

Πιθανογεννήτριες - Πολυωνυμική και Υπεργεωμετρική Κατανομή

Μ. Ζαζάνης

Πιθανότητες II

23 Μαρτίου 2020

Ορισμός Πιθανογεννήτριας

Έστω X μια διακριτή τυχαία μεταβλητή με κατανομή $\mathbb{P}(X = k) = p_k$, $k = 0, 1, 2, \dots$. Η πιθανογεννήτρια της X είναι η συνάρτηση

$$G(z) := \sum_{k=0}^{\infty} p_k z^k \quad (1)$$

Η μεταβλητή z παίρνει πραγματικές τιμές (στις εφαρμογές που θα συζητήσουμε) και κυμαίνεται στο διάστημα στο οποίο η σειρά (1) συγκλίνει. Παρατηρείστε ότι η (1) σημαίνει ότι $G(z) := \mathbb{E}[z^X]$.

Προσδιορισμός Κατανομής από την Πιθανογεννήτρια

Συμβολίζουμε με $G^{(k)}(z)$ την παράγωγο τάξης k υπολογισμένη στην τιμή z .
Τότε

$$p_k = \frac{1}{k!} G^{(k)}(0), \quad k = 0, 1, 2, \dots, \quad (2)$$

Η $G(z)$ προσδιορίζει με μοναδικά την κατανομή $\{p_k\}$ μέσω της (2).

Αν οι X, Y , είναι ανεξάρτητες τυχαίες μεταβλητές με πιθανογεννήτριες $G_X(z), G_Y(z)$ αντίστοιχα, η πιθανογεννήτρια του αθροίσματος $Z = X + Y$ είναι

$$G_Z(z) = G_X(z)G_Y(z).$$

Πράγματι,

$$G_Z(z) = \mathbb{E}[z^{X+Y}] = \mathbb{E}[z^X z^Y] = \mathbb{E}z^X \mathbb{E}z^Y,$$

λόγω της ανεξαρτησίας των X, Y . Επαγωγικά, για οποιοδήποτε πεπερασμένο πλήθος ανεξάρτητων τ.μ. $X_i, i = 1, 2, \dots, n$ με (κοινή) πιθανογεννήτρια $G_X(z)$, το άθροισμά $S_n := X_1 + \dots + X_n$ έχει πιθανογεννήτρια $G_{S_n}(z) = (G_X(z))^n$.

Η κατανομή Bernoulli

Η τυχαία μεταβλητή

$$X = \begin{cases} 0 & \text{με πιθανότητα } q \\ 1 & \text{με πιθανότητα } p \end{cases}$$

όπου $p \in [0, 1]$ και $q = 1 - p$ ονομάζεται Bernoulli. Η κατανομή Bernoulli είναι η πλέον στοιχειώδης και αποτελεί δομικό λίθο για πιο περίπλοκες κατανομές. Η πιθανογεννήτρια της κατανομής αυτής είναι

$$G(z) = z^0 \cdot \mathbb{P}(X = 0) + z^1 \cdot \mathbb{P}(X = 1) + z^2 \cdot \mathbb{P}(X = 2) + \dots = q + pz.$$

Η μέση τιμή της X είναι $\mathbb{E}[X] = G'(1) = p$. Η δεύτερη παραγοντική ροπή είναι $\mathbb{E}[X(X-1)] = G''(1) = 0$. Συνεπώς $\mathbb{E}[X^2 - X] = 0$ και $\mathbb{E}[X^2] = \mathbb{E}[X]$, δηλαδή $\mathbb{E}[X^2] = p$. Συνεπώς $\text{Var}(X) = \mathbb{E}[X^2] - (\mathbb{E}[X])^2 = p - p^2 = p(1 - p) = pq$.

Η Διωνυμική κατανομή

Μια τυχαία μεταβλητή X με κατανομή

$$\mathbb{P}(X = k) = \binom{n}{k} p^k q^{n-k}, \quad \text{αν } k = 0, 1, 2, \dots, n \text{ και } 0 \text{ διαφορετικά}$$

Πιθανότητα να έχουμε k επιτυχίες σε n ανεξάρτητες δοκιμές.

Πιθανογεννήτρια:

$$G(z) = \sum_{k=0}^n \binom{n}{k} p^k q^{n-k} z^k = (q + pz)^n.$$

Ο μέσος και η διασπορά μπορούν να υπολογισθούν από την πιθανογεννήτρια ως εξής: $G'(z) = np(q + pz)^{n-1}$ και $G''(z) = n(n-1)p^2(q + pz)^{n-2}$

(υποθέτουμε ότι $n \geq 2$). $\mathbb{E}[X] = G'(1) = np$ (χρησιμοποιήσαμε το γεγονός ότι $p + q = 1$). $\mathbb{E}[X(X-1)] = n(n-1)p^2$. Συνεπώς

$\mathbb{E}[X^2] = n(n-1)p^2 + \mathbb{E}[X] = n(n-1)p^2 + np$ και κατά συνέπεια

$$\begin{aligned} \text{Var}(X) &= \mathbb{E}[X^2] - (\mathbb{E}[X])^2 = n(n-1)p^2 + np - n^2p^2 = np - np^2 \\ &= np(1-p) = npq. \end{aligned}$$

Η κατανομή Poisson

Η τυχαία μεταβλητή X έχει κατανομή Poisson με παράμετρο $\alpha > 0$ αν

$$\mathbb{P}(X = k) = \frac{1}{k!} \alpha^k e^{-\alpha}, \quad k = 0, 1, 2, \dots$$

Η πιθανογεννήτρια της δίδεται από την

$$G(z) = \sum_{k=0}^{\infty} z^k \frac{1}{k!} \alpha^k e^{-\alpha} = e^{-\alpha} \sum_{k=0}^{\infty} \frac{1}{k!} (\alpha z)^k = e^{-\alpha} e^{z\alpha} = e^{-\alpha(1-z)}.$$

Η μέση τιμή και η διασπορά της κατανομής Poisson υπολογίζεται εύκολα ως $EX = \text{Var}(X) = \alpha$.

Μια από τις σημαντικότερες ιδιότητες της κατανομής Poisson είναι ότι προκύπτει ως το όριο της διωνυμικής κατανομής $\text{Binom}(n, \alpha/n)$ όταν $n \rightarrow \infty$ (δηλαδή στην περίπτωση που έχουμε ένα μεγάλο αριθμό ανεξάρτητων δοκιμών, n , η κάθε μια από τις οποίες έχει μικρή πιθανότητα επιτυχίας, α/n). Αυτό είναι εύκολο να διαπιστωθεί εξετάζοντας την πιθανογεννήτρια της διωνυμικής κατανομής $(n, \alpha/n)$ και παίρνοντας το όριο $n \rightarrow \infty$. Πράγματι,

$$\lim_{n \rightarrow \infty} \left(1 - \frac{\alpha}{n} + z \frac{\alpha}{n}\right)^n = \lim_{n \rightarrow \infty} \left(1 - \frac{\alpha(1-z)}{n}\right)^n = e^{-\alpha(1-z)}$$

το οποίο δείχνει ότι $\text{Binom}(\alpha/n, n) \rightarrow \text{Poi}(\alpha)$ όταν $n \rightarrow \infty$.

Ισχύει επίσης ότι, αν X_1, X_2 είναι ανεξάρτητες τυχαίες μεταβλητές Poisson με παραμέτρους α_1, α_2 αντίστοιχα, τότε $X_1 + X_2 \sim \text{Poi}(\alpha_1 + \alpha_2)$. Ο απλούστερος τρόπος να το διαπιστώσουμε είναι να εξετάσουμε την πιθανογεννήτρια $Ez^{X_1+X_2} = Ez^{X_1} Ez^{X_2} = e^{-\alpha_1(1-z)} e^{-\alpha_2(1-z)} = e^{-(\alpha_1+\alpha_2)(1-z)}$.

Η Γεωμετρική Κατανομή

Η τυχαία μεταβλητή X είναι γεωμετρική με παράμετρο p όταν η κατανομή της δίδεται από την

$$\mathbb{P}(X = k) = q^{k-1}p, \quad k = 1, 2, 3, \dots, \quad (3)$$

όπου $p \in (0, 1)$ και $q = 1 - p$. Η πιθανογεννήτρια συνάρτηση της κατανομής αυτής δίδεται από την σχέση

$$G(z) = \sum_{k=1}^{\infty} q^{k-1}pz^k = \frac{(1-q)z}{1-qz}. \quad (4)$$

Η παράμετρος p ονομάζεται συνήθως 'πιθανότητα επιτυχίας' και η τιμή της X είναι ο αριθμός των ανεξάρτητων δοκιμών που απαιτούνται μέχρι την πρώτη επιτυχία αν κάθε δοκιμή έχει πιθανότητα επιτυχίας p . Εναλλακτικά, μπορούμε να εξετάσουμε τον αριθμό των αποτυχιών, Y , μέχρι την πρώτη επιτυχία. Στην περίπτωση αυτή $Y = X - 1$ και

$$\mathbb{P}(Y = k) = q^k p, \quad k = 0, 1, 2, \dots, \quad (5)$$

με πιθανογεννήτρια

$$\mathbb{E}_z Y = \frac{1 - q}{1 - qz}. \quad (6)$$

Μπορούμε να δούμε εύκολα ότι $\mathbb{E}Y = q/p$ και $\text{Var}(Y) = q/p^2$. Επίσης, $\mathbb{E}X = 1 + \mathbb{E}Y = 1/p$ και $\text{Var}(X) = \text{Var}(Y) = q/p^2$.

Η Αρνητική Διωνυμική Κατανομή (Κατανομή Pascal)

Ξεκινάμε με τον ορισμό του διωνυμικού συντελεστή στην περίπτωση που $a \in \mathbb{R}$ και $n \in \mathbb{N}$ ως

$$\binom{a}{n} := \frac{a(a-1)\dots(a-n+1)}{n!}.$$

Αν ο a είναι φυσικός αριθμός τότε $\binom{a}{n} = 0$ για κάθε $n > a$. Αν ο a είναι αρνητικός ακέραιος ή μη ακέραιος πραγματικός αριθμός, τότε $\binom{a}{n} \neq 0$ για κάθε $n \in \mathbb{N}$. Σύμφωνα με το διωνυμικό θεώρημα, για κάθε $|x| < 1$ και $\alpha \in \mathbb{R}$:

$$(1+x)^\alpha = \sum_{k=0}^{\infty} \binom{\alpha}{k} x^k. \quad (7)$$

(Αν ο α είναι θετικός ακέραιος τότε $\binom{\alpha}{k} = 0$ για κάθε $k = \alpha + 1, \alpha + 2, \dots$ και συνεπώς η άπειρη σειρά (7) γίνεται ένα άθροισμα με πεπερασμένο πλήθος όρων: $(1+x)^\alpha = \sum_{k=0}^{\alpha} \binom{\alpha}{k} x^k$.)

Ο διωνυμικός συντελεστής $\binom{-\alpha}{n}$ γράφεται ως

$$\begin{aligned}\binom{-\alpha}{n} &= \frac{(-\alpha)(-\alpha-1)\cdots(-\alpha-n+2)(-\alpha-n+1)}{n!} \\ &= (-1)^n \frac{(\alpha+n-1)(\alpha+n-2)\cdots(\alpha+1)\alpha}{n!} \\ &= (-1)^n \binom{\alpha+n-1}{n}.\end{aligned}$$

Συνεπώς, για κάθε $|x| < 1$ ισχύει η ταυτότητα

$$(1-x)^{-\alpha} = \sum_{k=0}^{\infty} \binom{-\alpha}{k} (-x)^k = \sum_{k=0}^{\infty} \binom{\alpha+k-1}{k} x^k. \quad (8)$$

Αν $p \in (0, 1)$ και $q = 1 - p$ τότε η αρνητική διωνυμική κατανομή με παραμέτρους p και $\alpha > 0$ ορίζεται ως

$$\mathbb{P}(X = k) = \binom{\alpha + k - 1}{k} p^\alpha q^k, \quad k = 0, 1, 2, \dots \quad (9)$$

Η παραπάνω έκφραση ορίζει πράγματι μια κατανομή πιθανότητας στους μη αρνητικούς ακεραίους δεδομένου ότι $\binom{\alpha + k - 1}{k} > 0$ όταν $\alpha > 0$ για κάθε $k \in \mathbb{N}$ και $\sum_{k=0}^{\infty} \binom{\alpha + k - 1}{k} p^\alpha q^k = p^\alpha (1 - q)^{-\alpha} = 1$, λόγω της σχέσης (8).

Η πιθανογεννήτρια της αρνητικής διωνυμικής κατανομής δίδεται από την

$$G(z) = \sum_{k=0}^{\infty} \binom{\alpha + k - 1}{k} p^{\alpha} q^k z^k = \left(\frac{p}{1 - qz} \right)^{\alpha}.$$

Η μέση τιμή της αρνητικής διωνυμικής τυχαίας μεταβλητής X είναι

$$\mathbb{E}X = G'(1) = \alpha q \frac{p^{\alpha}}{(1-q)^{\alpha+1}} \quad \text{ή}$$

$$\mathbb{E}X = \alpha \frac{q}{p}.$$

Ομοίως, $\mathbb{E}X(X-1) = G''(1) = \alpha(\alpha+1)q^2 \frac{p^{\alpha}}{(1-q)^{\alpha+2}} = \alpha(\alpha+1) \left(\frac{q}{p} \right)^2$. Επομένως

έχουμε $\mathbb{E}X^2 = \alpha(\alpha+1) \left(\frac{q}{p} \right)^2 + \alpha \frac{q}{p}$ ανδ της

$$\text{Var}(X) = \alpha(\alpha+1) \left(\frac{q}{p} \right)^2 + \alpha \frac{q}{p} - \left(\alpha \frac{q}{p} \right)^2 = \alpha \frac{q}{p} \left(1 + \frac{q}{p} \right) \quad \text{ή}$$

$$\text{Var}(X) = \alpha \frac{q}{p^2}.$$

Όταν $\alpha = m \in \mathbb{N}$ η αρνητική διωνυμική κατανομή είναι η κατανομή του αθροίσματος m ανεξάρτητων τυχαίων μεταβλητών γεωμετρικά κατανεμημένων (του τύπου (5)), η κάθε μια με πιθανότητα επιτυχίας p . Αυτό αποδεικνύεται εύκολα με την βοήθεια των πιθανογεννητριών. Επίσης

$$\mathbb{E}[X(X-1)\cdots(X-k+1)] = G^{(k)}(1). \quad (10)$$

Η έκφραση (10) ονομάζεται κατιούσα παραγοντική ροπή τάξης k . Οι συνήθεις ροπές μπορούν να υπολογιστούν από αυτές.

Πολυωνυμική Κατανομή

Έστω ένα πείραμα που μπορεί να έχει m διαφορετικά αποτελέσματα, a_1, a_2, \dots, a_m . Η πιθανότητα του a_i είναι p_i και $\sum_{i=1}^m p_i = 1$. Π.χ. η ρίψη ενός τίμιου ζαριού όπου υπάρχουν έξι διαφορετικά ισοπίθανα αποτελέσματα.

Εκτελούμε το πείραμα n φορές, ανεξάρτητα. Έστω X_1 ο αριθμός των πειραμάτων με αποτέλεσμα a_1 , X_2 ο αριθμός των πειραμάτων με αποτέλεσμα a_2 και X_m ο αριθμός των πειραμάτων με αποτέλεσμα ήταν a_m .

Τα X_1, X_2, \dots, X_m είναι τυχαίες μεταβλητές οι οποίες δεν είναι ανεξάρτητες μεταξύ τους. Ισχύει ότι $X_1 + X_2 + \dots + X_m = n$.

Η από κοινού κατανομή των τυχαίων αυτών μεταβλητών ονομάζεται πολυωνυμική. Αν n_1, n_2, \dots, n_m είναι μη αρνητικοί ακέραιοι, τέτοιοι ώστε $\sum_{i=1}^m n_i = n$, τότε

$$P(X_1 = n_1, X_2 = n_2, \dots, X_m = n_m) = \binom{n}{n_1, n_2, \dots, n_m} p_1^{n_1} p_2^{n_2} \cdots p_m^{n_m}.$$

Παράδειγμα

Έστω ένα πείραμα που έχει τρία δυνατά αποτελέσματα, τα a_1 , a_2 , και a_3 τα οποία συμβαίνουν με πιθανότητες p_1 , p_2 και p_3 , όπου $p_1 + p_2 + p_3 = 1$. Το εκτελούμε 10 φορές ανεξάρτητα. X_i , $i = 1, 2, 3$, είναι ο αριθμός των πειραμάτων των οποίων το αποτέλεσμα ήταν a_i . Ας υπολογίσουμε την πιθανότητα $P(X_1 = 3, X_2 = 5, X_3 = 2)$. Η πιθανότητα να έχουμε τα αποτελέσματα $a_1 a_1 a_1 a_2 a_2 a_2 a_2 a_2 a_3 a_3$ είναι $p_1^3 p_2^5 p_3^2$ λόγω της ανεξαρτησίας των πειραμάτων. Η πιθανότητα μιας οποιασδήποτε άλλης πραγματοποίησης με 3 a_1 , 5 a_2 και 2 a_3 είναι η ίδια. Πρέπει όμως να δούμε πόσες διαφορετικές πραγματοποιήσεις υπάρχουν με τον συγκεκριμένο αριθμό των τριών αποτελεσμάτων, με πόσους διαφορετικούς τρόπους δηλαδή μπορούμε να βάλουμε στη σειρά 3 a_1 , 5 a_2 και 2 a_3 . Αυτός είναι ο αριθμός των επαναληπτικών μεταθέσεων που είναι $\binom{10}{3,5,2} = 2520$. Συνεπώς

$$P(X_1 = 3, X_2 = 5, X_3 = 2) = \binom{10}{3,5,2} p_1^3 p_2^5 p_3^2.$$

Παράδειγμα 2: Ρίψεις Ζαριού

Η πιθανότητα σε 6 ρίψεις ενός τιμίου ζαριού να έχουμε 2 δυάρια, 2 τεσσάρια και 2 εξάρια είναι

$$\begin{aligned} \binom{6}{0, 2, 0, 2, 0, 2} \left(\frac{1}{6}\right)^0 \left(\frac{1}{6}\right)^2 \left(\frac{1}{6}\right)^0 \left(\frac{1}{6}\right)^2 \left(\frac{1}{6}\right)^0 \left(\frac{1}{6}\right)^2 &= \frac{6!}{2!0!2!0!2!0!} \frac{1}{6^6} \\ &= 0,0019. \end{aligned}$$

Η από κοινού κατανομή του αριθμού των διαφορετικών αποτελεσμάτων, (X_1, X_2, \dots, X_m) ονομάζεται **πολυωνυμική κατανομή**. Το άθροισμα των πολυωνυμικών πιθανοτήτων για όλα τα n_1, n_2, \dots, n_m τέτοια ώστε $\sum_{i=1}^m n_i = n$ είναι μονάδα λόγω του πολυωνυμικού θεωρήματος:

$$\begin{aligned} \sum_{\{(n_1, \dots, n_m) : \sum_{i=1}^m n_i = n\}} \binom{n}{n_1, n_2, \dots, n_m} p_1^{n_1} p_2^{n_2} \cdots p_m^{n_m} &= (p_1 + \cdots + p_m)^n \\ &= 1^n = 1. \end{aligned}$$

Η περιθώρια κατανομή της X_i μπορεί να υπολογισθεί αθροίζοντας τις πολυωνυμικές πιθανότητες.

Ας δούμε ξανά το πείραμα που έχει τρία διαφορετικά αποτελέσματα, $a_1, a_2,$ και a_3 τα οποία συμβαίνουν με πιθανότητες p_1, p_2 και p_3 αντίστοιχα, όπου $p_1 + p_2 + p_3 = 1$, και το οποίο επαναλαμβάνουμε ανεξάρτητα n φορές. Έστω X_1, X_2, X_3 , ο αριθμός των αποτελεσμάτων τύπου $a_1, a_2,$ και a_3 στις n επαναλήψεις. Η από κοινού κατανομή των (X_1, X_2, X_3) θα είναι, για $m = 3$,

$$P(X_1 = i, X_2 = j, X_3 = k) = \binom{n}{i, j, k} p_1^i p_2^j p_3^k. \quad (11)$$

Για να βρούμε την περιθώρια κατανομή του X_1 αρκεί να αθροίσουμε ως εξής:

$$P(X_1 = i) = \sum_{\{(j,k): j+k=n-i, j,k \in \mathbb{N}_0\}} \binom{n}{i, j, k} p_1^i p_2^j p_3^k \quad i = 0, 1, 2, \dots, n.$$

Λαμβάνοντας υπ' όψιν ότι $i + j + k = n$ και

$$\binom{n}{i, j, k} = \frac{n!}{(n-i)! i! (n-i-j)! j!} = \binom{n}{i} \binom{n-i}{j}$$

Η παραπάνω έκφραση γράφεται ισοδύναμα ως

$$\begin{aligned} P(X_1 = i) &= \sum_{j=0}^{n-i} \binom{n}{i} \binom{n-i}{j} p_1^i p_2^j p_3^{n-i-j} = \binom{n}{i} p_1^i \sum_{j=0}^{n-i} \binom{n-i}{j} p_2^j p_3^{n-i-j} \\ &= \binom{n}{i} p_1^i (p_2 + p_3)^{n-i} = \binom{n}{i} p_1^i (1 - p_1)^{n-i} \end{aligned} \quad (12)$$

όπου, στην προτελευταία ισότητα χρησιμοποιήσαμε το διωνυμικό θεώρημα και στην τελευταία το γεγονός ότι $p_2 + p_3 = 1 - p_1$. Από την (12) είναι σαφές ότι η X_1 έχει Διωνυμική κατανομή με πιθανότητα επιτυχίας p_1 και αριθμό δοκιμών n . Αυτό μπορεί να το καταλάβει κανείς άμεσα θεωρώντας ότι το πείραμα δεν έχει τρία αποτελέσματα αλλά μόνο δύο: το αποτέλεσμα a_1 που συμβαίνει με πιθανότητα p_1 και το αποτέλεσμα «όχι a_1 » (δηλαδή a_2 ή a_3) που συμβαίνει με πιθανότητα $p_2 + p_3 = 1 - p_1$.

Με τον ίδιο ακριβώς τρόπο μπορούμε να αποδείξουμε γενικά (και οι δείκτες δεν πρέπει να μας αποθαρρύνουν) ότι η περιθώριος κατανομή του X_i για την γενική πολυωνυμική κατανομή είναι διωνυμική:

$$P(X_i = n_i) = \binom{n}{n_i} p_i^{n_i} (1 - p_i)^{n - n_i}, \quad n_i = 0, 1, \dots, n. \quad (13)$$

Από τις ιδιότητες της διωνυμικής κατανομής συμπεραίνουμε ότι $EX_i = np_i$ και $\text{Var}(X_i) = np_i(1 - p_i)$.

Στη συνέχεια μπορούμε να υπολογίσουμε την από κοινού κατανομή των (X_1, X_2) για την πολυωνυμική κατανομή (11) με τρία διαφορετικά αποτελέσματα. Αν i, j είναι δύο μη αρνητικοί ακέραιοι τέτοιοι ώστε $i + j \leq n$ τότε, λαμβάνοντας υπ' όψιν ότι $i + j + k = n$ έχουμε

$$\begin{aligned} P(X_1 = i, X_2 = j) &= \binom{n}{i, j, k} p_1^i p_2^j p_3^k \\ &= \binom{n}{i, j, n - i - j} p_1^i p_2^j (1 - p_1 - p_2)^{n - i - j}, \quad i + j \leq n. \end{aligned}$$

Προκειμένου να υπολογίσουμε την συνδιακύμανση των X_1, X_2 , υπολογίζουμε πρώτα την μέση τιμή του γινομένου

$$E[X_1 X_2] = \sum_{\{(i,j): i+j \leq n, i \geq 1, j \geq 1\}} ij \binom{n}{i, j, n - i - j} p_1^i p_2^j (1 - p_1 - p_2)^{n - i - j}$$

Πρόβλημα

Ρίχνουμε ένα ζάρι 10 φορές. Ποιά είναι η πιθανότητα να πάρουμε 4 εξάρια, 3 πεντάρια, 2 τεσσάρια και ένα τριάρι (με οποιαδήποτε σειρά);

(Απ. $\binom{10}{4,3,2,1} \frac{1}{6^{10}}$.)

Η πολυμεταβλητή υπεργεωμετρική κατανομή

Ας υποθέσουμε ότι σε μια κάλπη έχουμε K_1 μπάλες χρώματος 1, K_2 μπάλες χρώματος 2, κλπ. και K_m μπάλες χρώματος m . Συνολικά δηλαδή στην κάλπη υπάρχουν $N := K_1 + K_2 + \dots + K_m$ μπάλες, ασχέτως χρώματος. Από αυτές παίρνουμε, χωρίς επανατοποθέτηση, n μπάλες με $n \leq N$. Έστω X_i ο αριθμός των μπαλών χρώματος i , $i = 1, 2, \dots, m$ στο δείγμα μεγέθους n που πήραμε. Τότε

$$P(X_1 = n_1, X_2 = n_2, \dots, X_m = n_m) = \frac{\binom{K_1}{n_1} \binom{K_2}{n_2} \dots \binom{K_m}{n_m}}{\binom{N}{n}}, \quad n_i \in \mathbb{N}_0, \quad \sum_{i=1}^m n_i = n. \quad (17)$$

Επισημαίνουμε πάλι ότι μπορούμε να χρησιμοποιήσουμε την παραπάνω έκφραση ακόμα και στην περίπτωση που $n_i > K_i$ μια και ο αντίστοιχος διωνυμικός συντελεστής μηδενίζεται. Συνεπώς μπορούμε να χρησιμοποιήσουμε την έκφραση (17) για κάθε διάνυσμα μη αρνητικών ακεραίων (n_1, \dots, n_m) . Ο λόγος που ισχύει η (17) είναι ότι μπορούμε να διαλέξουμε n_i μπάλες χρώματος i από K_i που υπάρχουν στην κάλπη με $\binom{K_i}{n_i}$ τρόπους ενώ μπορούμε να διαλέξουμε n μπάλες ασχέτως χρώματος από τις N που υπάρχουν στην κάλπη με $\binom{N}{n}$ τρόπους.

Ας επαληθεύσουμε τώρα ότι

$$\sum_{\{(n_1, \dots, n_m)\} : \sum_{i=1}^m n_i = n} P(X_1 = n_1, \dots, X_m = n_m) = 1. \quad (18)$$

Προκειμένου να το δείξουμε αρκεί να δούμε ότι

$$\sum_{\{(n_1, \dots, n_m)\} : \sum_{i=1}^m n_i = n} \binom{K_1}{n_1} \binom{K_2}{n_2} \dots \binom{K_m}{n_m} = \binom{N}{n}. \quad (19)$$

Ας εξετάσουμε το γινόμενο

$$(1 + x_1)^{K_1} (1 + x_2)^{K_2} \dots (1 + x_m)^{K_m}.$$

Ο συντελεστής του όρου $x_1^{n_1} x_2^{n_2} \dots x_m^{n_m}$ θα είναι

$$\binom{K_1}{n_1} \binom{K_2}{n_2} \dots \binom{K_m}{n_m}.$$

Αν θέσουμε τώρα $x_1 = x_2 = \dots = x_m = x$ τότε

$$(1 + x)^{K_1} (1 + x)^{K_2} \dots (1 + x)^{K_m} = (1 + x)^N \quad (20)$$

Με βάση τις παραπάνω παρατηρήσεις, ο συντελεστής του x^n ($n \leq N = \sum_{i=1}^m K_i$) στο αριστερό μέλος της (20) δίνεται από το αριστερό μέλος της (19) ενώ ο συντελεστής του x^n στο δεξί μέλος της (20) δίνεται από το δεξί μέλος της (19).

Η περιθώρια κατανομή του X_i είναι εύκολο να διαπιστώσουμε ότι είναι υπεργεωμετρική. Αρκεί να θεωρήσουμε ότι όλες οι μπάλες που δεν είναι χρώματος i είναι κάποιου άλλου χρώματος που δεν μας ενδιαφέρει και να διαπιστώσουμε ότι

$$P(X_i = n_i) = \frac{\binom{K_i}{n_i} \binom{N-K_i}{n-n_i}}{\binom{N}{n}}, \quad n_i = 0, 1, \dots, n. \quad (21)$$

Με τον ίδιο τρόπο μπορούμε να δούμε ότι η από κοινού κατανομή των X_i, X_j είναι

$$P(X_i = n_i, X_j = n_j) = \frac{\binom{K_i}{n_i} \binom{K_j}{n_j} \binom{N-K_i-K_j}{n-n_i-n_j}}{\binom{N}{n}}, \quad n_i + n_j \leq n. \quad (22)$$

Η μέση τιμή και η διασπορά των X_i, X_j δίνεται από τις γνωστές εκφράσεις για την υπεργεωμετρική κατανομή.

$$EX_i = n \frac{K_i}{N}, \quad \text{Var}(X_i) = n \frac{K_i}{N} \frac{N - K_i}{N} \frac{N - n}{N - 1}. \quad (23)$$

Για να προσδιορίσουμε την συνδιακύμανση αρκεί να δούμε ότι

$$\begin{aligned} EX_1 X_2 &= \sum_{\substack{(n_1, n_2): n_i \geq 0, n_j \geq 0, \\ \{n_1 + n_2 \leq n\}}} n_1 n_2 \frac{\binom{K_i}{n_i} \binom{K_j}{n_j} \binom{N - K_i - K_j}{n - n_i - n_j}}{\binom{N}{n}} \\ &= \frac{K_i K_j}{\binom{N}{n}} \sum_{\{(n_1, n_2): n_i \geq 1, n_j \geq 1, n_1 + n_2 \leq n\}} \binom{K_i - 1}{n_i - 1} \binom{K_j - 1}{n_j - 1} \binom{N - K_i - K_j}{n - n_i - n_j} \end{aligned}$$

Αν θέσουμε $l_i = n_i - 1, l_j = n_j - 1$ η παραπάνω σχέση μπορεί να γραφεί ως

$$\begin{aligned} EX_1 X_2 &= \frac{K_i K_j}{\binom{N}{n}} \sum_{\substack{(l_1, l_2): l_i \geq 0, l_j \geq 0, \\ \{l_1 + l_2 \leq n - 2\}}} \binom{K_i - 1}{l_i} \binom{K_j - 1}{l_j} \binom{N - 2 - (K_i - 1) - (K_j - 1)}{n - 2 - l_i - l_j} \\ &= K_1 K_2 \frac{\binom{N-2}{n-2}}{\binom{N}{n}} = n(n-1) \frac{K_1 K_2}{N(N-1)}. \end{aligned}$$

Συνεπώς η συνδιακύμανση των X_1, X_2 είναι

$$\begin{aligned}\text{Cov}(X_1, X_2) &= E[X_1 X_2] - EX_1 EX_2 = n(n-1) \frac{K_1 K_2}{N(N-1)} - n \frac{K_1}{N} n \frac{K_2}{N} \\ &= -\frac{n(N-n)}{N-1} \frac{K_1}{N} \frac{K_2}{N}.\end{aligned}\quad (24)$$

Τέλος ο συντελεστής συσχέτισης προσδιορίζεται εύκολα από την (24) και την (23) και μετά από εύκολες απλοποιήσεις προκύπτει ότι

$$\rho = -\sqrt{\frac{K_i K_j}{(N-K_i)(N-K_j)}}.\quad (25)$$

Θεώρημα

Ένα κιβώτιο περιέχει χίλιους λαμπτήρες, 100 από τους οποίους δεν λειτουργούν. Οι χίλιοι αυτοί λαμπτήρες τοποθετούνται τυχαία σε 10 κουτιά. Ποιά είναι η πιθανότητα και οι 100 χαλασμένοι λαμπτήρες να βρεθούν στο ίδιο κουτί; Αν X_i , $i = 1, 2, \dots, 10$, είναι ο αριθμός των χαλασμένων δοχείων στο κουτί i , ποιά είναι η από κοινού κατανομή των τυχαίων μεταβλητών αυτών;

Πρόβλημα

Μια κάλπη έχει N_1 σφαιρίδια που γράφουν τον αριθμό 1, N_2 που γράφουν τον αριθμό 2 και N_3 που γράφουν τον αριθμό 3. Διαλέγω (χωρίς επανατοποθέτηση) n σφαιρίδια. Αν X_i ο αριθμός των σφαιριδίων, μεταξύ αυτών που επέλεξα, που γράφουν τον αριθμό i , $i = 1, 2, 3$, να βρείτε την από κοινού κατανομή των X_1, X_2, X_3 . Επίσης να ευρεθούν οι μέσοι, διακυμάνσεις και συνδιακυμάνσεις.