

με αυτές ως αφετηρία να μπορούμε να υπολογίσουμε πιθανότητες άλλων πιο σύνθετων. Απαιτούνται και κάποιες επιπλέον σχέσεις για τις  $p_1, p_2, \dots, p_N$ . Στο δεύτερο παράδειγμα, μια τέτοια περίπτωση υπολογισμού πιθανοτήτων δίνουμε (Παράδειγμα 3.3.7).

Στο τρίτο παράδειγμα (Παράδειγμα 3.3.8) αποδεικνύουμε ότι αν ο δειγματικός χώρος ενός πειράματος τύχης είναι πεπερασμένος και αν επιπλέον τα απλά ενδεχόμενά του είναι εξίσου πιθανά, τότε τα τρία αξιώματα οδηγούν σε έναν απλό τύπο υπολογισμού της πιθανότητας ενδεχομένου. Πρόκειται για τον ίδιο τύπο που δίνεται από τον κλασικό ορισμό. Για την εφαρμογή αυτού του τύπου, όπως ήδη διαπιστώσαμε όταν μιλήσαμε για τον κλασικό ορισμό (θυμηθείτε τα Παραδείγματα 3.3.1-3.3.3), απαιτούνται μόνο ικανότητες στην απαρίθμηση ευνοϊκών και δυνατών περιπτώσεων. Τέλος, στο Παράδειγμα 3.3.9, δίνουμε μια ακόμη εφαρμογή του τύπου αυτού σε ένα «διάσημο/πολύ γνωστό» πρόβλημα.

Σε μια έρευνα που ολοκληρώθηκε πρόσφατα, μελετήθηκαν μεταξύ άλλων, οι τιμές δύο αιματολογικών δεικτών, έστω  $A$  και  $B$ , στους άνδρες ηλικίας 50 έως 70 ετών που κατοικούν μόνιμα στο βορειοανατολικό Αιγαίο. Βρέθηκε ότι αν επιλέξουμε τυχαία έναν άνδρα που μένει μόνιμα σε νησί του βορειοανατολικού Αιγαίου και είναι ηλικίας 50 έως 70 ετών, η πιθανότητα να βρίσκεται σε φυσιολογικό επίπεδο η τιμή του δείκτη  $A$  στο αίμα του είναι ίση με 0.45. Αντίστοιχα, η πιθανότητα να βρίσκεται σε φυσιολογικό επίπεδο η τιμή του δείκτη  $B$  στο αίμα του είναι ίση με 0.30 και η πιθανότητα να βρίσκονται σε φυσιολογικό επίπεδο και οι δύο δείκτες είναι ίση με 0.10. Επιλέγουμε τυχαία έναν άνδρα που μένει μόνιμα σε νησί του βορειοανατολικού Αιγαίου και είναι ηλικίας 50 έως 70 ετών και ελέγχουμε τις τιμές των δεικτών  $A$  και  $B$  στο αίμα του. Ποια είναι η πιθανότητα να βρεθεί με τιμή σε φυσιολογικό επίπεδο

- α) τουλάχιστον ένας από τους δύο δείκτες
- β) μόνο ο δείκτης  $A$
- γ) μόνο ο δείκτης  $B$
- δ) μόνο ένας από τους δείκτες  $A, B$
- ε) κανέναν από τους δείκτες  $A, B$ .

Απάντηση: Έστω τα ενδεχόμενα

$A$ : Η τιμή του δείκτη  $A$  είναι σε φυσιολογικό επίπεδο

$B$ : Η τιμή του δείκτη  $B$  είναι σε φυσιολογικό επίπεδο.

Σύμφωνα με τα ευρήματα της έρευνας, έχουμε

$$P(A) = 0.45, \quad P(B) = 0.30 \quad \text{και} \quad P(AB) = 0.10.$$

Με βάση όσα αναφέραμε όταν μιλήσαμε για τις πράξεις μεταξύ ενδεχομένων (δες και το Σχήμα 3.2.13), οι ζητούμενες πιθανότητες, αντίστοιχα είναι

Παράδειγμα 3.3.9.

$$\alpha) P(A \cup B) = P(A) + P(B) - P(AB) = 0.45 + 0.30 - 0.10 = 0.65$$

$$\beta) P(AB') = P(A) - P(AB) = 0.45 - 0.10 = 0.35$$

$$\gamma) P(BA') = P(B) - P(AB) = 0.30 - 0.10 = 0.20$$

$$\delta) P(AB' \cup BA') = P(AB') + P(BA') = 0.35 + 0.20 = 0.55$$

$$\epsilon) 1 - P(A \cup B) = 1 - 0.65 = 0.35$$

$$\text{ή } P(AB') = P[(A \cup B)'] = 1 - P(A \cup B) = 0.35.$$

Παράδειγμα 3.3.7.

Από παρατηρήσεις πολλών ετών έχει εκτιμηθεί ότι η πιθανότητα ένας αιμοδότης που προσέρχεται σε κάποιο κέντρο αιμοδοσίας του λεκανοπεδίου Αττικής, να έχει ομάδα αίματος  $A$  είναι ίση με την πιθανότητα να έχει ομάδα αίματος  $O$  και δεκαπλάσια από την πιθανότητα να έχει ομάδα αίματος  $AB$  ενώ η πιθανότητα να έχει ομάδα αίματος  $B$  είναι τριπλάσια από την πιθανότητα να έχει ομάδα αίματος  $AB$ . Είναι γνωστό ότι ένας ασθενής με ομάδα αίματος  $A$  μπορεί να δεχθεί αίμα μόνο από τις ομάδες  $O$  και  $A$ . Ένας εθελοντής αιμοδότης προσέρχεται σε ένα κέντρο αιμοδοσίας του λεκανοπεδίου Αττικής για να δώσει αίμα για έναν ασθενή που έχει ομάδα αίματος  $A$ . Ποια είναι η πιθανότητα το αίμα του εθελοντή να είναι συμβατό με τον ασθενούς.

Απάντηση: Ένας κατάλληλος δειγματικός χώρος του πειράματος είναι προφανώς ο

$$\Omega = \{A, B, AB, O\}.$$

Ας συμβολίσουμε τις πιθανότητες των απλών ενδεχομένων  $\{A\}$ ,  $\{B\}$ ,  $\{AB\}$  και  $\{O\}$  με  $p_1, p_2, p_3$  και  $p_4$ , αντίστοιχα, δηλαδή,

$$p_1 = P(\{A\}), p_2 = P(\{B\}), p_3 = P(\{AB\}) \text{ και } p_4 = P(\{O\}).$$

Από το πρώτο και το τρίτο αξίωμα προκύπτουν όπως είδαμε οι σχέσεις

$$1. p_i \geq 0, \text{ για κάθε } i = 1, 2, 3, 4$$

$$2. p_1 + p_2 + p_3 + p_4 = 1$$

και σύμφωνα με τα δεδομένα του προβλήματος, επιπλέον ισχύουν οι σχέσεις,  $p_1 = p_4 = 10p_3$  και  $p_2 = 3p_3$ .

Αντικαθιστώντας από τις τελευταίες σχέσεις τα  $p_2, p_3$  και  $p_4$  στην  $p_1 + p_2 + p_3 + p_4 = 1$ , παίρνουμε

$$p_1 + \frac{3p_1}{10} + \frac{p_1}{10} + p_1 = 1 \Rightarrow \frac{24p_1}{10} = 1 \Rightarrow p_1 = \frac{5}{12} \cong 0.42$$

και επομένως

$$p_4 \cong 0.42, p_3 = \frac{p_1}{10} \cong 0.04 \text{ και } p_2 = 3p_3 \cong 0.12.$$

Έτσι, αξιοποιώντας τη σχέση  $p_1 + p_2 + p_3 + p_4 = 1$  (που προκύπτει από το τρίτο αξίωμα του ορισμού) και τις σχέσεις που μας δόθηκαν υπολογίσαμε τις πιθανότητες όλων των απλών ενδεχομένων και πλέον μπορούμε να υπολογίσουμε την πιθανότητα οποιουδήποτε ενδεχομένου του  $\Omega$ .

Εφόσον ένας ασθενής με ομάδα αίματος  $A$  μπορεί να δεχθεί αίμα

μόνο από τις ομάδες  $O$  και  $A$ , η ζητούμενη πιθανότητα, προφανώς είναι η πιθανότητα του ενδεχομένου  $\{O, A\}$ , επομένως έχουμε

$$P(\{O, A\}) = P(\{O\}) + P(\{A\}) = p_4 + p_1 = 0.42 + 0.42 = 0.84.$$

Έστω  $\Omega = \{\omega_1, \omega_2, \omega_3, \dots, \omega_N\}$  πεπερασμένος δειγματικός χώρος με  $N(\Omega) = N$  ισοπίθανα δειγματικά σημεία. Έστω επίσης  $A$ , ένα οποιοδήποτε ενδεχόμενο του  $\Omega$  με  $N(A)$  δειγματικά σημεία (στοιχεία). Θα δείξουμε ότι η πιθανότητα  $P(A)$ , πραγματοποίησης του  $A$ , δίνεται από τον τύπο

$$P(A) = \frac{N(A)}{N}.$$

Σύμφωνα με το Πρόγραμμα 3.3.1(β), για τις πιθανότητες,

$$p_1 = P(\{\omega_1\}), p_2 = P(\{\omega_2\}), p_3 = P(\{\omega_3\}), \dots, p_N = P(\{\omega_N\})$$

πραγματοποίησης των απλών ενδεχομένων,  $\{\omega_1\}, \{\omega_2\}, \{\omega_3\}, \dots, \{\omega_N\}$ , ισχύει

$$\sum_{i=1}^N p_i = p_1 + p_2 + \dots + p_N = 1.$$

Οι πιθανότητες των απλών ενδεχομένων θεωρούνται ίσες και έστω  $p$  η τιμή τους, έστω δηλαδή,  $p_1 = p_2 = p_3 = \dots = p_N = p$ . Έτσι, έχουμε

$$\sum_{i=1}^N p_i = p_1 + p_2 + \dots + p_N = 1 \Leftrightarrow Np = 1 \Leftrightarrow p = \frac{1}{N}.$$

Έστω ένα οποιοδήποτε ενδεχόμενο  $A$  του  $\Omega$  με  $N(A)$  δειγματικά σημεία (στοιχεία). Λόγω της Πρότασης 3.3.1(γ) για την πιθανότητα  $P(A)$ , πραγματοποίησης του  $A$ , έχουμε

$$P(A) = \sum_{\omega \in A} p(\omega) = \underbrace{p + p + \dots + p}_{N(A) \text{ το πλήθος}} = N(A) \cdot p = N(A) \cdot \frac{1}{N} = \frac{N(A)}{N}.$$

Δείξαμε έτσι, πώς από τα τρία αξιώματα του αξιωματικού ορισμού, προκύπτει ο τύπος που δίνεται στον κλασικό ορισμό για τον υπολογισμό της πιθανότητας ενδεχομένου. Ας δούμε ως ένα παράδειγμα εφαρμογής του τύπου αυτού ένα ενδιαφέρον πρόβλημα, γνωστό στη βιβλιογραφία ως πρόβλημα των γενεθλίων. Μπορείτε επίσης να ξαναδείτε τα παραδείγματα που δώσαμε όταν μιλήσαμε για τον κλασικό ορισμό.

Ποια είναι η πιθανότητα σε μια τάξη  $k$  φοιτητών, δύο τουλάχιστον να έχουν γενέθλια την ίδια ημέρα. Θεωρήστε ότι το έτος έχει 365 ημέρες και ότι  $k \leq 365$ .

Απάντηση: Ο δειγματικός χώρος  $\Omega$  του πειράματος αποτελείται από όλες τις διατεταγμένες  $k$ -άδες  $a_1, a_2, a_3, \dots, a_k$ , όπου  $a_1$  είναι η ημέρα γενεθλίων του 1ου φοιτητή,  $a_2$  είναι η ημέρα γενεθλίων του 2ου φοιτητή, ... και  $a_k$  είναι η ημέρα γενεθλίων του  $k$ ου φοιτητή. Πρόκειται για πεπερασμένο δειγματικό χώρο με  $N(\Omega) = 365^k$

Παράδειγμα 3.3.8. (πεπερασμένοι δειγματικοί χώροι με ισοπίθανα απλά ενδεχόμενα)

Παράδειγμα 3.3.9. (το πρόβλημα των γενεθλίων)

δηλαδή, με  $365^k$  δυνατά αποτελέσματα, αφού η ημερομηνία γενεθλίων του 1ου φοιτητή μπορεί να είναι οποιαδήποτε από τις 365 ημέρες του έτους, η ημερομηνία γενεθλίων του 2ου φοιτητή (όποια και αν είναι η ημερομηνία γενεθλίων του 1ου) μπορεί επίσης να είναι οποιαδήποτε από τις 365 ημέρες του έτους, κ.ο.κ. Δηλαδή, για το σχηματισμό μιας διατεταγμένης  $k$ -άδας το στοιχείο  $a_1$  μπορεί να πάρει οποιαδήποτε από 365 διαφορετικές τιμές, το στοιχείο  $a_2$  μπορεί επίσης να πάρει οποιαδήποτε από 365 διαφορετικές τιμές (όποια και αν είναι η τιμή που πήρε το  $a_1$ ), κ.ο.κ. και επομένως οι διαφορετικές  $k$ -άδες  $a_1, a_2, a_3, \dots, a_k$  που είναι δυνατόν να δημιουργηθούν σύμφωνα με την *πολλαπλασιαστική αρχή* είναι

$$\underbrace{365 \cdot 365 \cdot \dots \cdot 365}_{k \text{ το πλήθος}} = 365^k.$$

Με την παραδοχή ότι τα  $365^k$  δυνατά αποτελέσματα είναι ισοπίθανα θα υπολογίσουμε τη ζητούμενη πιθανότητα ως το λόγο των ευνοϊκών προς τις δυνατές περιπτώσεις. Έστω λοιπόν το ενδεχόμενο

$A$ : Δύο τουλάχιστον από τους  $k$  φοιτητές έχουν γενέθλια την ίδια ημέρα και το συμπλήρωμά του

$A'$ : οι  $k$  φοιτητές έχουν διαφορετικές ημερομηνίες γενεθλίων.

Θα υπολογίσουμε την πιθανότητα

$$P(A') = \frac{N(A')}{N(\Omega)}$$

του ενδεχομένου  $A'$  και στη συνέχεια από τον τύπο  $P(A) = 1 - P(A')$  θα υπολογίσουμε τη ζητούμενη πιθανότητα.

Το πλήθος των ευνοϊκών περιπτώσεων  $N(A')$  για την πραγματοποίηση του  $A'$  προφανώς είναι  $365 \cdot 364 \cdot 363 \cdot \dots \cdot [365 - (k - 1)]$ , δηλαδή,

$$N(A') = 365 \cdot 364 \cdot 363 \cdot \dots \cdot (365 - k + 1)$$

αφού στα ευνοϊκά για το ενδεχόμενο  $A'$  αποτελέσματα, οι  $k$  φοιτητές πρέπει να έχουν διαφορετικές ημερομηνίες γενεθλίων, δηλαδή, το  $A'$  αποτελείται από όλες τις διατεταγμένες  $k$ -άδες  $a_1, a_2, a_3, \dots, a_k$  που έχουν διαφορετικά στοιχεία δηλαδή που είναι  $a_i \neq a_j$  (για  $i \neq j$ ). Αυτό σημαίνει ότι στις ευνοϊκές  $k$ -άδες, το  $a_2$  δεν παίρνει 365 διαφορετικές τιμές αλλά  $365 - 1 = 364$  γιατί εξαιρείται η τιμή που πήρε το  $a_1$  (δηλαδή η ημερομηνία γενεθλίων του 1ου φοιτητή), ανάλογα, το  $a_3$  παίρνει  $365 - 2 = 363$  διαφορετικές τιμές γιατί εξαιρούνται οι ημερομηνίες γενεθλίων των προηγούμενων δύο φοιτητών και τέλος το  $a_k$  παίρνει  $365 - (k - 1)$  διαφορετικές τιμές αφού εξαιρούνται οι ημερομηνίες γενεθλίων των προηγούμενων  $k - 1$  φοιτητών.

Έτσι έχουμε

$$P(A') = \frac{365 \cdot 364 \cdot 363 \cdot \dots \cdot (365 - k + 1)}{365^k}$$

και άρα η ζητούμενη πιθανότητα είναι

$$P(A) = 1 - P(A') = 1 - \frac{365 \cdot 364 \cdot 363 \cdot \dots \cdot (365 - k + 1)}{365^k}, \quad 1 \leq k \leq 365.$$

Για να υπολογίσουμε τα  $N(\Omega)$  και  $N(A')$  μπορούμε να σκεφθούμε και ως εξής: κάθε δυνατό αποτέλεσμα είναι μια επαναληπτική διάταξη των  $n = 365$  ημερών του έτους ανά  $k$  και επομένως με εφαρμογή του τύπου που δίνει το πλήθος των επαναληπτικών διατάξεων των  $n$  στοιχείων ανά  $k$  έχουμε  $N(\Omega) = n^k = 365^k$  ενώ κάθε εννοϊκό αποτέλεσμα είναι μια διάταξη των  $n = 365$  ημερών του έτους ανά  $k$  και επομένως  $N(A') = (n)_k = (365)_k = 365 \cdot 364 \cdot 363 \cdot \dots \cdot (365 - k + 1)$ .

Σχόλιο 3.3.4

Στον πίνακα που ακολουθεί δίνουμε τις τιμές της πιθανότητας του ενδεχομένου  $A$  για διάφορες τιμές του  $k$ .

Σχόλιο 3.3.5

$k$	5	10	23	30	50	70
$P(A)$	0.027	0.117	0.507	0.706	0.970	0.999

Παρατηρείστε ότι αυξανόμενον τον  $k$ , η πιθανότητα από  $k$  άτομα να βρεθούν τουλάχιστον δύο που να έχουν γενέθλια την ίδια ημέρα ασφαλώς αυξάνεται και μάλιστα φθάνει πολύ γρήγορα σε τιμές κοντά στο 1. Για παράδειγμα, μεταξύ μόλις 50 ατόμων η πιθανότητα τουλάχιστον δύο να έχουν γενέθλια την ίδια ημέρα είναι πολύ μεγάλη, ίση με 97%, ενώ μεταξύ 70 ατόμων είναι σχεδόν βέβαιο ότι τουλάχιστον δύο έχουν γενέθλια την ίδια ημέρα. Παρατηρείστε επίσης, ότι για  $k = 23$  είναι  $P(A) = 0.507$ , δηλαδή, μεταξύ 23 ατόμων<sup>19</sup> η πιθανότητα να υπάρχουν τουλάχιστον δύο που να έχουν γενέθλια την ίδια ημέρα είναι μεγαλύτερη από την πιθανότητα να μην υπάρχουν!!!

Ερώτηση: Στο αμφιθέατρο βρίσκονται για το μάθημα της Στατιστικής 70 φοιτητές και ο καθηγητής. Ο καθηγητής μόλις έχει εξηγήσει το πρόβλημα των γενεθλίων όταν ένας φοιτητής απευθυνόμενος στον καθηγητή και τους συμμαθητές του λέει: έχω γενέθλια στις 24/6, υπάρχει κάποιος άλλος στο αμφιθέατρο που να έχει γενέθλια στις 24/6; Τι είναι άραγε πιο πιθανό, να βρεθεί και κάποιος άλλος που να έχει γενέθλια στις 24/6 ή να μη βρεθεί; (Υπόδειξη: Δείτε την Άσκηση 3.5)

19. Ας πούμε μεταξύ των 22 ποδοσφαιριστών και του διαιτητή σε έναν ποδοσφαιρικό αγώνα!



μήνυμα που περιέχει κάποια ή κάποιες από αυτές τις λέξεις είναι *Spam*. Αν επομένως απαντηθεί το ερώτημα «ποια είναι η πιθανότητα, να είναι *Spam* ένα μήνυμα που διαπιστώσαμε ότι περιέχει μια ή περισσότερες τέτοιες λέξεις» και βρεθεί ότι η πιθανότητα αυτή είναι μεγάλη (μεγαλύτερη από κάποιο επίπεδο που θέτουμε π.χ. 95%) τότε ένα τέτοιο μήνυμα μπορεί να απορριφθεί από το φίλτρο, δηλαδή, να θεωρηθεί *Spam*. Βέβαια, ένα τέτοιο φίλτρο μπορεί να κάνει λάθη. Δηλαδή, μπορεί ένα μήνυμα να το θεωρήσει *Spam* ενώ δεν είναι, καθώς επίσης ένα μήνυμα να μην το θεωρήσει *Spam* ενώ είναι. Αυτό που επιδιώκεται είναι να ελαχιστοποιείται η πιθανότητα να θεωρηθεί ένα μήνυμα *Spam* ενώ δεν είναι. Είναι προφανές ότι τέτοια φίλτρα μπορούν να βασίζονται σε μία ή περισσότερες λέξεις ή σε έναν ή περισσότερους συνδυασμούς λέξεων. Ας δούμε ένα απλό φίλτρο που βασίζεται σε μια μόνο λέξη.

Έστω « $w$ » μια τέτοια λέξη και ας υποθέσουμε ότι σε μια χρονική περίοδο φθάνει σε έναν *mail server* ένα σύνολο μηνυμάτων. Κάθε μήνυμα από αυτά είναι ή δεν είναι *Spam*. Έτσι, αν  $S$  είναι το υποσύνολο των μηνυμάτων που είναι *Spam* τότε προφανώς το  $S'$  είναι το υποσύνολο των μηνυμάτων που δεν είναι *Spam*. Μπορούμε να μετρήσουμε σε πόσα από τα μηνύματα του υποσυνόλου  $S$  και σε πόσα από τα μηνύματα του υποσυνόλου  $S'$  εμφανίζεται η λέξη « $w$ » και έτσι να εκτιμήσουμε αφενός την πιθανότητα: ένα μήνυμα που είναι *Spam* να περιέχει τη λέξη « $w$ » και αφετέρου την πιθανότητα: ένα μήνυμα που δεν είναι *Spam* να περιέχει τη λέξη « $w$ ». Επίσης, μπορούμε να εκτιμήσουμε την πιθανότητα: ένα μήνυμα που φθάνει στον *mail server* είναι *Spam* και την πιθανότητα: ένα μήνυμα που φθάνει στον *mail server* δεν είναι *Spam*.

Ένα μήνυμα φθάνει στον *mail server* και διαπιστώνεται ότι περιέχει τη λέξη « $w$ ». Αν  $E$  το ενδεχόμενο: το μήνυμα περιέχει τη λέξη « $w$ », τότε όπως αναφέραμε προηγουμένως οι πιθανότητες  $P(E/S)$ ,  $P(E/S')$ ,  $P(S)$  και  $P(S')$  μπορούν να εκτιμηθούν και επειδή τα ενδεχόμενα  $S$  και  $S'$  διαμερίζουν το σύνολο όλων των μηνυμάτων, από το **Θεώρημα Bayes** έχουμε

$$P(S/E) = \frac{P(E/S)P(S)}{P(E/S)P(S) + P(E/S')P(S')}$$

Ας δούμε ένα αριθμητικό παράδειγμα.

Παράδειγμα 4.4.4.  
(Μπεϋζιανά φίλτρα  
Spam)

Βρέθηκε ότι από τα 3000 μηνύματα που έφθασαν μια χρονική περίοδο σε έναν *mail server*, τα 2000 είναι *Spam* και τα 1000 δεν είναι *Spam*. Βρέθηκε επίσης ότι η λέξη «*Rolex*» εμφανίσθηκε σε 250 από τα 2000 μηνύματα που είναι *Spam* και σε 5 από τα 1000 μηνύματα που δεν είναι *Spam*.

Ένα μήνυμα φθάνει στον *mail server* και διαπιστώνουμε ότι περιέχει τη λέξη «*Rolex*». Ποια είναι η πιθανότητα το μήνυμα αυτό να είναι *Sram*.

*Απάντηση:* Θεωρώντας ότι ο αριθμός των επαναλήψεων του πειράματος (3000) είναι αρκετά μεγάλος ώστε να έχει επιτευχθεί σταθεροποίηση των σχετικών συχνοτήτων έχουμε

$$P(S) = \frac{2000}{3000} = 0.67, \quad P(S') = 1 - P(S) = 0.33.$$

$$P(E/S) = \frac{250}{2000} = 0.125 \quad \text{και} \quad P(E/S') = \frac{5}{1000} = 0.005.$$

Επομένως η ζητούμενη πιθανότητα είναι

$$P(S/E) = \frac{0.125 \cdot 0.67}{0.125 \cdot 0.67 + 0.005 \cdot 0.33} = 0.98.$$

Έτσι, αν ως επίπεδο απόρριψης ενός μηνύματος που περιέχει τη λέξη «*Rolex*» θέσουμε το 0.95 τότε το μήνυμα απορρίπτεται ως *Sram*.

Ανάλογα υπολογίζουμε τις αντίστοιχες πιθανότητες για φίλτρα που ελέγχουν περισσότερες από μια λέξεις.

### 4.5. Ανεξαρτησία ενδεχομένων

Σε όλα τα προηγούμενα παραδείγματα, όπως διαπιστώσαμε, οι δεσμευμένες πιθανότητες διαφέρουν από τις αντίστοιχες μη δεσμευμένες. Για παράδειγμα, η εκ των υστέρων (δεσμευμένη) πιθανότητα να έχει ένα άτομο αχρωματοψία δοθέντος ότι είναι άνδρας διαφέρει, και μάλιστα είναι μεγαλύτερη, από την εκ των προτέρων (μη δεσμευμένη) πιθανότητα ένα άτομο να έχει αχρωματοψία (Παράδειγμα 4.1.4). Δηλαδή, αν  $A$  και  $B$  τα ενδεχόμενα, αντίστοιχα, «το άτομο πάσχει από αχρωματοψία» και «το άτομο είναι άνδρας», τότε

$$P(A|B) > P(A)$$

ενώ

$$P(A|B') < P(A),$$

δηλαδή, η εκ των υστέρων πιθανότητα να έχει ένα άτομο αχρωματοψία δοθέντος ότι είναι γυναίκα, είναι μικρότερη από την αντίστοιχη εκ των προτέρων.

Επίσης, στο Παράδειγμα 4.1.6 είδαμε ότι για δύο ξένα ενδεχόμενα  $A, B$  (με  $P(A) > 0$  και  $P(B) > 0$ ) είναι

$$P(A|B) = 0 \quad \text{και} \quad P(B|A) = 0.$$

δηλαδή, η γνώση ότι εμφανίστηκε το ένα από τα δύο, αποκλείει την εμφάνιση του άλλου (προφανώς αναμενόμενο για ξένα ενδεχόμενα).

άλλον. Σε αυτές τις περιπτώσεις αναγνωρίζουμε και δεχόμαστε την ανεξαρτησία των  $A$  και  $B$  από τις συνθήκες του πειράματος και δεν ελέγχουμε τη σχέση ανεξαρτησίας  $P(AB) = P(A)P(B)$ . Μάλιστα, δεχόμενοι από τις συνθήκες του πειράματος ότι τα  $A$  και  $B$  είναι ανεξάρτητα, μπορούμε να χρησιμοποιήσουμε τη σχέση αυτή για τον υπολογισμό της πιθανότητας της τομής  $AB$  των  $A$  και  $B$  που πιθανόν μας ενδιαφέρει (δείτε και το παράδειγμα που ακολουθεί).

Δύο φοιτητές, ας πούμε ο  $A$  και ο  $B$ , κάνουν την καλοκαιρινή πρακτική τους άσκηση ως διορθωτές κειμένων σε έναν εκδοτικό οίκο. Σύμφωνα με ένα τεστ ικανοτήτων, ο  $A$  εντοπίζει ένα λάθος συλλαβισμού (χωρισμού λέξης) με πιθανότητα 0.65 ενώ ο  $B$  εντοπίζει ένα λάθος συλλαβισμού με πιθανότητα 0.80. Σε καθένα φοιτητή δόθηκε να ελέγξει ένα κείμενο που είχε ένα λάθος συλλαβισμού (το κείμενο ήταν ίδιο και για τους δύο φοιτητές). Ποια είναι η πιθανότητα να μην εντοπισθεί το λάθος;

Παράδειγμα 4.5.2.

Απάντηση: Ας θεωρήσουμε τα ενδεχόμενα

$A$ : ο φοιτητής  $A$  εντοπίζει το λάθος

$B$ : ο φοιτητής  $B$  εντοπίζει το λάθος.

Ζητάμε την πιθανότητα  $P(A'B')$ .

Επειδή οι διορθωτές κατά κανόνα εργάζονται μόνοι και όχι σε συνεργασία, είναι λογικό να θεωρήσουμε ότι το αν θα εντοπίσει ή όχι ο ένας φοιτητής το λάθος δεν έχει καμία συνέπεια/επίδραση στο αν ο άλλος φοιτητής θα εντοπίσει ή όχι το λάθος, ή αλλιώς, είναι λογικό να θεωρήσουμε ότι η πραγματοποίηση ή μη του ενός από τα ενδεχόμενα  $A$  και  $B$  δε μπορεί να έχει κάποια επίδραση στην πραγματοποίηση ή μη του άλλου. Πρόκειται επομένως για ανεξάρτητα ενδεχόμενα και συνεπώς είναι ανεξάρτητα και τα  $A'$  και  $B'$ , επομένως

$$P(A'B') = P(A')P(B') = 0.35 \cdot 0.20 = 0.07.$$

Ένα εργοστάσιο έχει δύο γραμμές παραγωγής  $\Gamma_1$  και  $\Gamma_2$ . Στο τμήμα ποιοτικού ελέγχου όταν διαπιστώνεται ότι ένα προϊόν είναι ελαττωματικό κατατάσσεται σε μια από δύο κατηγορίες  $E_1$  και  $E_2$  ανάλογα με τη σοβαρότητα του ελαττώματος και καταγράφεται από ποια γραμμή παραγωγής προέρχεται. Στον πίνακα που ακολουθεί φαίνεται πώς κατανέμονται 1440 ελαττωματικά προϊόντα στις δύο γραμμές παραγωγής  $\Gamma_1$ ,  $\Gamma_2$  και στις δύο κατηγορίες  $E_1$ ,  $E_2$ .

Παράδειγμα 4.5.3.

	$E_1$	$E_2$	Σύνολο
$\Gamma_1$	400	200	600
$\Gamma_2$	200	640	840
Σύνολο	600	840	1440



	$\Gamma 1$	$\Gamma 2$	Σύνολα
$E 1$	500	300	800
$E 2$	400	240	640
Σύνολα	900	540	1440

Ας θεωρήσουμε τα ενδεχόμενα

$\Gamma 1$ : το προϊόν προέρχεται από τη γραμμή παραγωγής  $\Gamma 1$

$\Gamma 2$ : το προϊόν προέρχεται από τη γραμμή παραγωγής  $\Gamma 2$

$E 1$ : το προϊόν ανήκει στην κατηγορία  $E 1$

$E 2$ : το προϊόν ανήκει στην κατηγορία  $E 2$ .

Τα ενδεχόμενα  $\Gamma 2$  και  $E 2$  είναι άραγε ανεξάρτητα ή εξαρτημένα;

Απάντηση: Με βάση το στατιστικό ορισμό της πιθανότητας έχουμε

$$P(\Gamma 2) = \frac{540}{1440} = 0.3750, \quad P(E 2) = \frac{640}{1440} = 0.4444$$

$$\text{και } P(\Gamma 2 E 2) = \frac{240}{1440} = 0.1666$$

και επειδή

$$P(\Gamma 2)P(E 2) = 0.3750 \cdot 0.4444 = 0.1666 = P(\Gamma 2 E 2),$$

τα  $\Gamma 2$  και  $E 2$  είναι ανεξάρτητα.

Αν εργασθούμε με δεσμευμένες πιθανότητες, ασφαλώς οδηγούμαστε στο ίδιο συμπέρασμα. Πράγματι,

$$P(\Gamma 2|E 2) = \frac{P(\Gamma 2 E 2)}{P(E 2)} = \frac{240/1440}{640/1440} = \frac{240}{640} = 0.3750 = P(\Gamma 2)$$

και ασφαλώς

$$P(E 2|\Gamma 2) = \frac{P(E 2 \Gamma 2)}{P(\Gamma 2)} = \frac{240/1440}{540/1440} = \frac{240}{540} = 0.4444 = P(E 2)$$

δηλαδή, η γνώση της πραγματοποίησης του ενός ενδεχομένου δεν επηρεάζει την πραγματοποίηση του άλλου και επομένως αυτά είναι ανεξάρτητα.

Εφόσον τα ενδεχόμενα  $\Gamma 2$  και  $E 2$  είναι ανεξάρτητα, μήπως και τα  $\Gamma 1$  και  $E 1$  είναι επίσης ανεξάρτητα; Η απάντηση είναι ναι και μπορούμε να το τεκμηριώσουμε χωρίς να χρειασθεί να υπολογίσουμε τις κατάλληλες πιθανότητες από τα δεδομένα του πίνακα. Παρατηρήστε ότι το  $\Gamma 1$  είναι το συμπλήρωμα του  $\Gamma 2$  (αφού ένα ελαττωματικό προϊόν είτε θα

προέρχεται από τη γραμμή  $G1$  είτε από τη  $G2$ ) και ότι το  $E1$  είναι το συμπλήρωμα του  $E2$  (αφού ένα ελαττωματικό προϊόν είτε θα κατατάσσεται στην κατηγορία  $E1$  είτε στην  $E2$ ). Επομένως, με βάση την Πρόταση 4.5.1, τα  $G1$  και  $E1$  θα είναι ανεξάρτητα ως τα συμπληρώματα των ανεξάρτητων ενδεχομένων  $G2$  και  $E2$ . Ανεξάρτητα θα είναι επίσης και τα  $G2$ ,  $E1$  αλλά και τα  $G1$ ,  $E2$  λόγω της Πρότασης 4.5.1 επίσης. Όπως θα δούμε σε επόμενο κεφάλαιο, η ανεξαρτησία αυτών των ζευγών ενδεχομένων σημαίνει (και συνεπάγεται) ότι είναι ανεξάρτητα τα χαρακτηριστικά «γραμμή παραγωγής από την οποία προέρχεται το προϊόν» και «κατηγορία που ανήκει το προϊόν». Σημειώνουμε επίσης ότι ένας διδιάστατος πίνακας όπως ο παραπάνω, όπου τα δεδομένα στις στήλες αφορούν ένα χαρακτηριστικό και τα δεδομένα στις γραμμές ένα άλλο, ονομάζεται πίνακας συνάφειας (contingency table). Στο Β' Μέρος θα αναφερθούμε στους πίνακες συνάφειας πιο αναλυτικά.

Τρία ενδεχόμενα  $A$ ,  $B$  και  $\Gamma$  του δειγματικού χώρου  $\Omega$  ενός πειράματος τύχης λέγονται ανεξάρτητα ή τελείως ανεξάρτητα αν ισχύουν οι σχέσεις

$$\begin{aligned} P(AB) &= P(A)P(B) \\ P(A\Gamma) &= P(A)P(\Gamma) \\ P(B\Gamma) &= P(B)P(\Gamma) \end{aligned} \quad (4.5.2)$$

και

$$P(AB\Gamma) = P(A)P(B)P(\Gamma). \quad (4.5.3)$$

Παρατηρήστε ότι, παρότι οι συνθήκες (4.5.2) εξασφαλίζουν ότι τρία ενδεχόμενα  $A$ ,  $B$  και  $\Gamma$  είναι ανεξάρτητα ανά δύο, εντούτοις, δεν αρκούν για τον ορισμό της ανεξαρτησίας τριών ενδεχομένων. Απαιτείται επιπλέον και η (4.5.3).

Σκεφθείτε ότι αν ένα ενδεχόμενο  $A$  είναι ανεξάρτητο από ένα ενδεχόμενο  $B$  και επίσης από ένα ενδεχόμενο  $\Gamma$ , αυτό δε σημαίνει ότι είναι ανεξάρτητο και από την τομή τους  $B\Gamma$  (δες Άσκηση 4.25). Δηλαδή, ενώ η πραγματοποίηση του  $B$  δεν επηρεάζει την πραγματοποίηση του  $A$  και επίσης ούτε η πραγματοποίηση του  $\Gamma$  επηρεάζει την πραγματοποίηση του  $A$ , εντούτοις, η ταυτόχρονη πραγματοποίηση των  $B$  και  $\Gamma$  μπορεί να επηρεάζει την πραγματοποίηση του  $A$ !!! Αυτό δε μπορεί βέβαια να είναι επιθυμητό για ανεξάρτητα ενδεχόμενα, γιατί προφανώς, με βάση το νόημα της ανεξαρτησίας δύο ενδεχομένων, η γενίκευσή της για τρία ενδεχόμενα, πρέπει να διασφαλίζει ότι η πραγματοποίηση οποιουδήποτε από τα τρία ενδεχόμενα δεν επηρεάζει τις πιθανότητες πραγματοποίησης των υπολοίπων αλλά πρέπει επίσης να διασφαλίζει ότι και η πραγματοποίηση οποιωνδήποτε δύο από τα τρία δεν επηρεάζει τις πιθανότητες πραγματοποίησης των υπολοίπων. Δηλαδή, για να είναι τρία ενδεχόμενα,

Ορισμός 4.5.2.  
(ανεξαρτησία  
τριών ενδεχομένων)

έστω  $A, B, \Gamma$ , (τελείως) ανεξάρτητα πρέπει να είναι ανεξάρτητα αφενός τα  $A$  και  $B$ ,  $A$  και  $\Gamma$ ,  $B$  και  $\Gamma$ , αλλά αφετέρου και τα  $A$  και  $B\Gamma$ ,  $B$  και  $A\Gamma$ , και τέλος, τα  $\Gamma$  και  $AB$ . Έτσι, προκύπτει η αναγκαιότητα και της (4.5.3) η οποία εκφράζει τη δεύτερη ομάδα συνθηκών (σχεφθείτε γιατί) και δεν προκύπτει από τις (4.5.2) (δες και Άσκηση 4.26).

Επίσης, ούτε η συνθήκη (4.5.3) αρκεί παρότι αποτελεί επέκταση για τρία ενδεχόμενα της συνθήκης ανεξαρτησίας (4.5.1) δύο ενδεχομένων γιατί δε διασφαλίζει ότι ισχύουν οι (4.5.2) (δες Άσκηση 4.27). Επομένως, όταν ελέγχεται η ανεξαρτησία τριών ενδεχομένων, πρέπει να ελέγχονται τόσο οι (4.5.2) όσο και η (4.5.3).

Σημειώνουμε επίσης, ότι αν για τρία ενδεχόμενα  $A, B$  και  $\Gamma$  ικανοποιούνται οι συνθήκες (4.5.2) τότε λέμε ότι αυτά είναι *ανεξάρτητα ανά δύο ή κατά ζεύγη*. Από όσα προηγουμένως αναφέραμε, είναι προφανές ότι στα *ανεξάρτητα κατά ζεύγη* ενδεχόμενα, η γνώση για την ταυτόχρονη πραγματοποίηση δύο εξ αυτών μπορεί να επηρεάσει την πιθανότητα πραγματοποίησης του τρίτου ενώ στα (τελείως) *ανεξάρτητα* αυτό δε μπορεί να συμβεί.

Ας δούμε τώρα πώς ορίζεται η ανεξαρτησία  $n \geq 2$  ενδεχομένων.

Ορισμός 4.5.3.  
(ανεξαρτησία  
 $n \geq 2$  ενδεχομένων)

Θα λέμε ότι  $n \geq 2$  ενδεχόμενα  $A_1, A_2, \dots, A_n$  του δειγματικού χώρου  $\Omega$  ενός πειράματος τύχης είναι *ανεξάρτητα ή τελείως ανεξάρτητα* αν για οποιοδήποτε σύνολο  $k$  δεικτών  $i_1, i_2, \dots, i_k$  από το σύνολο  $\{1, 2, \dots, n\}$  ισχύει

$$P(A_{i_1} A_{i_2} \dots A_{i_k}) = P(A_{i_1}) P(A_{i_2}) \dots P(A_{i_k}).$$

Δηλαδή, λέμε ότι  $n \geq 2$  ενδεχόμενα του δειγματικού χώρου ενός πειράματος τύχης είναι *ανεξάρτητα ή τελείως ανεξάρτητα* αν η γνώση ότι πραγματοποιήθηκε ταυτόχρονα οποιοσδήποτε αριθμός από αυτά, δεν επηρεάζει τις πιθανότητες πραγματοποίησης των υπολοίπων ενδεχομένων. Αυτό βέβαια έχει ως συνέπεια να αυξάνει ραγδαία με το  $n$  ο αριθμός των συνθηκών που πρέπει να ικανοποιούνται. Για παράδειγμα, για  $n = 4$  ανεξάρτητα ενδεχόμενα  $A_1, A_2, A_3, A_4$ , πρέπει να ικανοποιούνται

$$\binom{4}{2} = 6 \text{ συνθήκες της μορφής } P(A_i A_j) = P(A_i) P(A_j)$$

$$\binom{4}{3} = 4 \text{ συνθήκες της μορφής } P(A_i A_j A_k) = P(A_i) P(A_j) P(A_k) \text{ και}$$

$$\binom{4}{4} = 1 \text{ συνθήκη, η } P(A_1 A_2 A_3 A_4) = P(A_1) P(A_2) P(A_3) P(A_4),$$

δηλαδή συνολικά πρέπει να ικανοποιούνται 11 συνθήκες!

Γενικά, για  $n \geq 2$  ενδεχόμενα πρέπει να ικανοποιούνται

$\binom{n}{2} + \binom{n}{3} + \dots + \binom{n}{n} = 2^n - n - 1$  συνθήκες (θυμηθείτε το σχετικό παραδειγμα εφαρμογής του τύπου των Νεύτωνι που δώσαμε όταν μιλήσαμε για τους διωνυμικούς συντελεστές). Προφανώς ο αριθμός αυτός είναι μεγάλος ακόμη και για μικρά  $n$ , π.χ. αν  $n = 5$  ενδεχόμενα, για να ελεγχθεί αν αυτά είναι τελείως ανεξάρτητα πρέπει να ελεγχθούν  $2^5 - 5 - 1 = 26$  συνθήκες!

Βέβαια, όπως εξηγήσαμε προηγουμένως (Σχόλιο 4.5.1.), στην πράξη αναγνωρίζουμε και δεχόμαστε την ανεξαρτησία ενδεχομένων από τις συνθήκες και τους περιορισμούς του πειράματος και έτσι δεν κάνουμε έλεγχο των συνθηκών ανεξαρτησίας αλλά αντίθετα τις χρησιμοποιούμε για να υπολογίσουμε πιθανότητες τομών ενδεχομένων που πιθανόν μας ενδιαφέρουν.

Σημειώνουμε τέλος, ότι εύκολα προκύπτει ότι τα συμπληρώματα  $n \geq 2$  ανεξάρτητων ενδεχομένων είναι ανεξάρτητα όπως και οποιαδήποτε  $k$  από αυτά με τα συμπληρώματα των υπόλοιπων  $n - k$  είναι επίσης ανεξάρτητα.

Μια ασφαλιστική εταιρεία, στο πλαίσιο μιας πιλοτικής μελέτης για τις μελλοντικές υποχρεώσεις της σε αποζημιώσεις ασφαλιστήριων συμβολαίων ζωής, επέλεξε τρεις πελάτες από τους οποίους ένας είναι κάτοικος του λεκανοπεδίου Αττικής, ένας κάτοικος Θεσσαλονίκης και ο τρίτος κάτοικος Ρόδου. Σύμφωνα με τις εκτιμήσεις της εταιρείας, η πιθανότητα να ζήσει μέχρι το 2020 ο πρώτος εκτιμάται ίση με 0.6 και αντίστοιχα 0.9 και 0.3 ο δεύτερος και ο τρίτος. Ποια είναι η πιθανότητα, μέχρι το τέλος του 2019 η εταιρεία να πρέπει να πληρώσει αποζημίωση λόγω θανάτου ενός (ακριβώς) από τους τρεις πελάτες.

Παράδειγμα 4.5.4.

Απάντηση: Ας θεωρήσουμε τα ενδεχόμενα

$A_1$ : ο κάτοικος Αττικής το 2019 ζει

$A_2$ : ο κάτοικος Θεσσαλονίκης το 2019 ζει

$A_3$ : ο κάτοικος Ρόδου το 2019 ζει.

Ζητάμε την πιθανότητα του ενδεχομένου

$$E = (A_1' A_2 A_3) \cup (A_1 A_2' A_3) \cup (A_1 A_2 A_3')$$

το οποίο είναι ένωση ξένων ανά δύο ενδεχομένων και επομένως

$$P(E) = P(A_1' A_2 A_3) + P(A_1 A_2' A_3) + P(A_1 A_2 A_3').$$

Επειδή δεν έχουμε κάποιο λόγο να πιστεύουμε ότι τα ενδεχόμενα  $A_1$ ,  $A_2$  και  $A_3$  δεν είναι ανεξάρτητα και επειδή οι πιθανότητες των τομών ανεξάρτητων ενδεχομένων εκφράζονται ως γινόμενα πιθανοτήτων, έχουμε

$$\begin{aligned} P(E) &= P(A_1')P(A_2)P(A_3) + P(A_1)P(A_2')P(A_3) + P(A_1)P(A_2)P(A_3') = \\ &= 0.4 \cdot 0.9 \cdot 0.3 + 0.6 \cdot 0.1 \cdot 0.3 + 0.6 \cdot 0.9 \cdot 0.7 = 0.504. \end{aligned}$$

αυτά, καθώς και η έκβαση οποιασδήποτε ομάδας από αυτά, δεν επηρεάζει την έκβαση των υπολοίπων. Έτσι, αν τα  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_r$  είναι ανεξάρτητα πειράματα, τότε για οποιαδήποτε ενδεχόμενα

$$A_1 \subseteq \Omega_1, A_2 \subseteq \Omega_2, \dots, A_r \subseteq \Omega_r,$$

όπου καθένα σχετίζεται μόνο με το αντίστοιχο πείραμα  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_r$ , ορίζουμε

$$P(A_1 A_2 \dots A_r) = P(A_1)P(A_2) \dots P(A_r).$$

Με  $A_1 A_2 \dots A_r$  συμβολίζουμε το ενδεχόμενο  $A_1 \times A_2 \times \dots \times A_r$  του δειγματικού χώρου  $\Omega_1 \times \Omega_2 \times \dots \times \Omega_r$  του σύνθετου πειράματος, δηλαδή, συμβολίζουμε το ενδεχόμενο το οποίο πραγματοποιείται όταν, κατά την εκτέλεση του πειράματος  $\varepsilon_1$  πραγματοποιηθεί το  $A_1$ , κατά την εκτέλεση του πειράματος  $\varepsilon_2$  πραγματοποιηθεί το  $A_2$ , ..., και κατά την εκτέλεση του πειράματος  $\varepsilon_r$  πραγματοποιηθεί το  $A_r$ .

#### Παράδειγμα 4.5.7.

Έστω το πείραμα  $\varepsilon$ : «ρίχνω ένα νόμισμα δύο φορές και στη συνέχεια ένα ζάρι». Προφανώς το πείραμα αυτό αναλύεται στα πειράματα

$\varepsilon_1$ : «ρίχνω ένα νόμισμα» με δειγματικό χώρο  $\Omega_1 = \{\kappa, \gamma\}$ .

$\varepsilon_2$ : «ρίχνω ένα νόμισμα» με δειγματικό χώρο  $\Omega_2 = \{\kappa, \gamma\}$  και

$\varepsilon_3$ : «ρίχνω ένα ζάρι» με δειγματικό χώρο  $\Omega_3 = \{1, 2, 3, 4, 5, 6\}$ .

Ο δειγματικός χώρος  $\Omega$  του (σύνθετου) πειράματος  $\varepsilon$ , προφανώς αποτελείται από όλες τις δυνατές διατεταγμένες τριάδες  $\alpha_1 \alpha_2 \alpha_3$ , όπου  $\alpha_i \in \{\kappa, \gamma\}$  για  $i = 1, 2$  και  $\alpha_3 \in \{1, 2, 3, 4, 5, 6\}$  δηλαδή,  $\Omega = \Omega_1 \times \Omega_2 \times \Omega_3$ . Πρόκειται για πεπερασμένο δειγματικό χώρο με  $N(\Omega) = 24$  (σκεφθείτε γιατί). Πράγματι

$$\Omega = \{\kappa\kappa 1, \kappa\kappa 2, \kappa\kappa 3, \kappa\kappa 4, \kappa\kappa 5, \kappa\kappa 6, \kappa\gamma 1, \kappa\gamma 2, \kappa\gamma 3, \kappa\gamma 4, \kappa\gamma 5, \kappa\gamma 6, \gamma\kappa 1, \gamma\kappa 2, \gamma\kappa 3, \gamma\kappa 4, \gamma\kappa 5, \gamma\kappa 6, \gamma\gamma 1, \gamma\gamma 2, \gamma\gamma 3, \gamma\gamma 4, \gamma\gamma 5, \gamma\gamma 6\}.$$

Έτσι, αν θεωρήσουμε τρία ενδεχόμενα  $A_1 \subseteq \Omega_1, A_2 \subseteq \Omega_2$  και  $A_3 \subseteq \Omega_3$ , έστω για παράδειγμα, τα ενδεχόμενα

$$A_1 = \{\kappa\}, A_2 = \{\gamma\} \text{ και } A_3 = \{1, 3, 5\} \text{ τότε } A_1 A_2 A_3 = \{\kappa\gamma 1, \kappa\gamma 3, \kappa\gamma 5\}$$

και είναι προφανές ότι το ενδεχόμενο  $A_1 A_2 A_3$  του  $\Omega = \Omega_1 \times \Omega_2 \times \Omega_3$  πραγματοποιείται όταν κατά την εκτέλεση του πειράματος  $\varepsilon_1$  εμφανισθεί «κεφαλή», κατά την εκτέλεση του πειράματος  $\varepsilon_2$  εμφανισθεί «γράμματα» και κατά την εκτέλεση του πειράματος  $\varepsilon_3$  εμφανισθεί περιττός αριθμός. Με την παραδοχή ότι το νόμισμα και το ζάρι είναι αμερόληπτα προφανώς έχουμε

$$P(A_1 A_2 A_3) = \frac{3}{24} = \frac{1}{8}, \quad P(A_1) = \frac{1}{2}, \quad P(A_2) = \frac{1}{2} \text{ και } P(A_3) = \frac{3}{6} = \frac{1}{2}.$$

Παρατηρήστε ότι για τα  $A_1 = \{\kappa\}, A_2 = \{\gamma\}$  και  $A_3 = \{1, 3, 5\}$  η σχέση  $P(A_1 A_2 A_3) = P(A_1)P(A_2)P(A_3)$  επαληθεύεται. Εύκολα επίσης μπορείτε

να δείξετε ότι η συνθήκη ανεξαρτησίας επαληθεύεται για οποιαδήποτε ενδεχόμενα των  $\Omega_1$ ,  $\Omega_2$  και  $\Omega_3$ . Το ότι τα  $\varepsilon_1$ ,  $\varepsilon_2$  και  $\varepsilon_3$  είναι ανεξάρτητα, είναι βέβαια προφανές αφού η έκβαση οποιονδήποτε από αυτά ή η έκβαση οποιονδήποτε δύο από αυτά δεν είναι λογικό να δεχθούμε ότι επηρεάζει την έκβαση των υπολοίπων.

Σε πρακτικές εφαρμογές, την ανεξαρτησία πειραμάτων συνήθως την ελέγχουμε με την εξέταση και τον έλεγχο των συνθηκών κάτω από τις οποίες αυτά εκτελούνται. Αυτό μας δίνει τη δυνατότητα, όταν διαπιστώνουμε ότι τα πειράματα είναι ανεξάρτητα, να μπορούμε να αξιοποιούμε (για τον υπολογισμό πιθανοτήτων) τη σχέση

$$P(A_1 A_2 \dots A_n) = P(A_1)P(A_2) \dots P(A_n).$$

Βέβαια, ο έλεγχος υποθέσεων και παραδοχών, όπως αυτός της ανεξαρτησίας, αποτελεί όπως θα δούμε στο Β' Μέρος, αντικείμενο της στατιστικής συμπερασματολογίας. Σημειώνουμε επίσης, ότι δεν γράφονται όλα τα ενδεχόμενα του δειγματικού χώρου  $\Omega_1 \times \Omega_2 \times \dots \times \Omega_n$  ως καρτεσιανά γινόμενα. Για το πώς υπολογίζουμε πιθανότητες τέτοιων ενδεχομένων όπως και για άλλα θέματα που τίθενται για τους «χώρους-γινόμενα» δε θα επεκταθούμε.

Εάν τα  $n$  πειράματα στα οποία αναλύεται ένα σύνθετο πείραμα είναι ανεξάρτητες επαναλήψεις του ίδιου πειράματος τότε λέμε ότι το πείραμα αποτελείται από  $n$  ανεξάρτητες δοκιμές ή ότι πρόκειται για μια σειρά ή ακολουθία  $n$  ανεξάρτητων δοκιμών ή για  $n$  επαναλαμβανόμενες ανεξάρτητες δοκιμές (*repeated independent trials*).

Όπως αναφέραμε στο προηγούμενο κεφάλαιο (δες Παράδειγμα 3.1.1α,δ), ένα πείραμα τύχης με δύο μόνο δυνατά αποτελέσματα (αμοιβαίως αποκλειόμενα) ονομάζεται *δοκιμή Bernoulli*. Το ένα αποτέλεσμα έχει επικρατήσει να ονομάζεται «επιτυχία» και το άλλο «αποτυχία». Έτσι, αν ένα πείραμα αναλύεται σε διαδοχικές ανεξάρτητες επαναλήψεις ενός πειράματος με δύο μόνο δυνατά αποτελέσματα, λέμε ότι το πείραμα αποτελείται από  $n$  ανεξάρτητες δοκιμές *Bernoulli* ή από μια σειρά ή ακολουθία  $n$  ανεξάρτητων δοκιμών *Bernoulli*. Για παράδειγμα, η ρήψη ενός νομίσματος 10 φορές είναι ένα τυχαίο πείραμα που αναλύεται σε 10 ανεξάρτητες δοκιμές *Bernoulli*.

Αν συμβολίσουμε με «ε» το αποτέλεσμα «επιτυχία» και με «α» το αποτέλεσμα «αποτυχία» μιας δοκιμής *Bernoulli*, είναι προφανές (δες και Παράδειγμα 3.1.1δ), ότι τα στοιχεία του δειγματικού χώρου ενός πειράματος που αποτελείται από  $n$  ανεξάρτητες δοκιμές *Bernoulli*, είναι διατεταγμένες  $n$ -άδες από «επιτυχίες» και «αποτυχίες» δηλαδή έχουν τη μορφή  $\underbrace{\text{αεεαε} \dots \text{εαε}}_{n \text{ το πλήθος}}$ .

Σημείωση 1.5.2.

Στη συνέχεια, όταν θα μιλήσουμε για κατανομές τυχαίων μεταβλητών, θα διαπιστώσουμε ότι οι διαδοχικές ανεξάρτητες δοκιμές *Bernoulli* εμφανίζονται στην περιγραφή και την κατασκευή πολλών μοντέλων πιθανοτήτων με ευρύτατο φάσμα εφαρμογών. Προς το παρόν, ας δούμε μια ενδιαφέρουσα πρόταση ιδιαίτερος χρήσιμη για τη συνέχεια, όταν θα μιλήσουμε για μοντέλα πιθανοτήτων.

- Πρόταση 4.5.2. Αν ένα πείραμα τύχης αποτελείται από  $n$  ανεξάρτητες δοκιμές *Bernoulli* όπου η πιθανότητα επιτυχίας σε κάθε μια δοκιμή είναι ίση με  $p$ , τότε η πιθανότητα, στις  $n$  δοκιμές
- (α) να εμφανισθούν  $n$  «επιτυχίες» είναι ίση με  $p^n$
  - (β) να μην εμφανισθεί «επιτυχία» είναι ίση με  $(1-p)^n$
  - (γ) να εμφανισθεί τουλάχιστον μια «επιτυχία» είναι ίση με  $1 - (1-p)^n$
  - (δ) να εμφανισθούν ακριβώς  $r$  «επιτυχίες» είναι ίση με  $\binom{n}{r} p^r (1-p)^{n-r}$ .

Απόδειξη: Έστω τα ενδεχόμενα

$A_i, i = 1, 2, \dots, n$ : στην  $i$  δοκιμή εμφανίζεται «επιτυχία».

- (α) Ζητάμε την πιθανότητα του ενδεχομένου  $A_1 A_2 \dots A_n$ .  
Από την ανεξαρτησία των δοκιμών προφανώς έχουμε

$$P(A_1 A_2 \dots A_n) = P(A_1) P(A_2) \dots P(A_n) = p \cdot p \cdot \dots \cdot p = p^n.$$

- (β) Ζητάμε την πιθανότητα του ενδεχομένου  $A'_1 A'_2 \dots A'_n$ .  
Από την ανεξαρτησία των δοκιμών προφανώς έχουμε

$$\begin{aligned} P(A'_1 A'_2 \dots A'_n) &= P(A'_1) P(A'_2) \dots P(A'_n) = \\ &= (1-p) \cdot (1-p) \cdot \dots \cdot (1-p) = (1-p)^n. \end{aligned}$$

- (γ) Ζητάμε την πιθανότητα του συμπληρώματος του ενδεχομένου  $A'_1 A'_2 \dots A'_n$ .

Προφανώς η ζητούμενη πιθανότητα είναι

$$1 - (1-p)^n.$$

- (δ) Ο δειγματικός χώρος του πειράματος αποτελείται όπως είδαμε από διατεταγμένες  $n$ -άδες της μορφής  $\underbrace{αεεαε \dots εαε}_{n \text{ το πλήθος}}$ .

Ζητάμε την πιθανότητα του ενδεχομένου που αποτελείται από εκείνες τις διατεταγμένες  $n$ -άδες αυτής της μορφής, που περιέχουν  $r$  (ακριβώς) το πλήθος «ε» και  $n-r$  το πλήθος «α».

Όπως δείξαμε στο Παράδειγμα 3.1.1δ, το πλήθος αυτών των διατεταγμένων  $n$ -άδων είναι

$$\frac{n!}{r! \cdot (n-r)!} = \binom{n}{r}.$$

Δηλαδή, το ενδεχόμενο του οποίου ζητάμε την πιθανότητα αποτελείται από

$$\binom{v}{r}$$

$v$ -άδες που περιέχουν  $r$  (ακριβώς) το πλήθος «ε» και  $v - r$  το πλήθος «α». Η πιθανότητα εμφάνισης κάθε μιας τέτοιας  $v$ -άδας είναι, λόγω της ανεξαρτησίας των δοκιμών, προφανώς ίση με  $p^r(1 - p)^{v-r}$  και επομένως η ζητούμενη πιθανότητα είναι πράγματι ίση με

$$\binom{v}{r} p^r (1 - p)^{v-r}.$$

Ολοκληρώνουμε με μια ακόμη κατηγορία πειραμάτων που, όπως θα διαπιστώσουμε στο Β' Μέρος, συναντάται σε μεγάλο φάσμα εφαρμογών. Πρόκειται για τις *πολωννυμικές δοκιμές (multinomial trials)*.

Η *δοκιμή Bernoulli*, όπως είδαμε, είναι ένα πείραμα με δύο μόνο (αμοιβαίως αποκλειόμενα) δυνατά αποτελέσματα,  $\varepsilon$  και  $\alpha$  («επιτυχία» και «αποτυχία», αντίστοιχα). Αν ένα πείραμα έχει  $k$  (αμοιβαίως αποκλειόμενα) δυνατά αποτελέσματα,  $r_1, r_2, \dots, r_k$ , ονομάζεται *πολωννυμική δοκιμή*.

Είναι προφανές ότι η πολωννυμική δοκιμή αποτελεί γενίκευση, μάλιστα εύλογη, της *δοκιμής Bernoulli* (μια *δοκιμή Bernoulli* είναι μια *πολωννυμική δοκιμή* με  $k = 2$  δυνατά αποτελέσματα). Έτσι, ενώ για παράδειγμα, η εξέταση ενός ατόμου για να διαπιστωθεί αν έχει ή δεν έχει προσβληθεί από ένα συγκεκριμένο ιό είναι μια *δοκιμή Bernoulli*, η εξέταση ενός ατόμου για να διαπιστωθεί η ομάδα αίματός του είναι μια *πολωννυμική δοκιμή* με  $k = 4$  δυνατά αποτελέσματα (Α, Β, ΑΒ και Ο). Επίσης, η υποβολή ερώτησης σε ένα άτομο για το αν συμφωνεί, διαφωνεί ή το αφήνει αδιάφορο μια συγκεκριμένη άποψη, είναι μια *πολωννυμική δοκιμή* με  $k = 3$  δυνατά αποτελέσματα όπως και ο έλεγχος ενός ελαττωματικού προϊόντος για να διαπιστωθεί από ποια από τις πέντε γραμμές παραγωγής παρήχθη είναι μια *πολωννυμική δοκιμή* με  $k = 5$  δυνατά αποτελέσματα.

Αν ένα πείραμα τύχης αποτελείται από  $v$  ανεξάρτητες πολωννυμικές δοκιμές, όπου σε κάθε δοκιμή τα δυνατά αποτελέσματα είναι  $k$ , έστω  $r_1, r_2, \dots, r_k$ , και η πιθανότητα να εμφανισθεί το αποτέλεσμα  $r_i$  σε μια (οποιαδήποτε) δοκιμή είναι  $p_i$ , τότε η πιθανότητα, στις  $v$  δοκιμές, να εμφανισθούν  $v_1$  αποτελέσματα  $r_1, v_2$  αποτελέσματα  $r_2, \dots$  και  $v_k$  αποτελέσματα  $r_k$  είναι ίση με

Πρόταση 4.5.3.

όπου

$$\frac{v!}{v_1! \cdot v_2! \cdot \dots \cdot v_k!} p_1^{v_1} p_2^{v_2} \dots p_k^{v_k},$$

$$\sum_{i=1}^k v_i = v \text{ και } \sum_{i=1}^k p_i = 1.$$

Όπως θα διαπιστώσουμε όταν θα μιλήσουμε για τους στατιστικούς ελέγχους  $\chi^2$ , πρόκειται για ένα πολύ χρήσιμο αποτέλεσμα. Την απόδειξη δείτε την ως μια απλή άσκηση (αποτελεί πολύ απλή (ευθεία) γενίκευση της απόδειξης της Πρότασης 4.5.2δ).