можно получить, используя всего лишь 10 признаков. Если посмотреть на t-статистику, то можно заметить, что результирующий признак V_s наименее чувствителен к V_7 и V_8 , наиболее чувствителен к V_1 и V_3 . Кстати, в следующем эксперименте мы оставили только эти 2 признака и результат практически не изменился:

REGRESSION QUALITY:

R*2 (Determination coeff.) = 0.90
 R (Correlation) = 0.95
 SEE* (St. Error of Estimate) = 0.032
 MAE (Mean Absolute Error) = 0.024
 MAPE (Mean Abs. Perc. Error) = 2.99 %

LINEAR REGRESSION FORMULA:

$V_s = -0.162 + -2.04E-4 \cdot V_1 + 0.014 \cdot V_3$
 (-1.95) (-8.53) (12.68)

COEFFICIENTS OF LINEAR REGRESSION:

Variable	Coeff.	StErr	t-Stat	Var.Mean	Var.StDev
V_s				0.86	0.10
INTERCEPT	-0.162	0.083	-1.95		
V_1	0.000	0.000	-8.53	89.01	223.83
V_3	0.014	0.001	12.68	73.26	4.77

Degrees of freedom for t-Statistic = 43

Мы также можем исследовать зависимость между результирующим признаком V_s и вычисленными ранее интегральными показателями. Возьмем для начала первые три главные компоненты всего пространства признаков:

REGRESSION QUALITY:

R*2 (Determination coeff.) = 0.89
R (Correlation) = 0.95
SEE* (St. Error of Estimate) = 0.034
MAE (Mean Absolute Error) = 0.022
MAPE (Mean Abs. Perc. Error) = 2.68 %

LINEAR REGRESSION FORMULA:

$$V_s = 0.864 + (-0.045)PC_1 + (-0.015)PC_2 + (-0.023)PC_3$$

(174.19) (-18.22) (-3.80) (-5.26)

COEFFICIENTS OF LINEAR REGRESSION:

Variable	Coeff.	StErr	t-Stat	Var.Mean	Var.StDev
V_s				0.86	0.10
INTERCEPT	0.864	0.005	174.19		
PC_1	-0.045	0.002	-18.22	0.00	2.04
PC_2	-0.015	0.004	-3.80	0.00	1.29
PC_3	-0.023	0.004	-5.26	0.00	1.13

Degrees of freedom for t-Statistic = 42

Видно, что основная нагрузка лежит на первой главной компоненте PC_1. Если мы уберем остальные компоненты, то результат изменится несильно ($R^2 = 0.79$).

Если рассматривать множество блочных интегральных показателей, то неплохой результат получится на подмножестве {Population1-2, Education1}:

REGRESSION QUALITY:

R*2 (Determination coeff.) = 0.90
R (Correlation) = 0.95
SEE* (St. Error of Estimate) = 0.033
MAE (Mean Absolute Error) = 0.024
MAPE (Mean Abs. Perc. Error) = 3.04 %

LINEAR REGRESSION FORMULA:

$$V_s = 0.864 + (-0.053)Population1 + (-0.034)Population2 + 0.013Education1$$

(177.95) (-8.97) (-6.56) (2.35)

COEFFICIENTS OF LINEAR REGRESSION:

Variable	Coeff.	StErr	t-Stat	Var.Mean	Var.StDev
V_s				0.86	0.10
INTERCEPT	0.864	0.005	177.95		
Population1	-0.053	0.006	-8.97	0.00	1.37
Population2	-0.034	0.005	-6.56	0.00	1.05
Education1	0.013	0.006	2.35	0.00	1.49

Degrees of freedom for t-Statistic = 42

И, наконец, протокол исследования зависимости между V_s и надблочными интегральными показателями с помощью метода линейной регрессии:

REGRESSION QUALITY:

R^2 (Determination coeff.) = 0.82
 R (Correlation) = 0.91
 SEE^* (St. Error of Estimate) = 0.044
 MAE (Mean Absolute Error) = 0.031
 $MAPE$ (Mean Abs. Perc. Error) = 3.96 %

LINEAR REGRESSION FORMULA:

$$V_s = 0.864 + -0.058 \cdot \text{Overb_1} + -0.023 \cdot \text{Overb_2} + 0.019 \cdot \text{Overb_3}$$

(134.54)
(-13.41)
(-4.08)
(3.27)

COEFFICIENTS OF LINEAR REGRESSION:

Variable	Coeff.	StErr	t-Stat	Var.Mean	Var.StDev
V_s				0.86	0.10
INTERCEPT	0.864	0.006	134.54		
Overb_1	-0.058	0.004	-13.41	0.00	1.51
Overb_2	-0.023	0.006	-4.08	0.00	1.15
Overb_3	0.019	0.006	3.27	0.00	1.10

Degrees of freedom for t-Statistic = 42

Результат только для первой главной компоненты Overb_1: $R^2 = 0.72$. Нетрудно заметить, что надблочный интегральный показатель коррелируется с результирующим признаком существенно хуже, чем первая главная компонента всего пространства признаков. Видимо, это связано с наличием «посредников» - блочных интегральных показателей.

4. Классификация объектов в пространстве признаков - детерминантов

У нас будут 4 класса, так как уменьшение количества классов приведет к уменьшению доли объясненного разброса почти в 2 раза. Ниже приведен протокол классификации объектов:

Number of classes = 4
 Explained scatter = 50.81 % (5.08 / 10.00)

CLASSES:

Class	Example	Objects	%	Explned	Scatter	%
1	INDIA	1	2.17	75.29	75.29	100.00
2	CHINA	1	2.17	42.37	42.37	100.00
3	COLOMBIA	12	26.09	72.03	148.36	48.55
Swamp	AUSTRALIA	32	69.57	44.07	193.98	22.72
Total		46	100.00	233.75	460.00	50.81

CENTERS OF CLASSES (STANDARDIZED):

Variable	1	2	3	Swamp
V ₁	3.83	5.16	-0.10	-0.24
V ₂	1.49	-0.38	1.20	-0.49
V ₃	-2.73	-1.01	-1.01	0.50
V ₄	-0.09	1.21	-0.67	0.22
V ₅	0.30	1.58	0.81	-0.36
V ₆	4.88	-0.75	0.04	-0.14
V ₇	-1.65	-1.33	-1.24	0.56
V ₈	-1.47	-1.70	-0.72	0.37
V ₉	4.63	2.25	0.56	-0.42
V ₁₀	0.83	-0.61	0.23	-0.09

CONTRIBUTIONS:

Variable	1	2	3	Swamp	Total
V ₁	14.71	26.61	0.11	1.92	43.35
V ₂	2.22	0.14	17.33	7.54	27.23
V ₃	7.43	1.02	12.27	7.87	28.59
V ₄	0.01	1.45	5.38	1.50	8.33
V ₅	0.09	2.48	7.86	4.19	14.62
V ₆	23.86	0.56	0.02	0.67	25.11
V ₇	2.72	1.77	18.39	9.94	32.82
V ₈	2.17	2.90	6.26	4.38	15.71
V ₉	21.39	5.05	3.76	5.77	35.98
V ₁₀	0.68	0.38	0.66	0.28	2.00
Total	75.29	42.37	72.03	44.07	233.75

CENTERS OF CLASSES (REAL):

Variable	1	2	3	Swamp
V ₁	938.00	1231.00	67.71	34.78
V ₂	65.80	50.60	63.45	49.72
V ₃	60.40	68.50	68.49	75.60
V ₄	41.57	50.77	37.46	43.75
V ₅	1.99	2.26	2.10	1.85
V ₆	50.00	2.90	9.49	7.95
V ₇	44.00	51.00	53.08	92.75
V ₈	6.00	2.00	19.17	38.28
V ₉	48.00	26.70	11.59	2.77
V ₁₀	73.00	53.60	65.02	60.60

CLASSIFICATION (LATENT NOMINAL VARIABLE):

Grade	Objects	Distance	Contrib.
1	INDIA	0.00	75.29
2	CHINA	0.00	42.37
3	COLOMBIA	0.71	5.35
	MEXICO	1.26	6.29
	VENEZUELA	1.61	5.22
	TURKEY	1.63	8.14
	MALAYSIA	1.91	7.86
	PHILIPPINES	2.08	6.45
	ARGENTINA	2.26	4.24
	BRAZIL	2.27	5.80
	CHILE	2.33	3.81
	THAILAND	3.30	3.76
	SOUTH AFRICA	3.95	9.25
	INDONESIA	4.35	5.85
Swamp	AUSTRALIA	0.85	1.42
	UN, KINGDOM	0.97	0.77
	AUSTRIA	1.09	2.30
	FRANCE	1.32	1.71
	NEW ZEALAND	1.36	1.28
	LUXEMB	1.37	2.13
	BELGIUM	1.46	1.58
	NETHERLANDS	1.50	2.22
	DENMARK	1.63	2.48
	JAPAN	1.75	2.34
	ITALY	1.79	1.21
	CZECH REP	1.80	0.28
	NORWAY	1.88	2.10
	SWEDEN	1.94	1.52
	GERMANY	1.99	2.17
	PORTUGAL	2.04	-0.36
	GREECE	2.11	1.51
	ISRAEL	2.15	-0.08
	ICELAND	2.19	2.04
	FINLAND	2.20	2.57
	POLAND	2.20	-0.61
	IRELAND	2.25	0.82
	TAIWAN	2.28	0.59
	HUNGARY	2.33	-0.16
	USA	2.56	1.78
	KOREA	2.72	0.86
	SWITZERLAND	2.78	2.32
	SPAIN	2.82	1.36
	HONG KONG	2.83	1.16
	RUSSIA	3.16	0.79
	SINGAPORE	3.20	0.75
	CANADA	3.55	3.19