

Э.Х. Симпсон**
ИЗМЕРЕНИЕ РАЗНООБРАЗИЯ*

«Характеристика», определенная Юлом¹ и «индекс разнообразия», определенный Фишером², – две меры степени концентрации или достигнутого разнообразия, когда особи популяции разбиты на группы. Оба [эти показателя] определены как статистики, которые вычисляются на основе выборочных данных, а не в терминах популяционных констант. Прежний индекс разнообразия основан на логарифмическом распределении. Это не общее допущение, поскольку не всегда дает значения, которые независимы от объема выборки; такой индекс нельзя использовать, например, применительно к бесконечному числу особей популяции, разбитых на конечное число групп. Уильямс³ указал на зависимость между «характеристикой» и «индексом разнообразия», когда оба используют логарифмическое распределение. Цель настоящего сообщения состоит в том, чтобы определить и исследовать меру концентрации в терминах популяционных констант.

Пусть бесконечная популяция такова, что каждая особь принадлежит одной из Z групп, и пусть $\pi_1 \dots \pi_Z$ ($\sum \pi = 1$) – доли особей в различных группах. Тогда λ , определяемая как $\sum \pi^2$, – мера концентрации классификации. Эта величина $[\lambda]$ может принимать любое значение между $1/Z$ и 1 , старое представление наименьшей концентрации или наибольшего разнообразия, возможного с Z группами, и последней полной концентрацией, когда все особи, находятся в одной группе. Показатель λ может быть просто интерпретирован как вероятность того, что две особи, выбранные случайно и независимо из популяции, будут принадлежать одной и той же группе.

Теперь предположим, что имеем выборку из N особей, случайно отобранных из популяции и n_1, n_2, \dots, n_Z ($\sum n = N$) – это число особей в разных группах. Легко показать, что $L = (\sum n(n-1)) / (N(N-1))$ – несмещенная оценка λ ; это почти очевидно, если принять во внимание, что $0,5N(N-1)$ – число пар в выборке и $0,5n(n-1)$ – число пар, с учетом разбиения на группы.

L – также является несмещенной оценкой λ для переменного объема выборки, если отсутствуют выборки объема 0 или 1 и вероятность получения выборки (n_1, n_2, \dots, n_Z) раскладывается в эти два фактора:

** Симпсон Эдуард (Edward Hugh Simpson; г.р. 1927) – математик, статистик; член Британского королевского статистического общества.

* Simpson E.H. Measurement of diversity // Nature. – 1949. – V. 163, № 688. – P. 688. (перевод Г.С. Розенберга).

$$P(n_1, n_2, \dots, n_Z) = P(N) \frac{N!}{n_1! n_2! \dots} (\pi_1)^{n_1} (\pi_2)^{n_2} \dots,$$

где $P(N)$ задает распределение вероятности объема выборки, $2 \leq N \leq \infty$. Это тем более верно, когда выборки получены методом «постоянных (стационарных) воздействий» (fixed-exposure), традиционным в биологических исследованиях; N тогда имеет распределение Пуассона, пригодное для описания выборок с отсутствием первых двух [выборок объема 0 и 1].

Если повторная выборка объема N получена из той же самой популяции, вычисленное значение L будет распределено как λ с дисперсией

$$\frac{4N(N-1)(N-2)\sum \pi^3 + 2N(N-1)\sum \pi^2 - 2N(N-1)(2N-3)(\sum \pi^2)^2}{[N(N-1)]^2};$$

или, если N очень велико, приблизительно

$$\frac{4}{N} [\sum \pi^3 - (\sum \pi^2)^2].$$

Третьи и четвертые кумулянты [накопленные частоты. – Г.Р.] распределения L также были точно определены. Они показывают, что при росте N распределение стремится к нормальному, кроме того случая, когда $\lambda = 1/Z$; в этом случае распределение LNZ стремится к χ^2 -распределению с $(Z-1)$ степенью свободы, но со средней смещенной от $Z-1$ к N .

«Характеристика», определенная Юлом¹, – $1000 (\sum n(n-1)) / N^2$, что отличается от L , оценивающей λ , только наличием N вместо $N-1$ в знаменателе и коэффициентом масштаба 1000.

Теперь, позвольте показать, что значение λ , взятое для популяции, состоящей из Z групп, частоты которых $\pi_i = w_i / \sum w$, где w_i выбраны случайно и независимо, соответствует распределению III-го типа:

$$dF = \frac{1}{(k-1)!} e^{-w} w^{k-1} dw, \quad 0 \leq w \leq \infty.$$

Это можно назвать «отрицательной биномиальной популяцией», так как выборки, полученные методом «постоянных (стационарных) воздействий», будут подчиняться отрицательному биномиальному распределению. Можно вычислить соответствующее этому значение λ , со средним значением $\sum w_i^2 / (\sum w_i)^2$ по всем наборам (w_1, w_2, \dots, w_Z) , которое может быть получено по популяционным значениям w . Таким образом,

$$\lambda = \int_0^{\infty} \dots \int_0^{\infty} \left[\frac{1}{(k-1)!} \right] e^{-\sum w} [w_1 \dots w_z]^{k-1} dw_1 \dots dw_z = \frac{k+1}{Zk+1} .$$

Распределение Пуассона – специальный случай отрицательного биномиального распределения, в котором k стремится к бесконечности. При этом условии, $\lambda = 1/Z$. Это именно то, что мы и ожидали, так как распределение Пуассона соответствует популяции, в которой все группы представлены одинаково, и, таким образом, вероятность, что две случайно выбранные особи будут принадлежать одной группе, должна быть $1/Z$.

Другой особый случай отрицательного биномиального распределения – «логарифмическая популяция», которая получается, если одновременно Z стремится к бесконечности, а k – к нулю так, что произведение Zk остается конечным и стремится к величине α . (Это – не совсем то же самое предположение, которое использует Фишер², но количественно α и есть его «индекс разнообразия»). Полученное значение для λ , снизу ограничено $1/(\alpha+1)$.

Заметим, что это последнее значение не совместимо с уравнением, приводимым Уильямсом³, а именно, «характеристика» Юла¹ имеет вид $1000/\alpha$, для логарифмического распределения. Этот результат был получен с использованием формулы Юла к рядам вероятных значений, тогда как предлагаемая процедура эквивалентна применению формулы сначала и затем усреднения результата. Некоторая поддержка новому уравнению найдена при рассмотрении рангов связанных переменных. Так как «характеристика» не может превысить 1000, более раннее уравнение [$1000/\alpha$. – Г.Р.] отрицало бы все значения α меньше чем 1; но предлагаемое уравнение задает диапазон $0 \leq \alpha \leq \infty$, в то время как $1 \geq \lambda \geq 0$.

3 West End Avenue,
Pinner (пригород в северо-западном Лондоне. – Г.Р.).
Jan. 29.

¹ Yule, "Statistical Study of Literary Vocabulary" (Cambridge, 1944).

² Fisher, Corbet and Williams, *J. Animal Ecol.*, **12**, 42 (1948).

³ Williams, *Nature*, **157**, 482 (1946).