

3.4. Дискриминантный анализ

Дискриминантный анализ является мощным статистическим средством анализа разделения (дискриминации) многомерных совокупностей наблюдений на группы. Данный анализ был разработан независимо друг от друга известными статистиками Р. Фишером, Г. Хоттелингом и Махаланобисом.

Основной задачей дискриминантного анализа является анализ имеющегося разделения, дискриминации исследуемого множества объектов, характеризующихся набором закоррелированных выходных характеристик, и разделенных на две или большее число групп. В результате такого анализа оцениваются связи между имеющимся делением на группы и вкладами отдельных количественных признаков в это деление.

Линейная дискриминантная функция преобразует множество измерений, входящих в выборку в значение дискриминантной функции (дискриминантную метку). Последним определяется граница разделения совокупностей.

Для нахождения линейной дискриминантной функции строится уравнение регрессии, в котором в качестве зависимых переменных выступают разности между многомерными средними двух анализируемых групп $H_j = U_j - V_j$. С этой целью решается матричное уравнение вида $[C][a] = [H]$ (где $[C]$ – ковариационная матрица объединенной выборки размерности $m \times m$; $[a]$ – вектор – столбец коэффициентов дискриминантной функции; $[H]$ – вектор – столбец разностей между средними значениями признаков групп). Уравнение решается с помощью операции обращения и умножения матриц $[a] = [C]^{-1} [H]$, после чего по вычисленным коэффициентам $a_1, a_2, \dots, a_p, \dots, a_k$ строится дискриминантная функция

$$DX_1, X_2, \dots, X_p, \dots, X_k = \sum_{p=1}^k a_p X_p.$$

Дискриминантный индекс D_0 , определяющий принадлежность испытуемого объекта к той или иной группе, рассчитывается по формуле

$$D_0 = 1/2 \sum_{p=1}^k a_p (u_p + v_p).$$

Он соответствует середине «обобщенного расстояния» между центрами обеих групп в многомерном пространстве изучаемых признаков.

После расчета порогового значения (дискриминантного индекса) D_0 оцениваются значения центров обеих исходных групп D_u и D_v , путем подстановки начальных значений u_j , а затем v_j в уравнение дискриминантной функции. «Обобщенное расстояние» между двумя

многомерными средними D^2 называют расстоянием (или критерием) Махаланобиса. Оно вычисляется путем вычитания D_u из D_v , что эквивалентно подстановке вектора разности между средними двух групп u_j и v_j в дискриминантную функцию

$$D^2 = \sum_{i=1}^p a_i (u_i - v_i).$$

Чем больше D^2 , тем более уверенное разделение можно провести между объектами (А.Б.Кождан, О.И.Гуськов, 1990). Критерий Хотеллинга T^2 для проверки значимости дискриминантной функции выражается через это расстояние. Если $T^2_{\text{расч}} > T^2_{\text{табл}}$ и $p < \alpha$, то нулевая гипотеза о равенстве двух многомерных средних или о равенстве расстояния между ними нулю отвергается. В дискриминантном анализе, получив оценку дискриминантной функции и подставляя в нее значения X_1, X_2, \dots, X_p , можем заново, более точно произвести переклассификацию наблюдений, относя их в зависимости от значения функции к той или другой группе. В этом и заключается основное отличие от дисперсионного анализа – в возможности апостериорной переклассификации наблюдений.