

ΑΝΑΓΚΑΙΑΙ ΚΑΙ ΙΚΑΝΑΙ ΣΥΝΘΗΚΑΙ ΔΙΑ ΤΗΝ ΙΣΧΥΝ
ΒΑΣΙΚΩΝ ΤΙΝΩΝ ΙΔΙΟΤΗΤΩΝ ΤΟΥ ΔΕΙΚΤΟΥ
Π Ρ Ο Σ Δ Ι Ο Ρ Ι Σ Μ Ο Υ

Τοῦ κ. ΔΗΜΗΤΡΙΟΥ ΑΘΑΝΑΣΟΠΟΥΛΟΥ

Ἐκτ. Καθηγητοῦ τῆς Α.Β.Σ.Π.

Ὁ δείκτης προσδιορισμοῦ R^2 ἀποτελεῖ ὡς γνωστὸν ἓν στατιστικὸν μέτρον τὸ ὁποῖον χρησιμοποιεῖται κατὰ τὴν μελέτην τοῦ τρόπου ἀ λ λ η λ ε ξ α ρ τ ῆ σ ε ω ς δύο (ἢ περισσοτέρων) μεταβλητῶν (X, Y) καὶ — μεταξὺ ἄλλων — χαρακτηρίζει τὸν βαθμὸν προσαρμογῆς πρὸς τὰ ὑφιστάμενα δεδομένα — δηλαδὴ τὰ ζεύγη τῶν ἀριθμητικῶν τιμῶν (x_i, y_i) , $i = 1, 2, \dots, N$ ἢ τὸ ἀντίστοιχον «σημειακὸν νέφος» — μιᾶς καμπύλης (ἢ μιᾶς ἐπιφανείας) παλινδρομήσεως.

Ἡ κατανόησις τῆς σημασίας καὶ ἡ ἐρμηνεία τοῦ δείκτου R^2 , ἰδιαιτέρως δὲ ἡ πρακτικὴ χρησιμότης αὐτοῦ, βασίζονται ἐν γένει ἐπὶ ὠρισμένων ἰδιοτήτων τοῦ ἐν λόγῳ μέτρου καὶ συγκεκριμένως εἰς τὸ ὅτι ὁ δείκτης R^2 εἶναι κ α θ α ρ ὶ ς — ἄνευ μονάδων μετρήσεως — ἀριθμὸς ὁ ὁποῖος

(α) λαμβάνει τιμὰς εἰς τὸ κλειστὸν διάστημα $[0, 1]$, πληροῖ δηλαδὴ τὴν διπλῆν ἀνισότητα $0 \leq R^2 \leq 1$, καὶ

(β) εἶναι ἀνεξάρτητος τῶν χρησιμοποιουμένων κατὰ περίπτωσιν μονάδων μετρήσεως.

Αἱ ἀνωτέρω ὁμοῦς ιδιότητες, παρ' ὅτι εἰς τὴν πρᾶξιν θεωροῦνται κατὰ κανόνα ὡς ἀπορρέουσαι ἐκ τοῦ τρόπου ὀρισμοῦ τοῦ ἐν λόγῳ δείκτου καὶ κατὰ συνέπειαν ὡς αὐταπόδεκτοι καὶ γενικῶς ἀληθεῖς, ἰσχύουν, ὡς θὰ ἴδωμεν κατωτέρω, μ ὄ ν ο ν ὑ π ὸ ὠ ρ ἰ σ μ ῆ ν α ς — συγκεκριμέναν ἐκάστοτε — συνθήκας καὶ ὡς ἐκ τούτου εἰς πολλὰς περιπτώσεις εἶναι δυνατόν νὰ μὴ ἀληθεύουν.

Σκοπὸς τοῦ παρόντος ἄρθρου εἶναι ἡ διατύπωσις καὶ ἀπόδειξις τῶν ἐν λόγῳ συνθηκῶν — ἀναγκαίων καὶ ἰκανῶν διὰ τὴν ἰσχὺν τῶν ὡς ἄνω βασικῶν ἰδιοτήτων τοῦ δείκτου R^2 — ὡς καὶ ἡ διερεύνησις τῆς πρακτικῆς σημασίας αὐτῶν εἰς τὰς καθ' ἑκάστα ἐφαρμογὰς.

Κατὰ τὴν παρουσίαισιν τῶν σχετικῶν ἀποτελεσμάτων ἀναφερόμεθα κατὰ βάσιν — διὰ λόγους ἀπλότητος καὶ συντομίας — εἰς διμεταβλητοῦς στατιστικοῦς

πληθυσμούς και αντίστοιχως εἰς τὴν χρῆσιν τοῦ δείκτου R^2 ὡς μέτρου τοῦ βαθμοῦ προσαρμογῆς μιᾶς καμπύλης παλινδρομήσεως. Ἐξ ὧτων ὁμοῦ ἀκολουθοῦν καθίσταται προφανές ὅτι ἡ γενίκευσις τῶν ἐν λόγῳ ἀποτελεσμάτων καὶ ἡ ἐφαρμογή αὐτῶν εἰς περιπτώσεις πολυμεταβλητῶν πληθυσμῶν καὶ τῶν προσαρμοζομένων ἀντιστοίχως ἐπιφανέων παλινδρομήσεως εἶναι ἄμεσος καὶ ἀπλῆ.

I. Δείκτης προσδιορισμοῦ ἢ προσαρμογῆς μιᾶς καμπύλης παλινδρομήσεως

ὑποθέσωμεν ὅτι προκειμένου νὰ μελετηθῇ ὁ τρόπος ἀλληλεξαρτήσεως καὶ ὁ βαθμὸς συνάφειας, δύο μεταβλητῶν (X, Y) καὶ εἰδικότερον νὰ περιγραφῆ ἀπλᾶ καὶ συνοπτικὰ ἡ νομοτέλεια ἢ ὁποία διέπει ἐν γένει τὴν διαμόρφωσιν τῶν τιμῶν τῆς μιᾶς — καλουμένης ἐν προκειμένῳ ἐξηρητημένης μεταβλητῆς — ἐν σχέσει πρὸς τὴν διαμόρφωσιν τῶν τιμῶν τῆς ἄλλης — θεωρουμένης ἀντιστοίχως ὡς ἀνεξαρτήτου ἢ ἐπεξηγηματικῆς μεταβλητῆς — ἀποφασίζεται ὑπὸ τοῦ μελετητοῦ ἢ προσαρμογῆ πρὸς τὰ ἐμπειρικὰ δεδομένα — τὰ ζεύγη δηλαδὴ (x_i, y_i) , $i=1, 2, \dots, N$ τῶν τιμῶν τῶν ἐν λόγῳ μεταβλητῶν τὰ ὁποῖα ἀντιστοιχοῦν εἰς τὰς N ἐπι μέρους μονάδας τοῦ ὑπὸ ἔρευναν πληθυσμοῦ ἢ καλλίτερον τὰ σημεῖα τοῦ ἀντιστοίχου στικτοῦ διαγράμματος — μιᾶς ἀπλῆς ἐξίσωσως ἢ ἄλλως μιᾶς καμπύλης παλινδρομήσεως τῆς μορφῆς *

$$y = f(x, \alpha, \beta) \quad (1)$$

διὰ τῆς ὁποίας — πέραν τῶν ἄλλων — νὰ καθορίζεται μία συγκεκριμένη ποσοτική διαδικασία ἐπιτρέπουσα ἐκ τῶν τιμῶν τῆς ἀνεξαρτήτου μεταβλητῆς X νὰ ὑπολογίζωνται μὲ ὅσον τὸ δυνατόν καλλιτέραν πρὸσέγγισιν αἰ ἀντίστοιχοι τιμαὶ τῆς ἐξηρητημένης τοιαύτης Y .

Ὁ προσδιορισμὸς — τῇ βοήθειᾳ πάντοτε τῶν δεδομένων τῆς παρατηρήσεως (x_i, y_i) , $i=1, 2, \dots, N$ — τῶν παραμέτρων α καὶ β τῆς ἐξίσωσως (1), ἐν ἄλλοις δηλαδὴ λόγοις ἡ ἐπιλογή μεταξὺ τῶν μελῶν τῆς ἐν λόγῳ οἰκογενείας καμπύλων μιᾶς συγκεκριμένης καμπύλης ἢ ὁποία νὰ διέρχεται ὅσον τὸ δυνατόν «ἐγγύτερον» ἐκ τῶν σημείων (x_i, y_i) , $i=1, 2, \dots, N$ — συνοψίζουσα οὕτω κατὰ τὸν καλλίτερον ἐν προκειμένῳ δυνατόν τρόπον τὸ ἀντίστοιχον σημεῖα κόν νέφος — γίνεται, ὡς γνωστὸν διὰ τῆς μεθόδου τῶν Ἐλαχίστων Τετραγῶνων. Συγκεκριμένως, αἰ ζητούμεναι τιμαὶ α καὶ β τῶν ὑπὸ προσδιορισμὸν παραμέτρων α καὶ β εὐρίσκονται δι' ἐπιλύσεως τοῦ συστήματος

$$\begin{aligned} \frac{\partial}{\partial \alpha} \sum_{i=1}^N [y_i - f(x_i, \alpha, \beta)]^2 &= 0 \\ \frac{\partial}{\partial \beta} \sum_{i=1}^N [y_i - f(x_i, \alpha, \beta)]^2 &= 0 \end{aligned} \quad (2)$$

* Ἡ ἐξίσωσις (1) εἶναι δυνατόν νὰ περιλαμβάνῃ τρεῖς ἢ καὶ περισσοτέρας ἀκόμη παραμέτρους α, β, \dots

γνωστού ὡς συστήματος τῶν κανονικῶν ἐξισώσεων, ἢ συγκεκριμένη δὲ καμπύλη — μέλος τῆς οἰκογενείας (1) — ἢ ὅποια ἀντιστοιχεῖ εἰς τὰς οὕτω ὑπολογιζομένας τιμὰς $\hat{\alpha}$ καὶ $\hat{\beta}$, συμβολιζομένη ὑπὸ τῆς ἐξισώσεως

$$\hat{y} = f(x, \hat{\alpha}, \hat{\beta}) \quad (3)$$

ἀποτελεῖ τὴν ζητούμενην καμπύλην παλινδρομῆσεως.

Ὁ βαθμὸς προσαρμογῆς τῆς οὕτω προσδιοριζομένης καμπύλης παλινδρομῆσεως, δηλαδὴ τὸ πόσον ἱκανοποιητικὴ εἶναι ἡ προσέγγισις μετὰ τὴν ὁποίαν ἡ ἐν λόγῳ καμπύλη συνοψίζει τὰ δεδομένα τῆς παρατηρήσεως καὶ κατὰ συνέπειαν τὸ «πόσον καλά» περιγράφει αὕτη τὸν τρόπον ἀλληλεξαρτήσεως τῶν συνεξεταζομένων μεταβλητῶν, ὡς καὶ ἡ ἀκρίβεια τῶν δι' αὐτῆς ἐξαγομένων συμπερασμάτων, χαρακτηρίζονται ὡς γνωστὸν ὑπὸ τοῦ Δείκτου Προσδιορισμοῦ ἢ ἄλλως Δείκτου Προσαρμογῆς τῆς καμπύλης ταύτης, ὁ ὁποῖος ὀρίζεται ἐκ τῆς σχέσεως:

$$R^2 = 1 - \frac{\sigma^2}{\sigma_y^2} \quad (4)$$

ὅπου σ^2 καὶ σ_y^2 συμβολίζουν ἀντιστοίχως τὸ καλούμενον μέσον τετραγώνικόν σφάλμα περὶ τὴν καμπύλην παλινδρομῆσεως καὶ τὴν — συνολικὴν — διακύμανσιν — τῶν τιμῶν — τῆς μεταβλητῆς Y καὶ ὀρίζονται ἐκ τῶν σχέσεων

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N [y_i - f(x_i, \hat{\alpha}, \hat{\beta})]^2 \quad (5)$$

καὶ

$$\sigma_y^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \mu_y)^2 \quad (6)$$

τοῦ μ_y συμβολίζοντος τὸν μέσον ἀριθμητικὸν — τῶν παρατηρηθεισῶν τιμῶν — τῆς Y.

Ἡ σημασία τοῦ δείκτου R^2 ὡς μέτρου τοῦ βαθμοῦ προσαρμογῆς τῆς προσδιοριζομένης κατὰ περίπτωσιν καμπύλης παλινδρομῆσεως καὶ εἰδικώτερον

(i) ἡ ἀξιολόγησις τῆς ἀριθμητικῆς τιμῆς αὐτοῦ καὶ ἡ ἐξαγωγή συμπερασμάτων ἀναφορικῶς πρὸς τὴν προσέγγισιν μετὰ τὴν ὁποίαν ὠρισμένη καμπύλη συνοψίζει τὰ δεδομένα τῆς παρατηρήσεως ἢ ἄλλως «πόσον καλά» περιγράφει αὕτη τὸν τρόπον ἀλληλεξαρτήσεως τῶν συνεξεταζομένων μεταβλητῶν, καὶ

(ii) ἡ σύγκρισις τῶν τιμῶν δύο ἢ περισσοτέρων τοιοῦτων δεικτῶν — ἀναφερομένων εἰς διαφόρους καμπύλας — πρὸς ἐπιλογὴν τῆς καταλληλοτέρας ἐκάστοτε μορφῆς τῆς καμπύλης παλινδρομῆσεως βασιζόνται, ὡς ἤδη ἐλέγχθη, ἐπὶ τῶν ἀναφερομένων ἀνωτέρω ἰδιοτήτων του. Ἡ διερεύνησις τῶν ἐν λόγῳ ἰδιοτήτων καὶ ἰδιαιτέρως αἱ συνθήκαι διὰ τὴν ἰσχὺν

αὐτῶν εἰς τὰς καθ' ἑκάστα ἐφαρμογὰς θὰ μᾶς ἀπασχολήσουν λεπτομερῶς ἀμέσως κατωτέρω.

II. Βασικαὶ ιδιότητες τοῦ δείκτη προσδιορισμοῦ

1η Ἰδιότης: «Ὁ δείκτης προσδιορισμοῦ R^2 εἶναι ἀριθμὸς $\kappa \alpha \theta \alpha \rho \acute{o} \varsigma$ — ἄνευ μονάδων μετρήσεως — καὶ συνεπῶς πάντοτε $\sigma \upsilon \gamma \kappa \rho \iota \sigma \iota \mu \omicron \varsigma$ ».

Ἡ ἀπόδειξις τῆς ἐν λόγῳ ιδιότητος — ἰσχυοῦσης $\acute{\alpha} \nu \epsilon \upsilon \sigma \upsilon \nu \theta \eta \kappa \acute{\omega} \nu$ — εἶναι ἀπλουστάτη. Πράγματι, τὸσον τὸ μέσον τετραγωνικὸν σφάλμα σ^2 ὑπολογιζόμενον ἐκ τοῦ τύπου (5), ὅσον καὶ ἡ διακύμανσις τῆς μεταβλητῆς Y — τύπος (6) — ἐκφράζονται εἰς τὰς μονάδας μετρήσεως — τετραγωνισμένας — τῆς ἐξηρητημένης μεταβλητῆς Y καὶ κατὰ συνέπειαν ὁ λόγος αὐτῶν $\sigma^2 : \sigma_y^2$ ὡς καὶ ὁ δείκτης R^2 — ὀριζόμενος ἐκ τοῦ τύπου (4) — εἶναι ἀριθμοὶ καθαροί.

Ἡ πρακτικὴ χρησιμότης τῆς ἐν λόγῳ ιδιότητος συνίσταται, ὡς εἶναι εὐνόητον, εἰς τὸ ὅτι δι' αὐτῆς καθίσταται δυνατὴ ἡ σύγκρισις τιμῶν τοῦ δείκτη R^2 αἱ ὁποῖαι ἀναφέρονται εἰς διαφόρους διμεταβλητοὺς στατιστικὸς πληθυσμοὺς ἢ ἄλλως εἰς μεταβλητὰς ἐκφραζόμενας εἰς διαφόρους μονάδας μετρήσεως, πρᾶγμα τὸ ὁποῖον εἶναι, ὡς γνωστόν, ἀνέφικτον διὰ τὰ ἀντίστοιχα μέσα τετραγωνικὰ σφάλματα.

2α Ἰδιότης: «Ὁ δείκτης R^2 λαμβάνει τιμὰς εἰς τὸ κλειστὸν διάστημα $[0, 1]$, πληροὶ δηλαδὴ τὴν διπλὴν ἀνισότητα

$$0 < R^2 \leq 1 \quad (7)$$

καὶ ὡς ἐκ τούτου ἡ ἀξιολόγησις τῶν τιμῶν αὐτοῦ καθίσταται ἀπλῆ καὶ ἀντικειμενικῆ».

Συγκεκριμένως, ὡς θὰ ἀποδείξωμεν κατωτέρω, ἡ ἰσότης $R^2 = 1$ λαμβάνει χώραν ἔαν — καὶ μόνον ἔαν — μεταξὺ τῶν συνεξεταζομένων μεταβλητῶν (X, Y) ὑφίσταται $\sigma \upsilon \nu \alpha \rho \tau \eta \sigma \iota \alpha \kappa \eta$ σχέσις τῆς μορφῆς (1) ἐν ἄλλοις δηλαδὴ λόγοις ἔαν ἢ κατὰ τὰ ὡς ἄνω προσδιοριζομένη καμπύλη παλινδρομήσεως (3) διέρχεται δι' ὄλων τῶν σημείων $(x_i, y_i), i = 1, 2, \dots, N$ — π λ ῆ ρ η ς προσαρμογῆ — καὶ πεγράφει τὴν ὑφισταμένην μεταξὺ τῶν ἐν λόγῳ μεταβλητῶν σχέσιν κατὰ τρόπον ὥστε ἐκ τῶν τιμῶν τῆς ἀνεξαρτήτου μεταβλητῆς X νὰ ὑπολογίζονται αἱ ἀντίστοιχοι τιμαὶ τῆς ἐξηρητημένης τοιαύτης Y μὲ ἀπόλυτον ἀκρίβειαν (ἄνευ σφάλματος).

Ἐξ ἄλλου — ὡς θὰ ἀποδειχθῆ ἐπίσης — ὁ δείκτης R^2 λαμβάνει τὴν τιμὴν μηδὲν ($R^2 = 0$), ἔαν — καὶ μόνον ἔαν — ἡ διὰ τῆς μεθόδου τῶν ἐλαχίστων τετραγώνων ἐπιλεγομένη γραμμὴ παλινδρομήσεως εἶναι ἡ παράλληλος πρὸς τὸν ἄξονα τῶν x εὐθεῖα

$$\hat{y} = \mu_y = \frac{1}{N} \sum_{i=1}^N y_i \quad (8)$$

ἐν ἄλλοις δηλαδὴ λόγοις ἔαν ἡ διαμόρφωσις τῶν τιμῶν τῆς Y οὐδόλως ἐπηρρεά-

ζεται ή σχετίζεται πρὸς τὴν διαμόρφωσιν τῶν τιμῶν τῆς X , ἤτοι εἰς τὴν περίπτωσιν μὴ συσχετισμένων — στατιστικῶς — μεταβλητῶν.

Ἐξυπακούεται ἐκ τῶν ἀνωτέρω ὅτι εἰς πᾶσαν ἄλλην περίπτωσιν ἢ τιμῆ τοῦ R^2 εὐρίσκεται μεταξύ 0 καὶ 1, πλησιάζει δὲ πρὸς τὸ 1 ὅσον ἐντονωτέρα εἶναι ἢ μεταξύ τῶν ἐν λόγῳ μεταβλητῶν συνάφεια καὶ ἡ μορφή τῶν καμπύλων τῆς οἰκογενείας (1), καταλληλοτέρα διὰ τὴν περιγραφὴν τῆς ἀντιστοίχου μεταξύ αὐτῶν σχέσεως.

Ἡ ἀπόδειξις καὶ τῆς παρουσίας ιδιότητος εἶναι κατὰ τὸ μᾶλλον ἢ ἥττον ἀπλῆ. Ἀντιθέτως ὁμοῦ πρὸς τὴν προηγουμένην τοιαύτην ἢ ἐν λόγῳ ιδιότητος δὲ ν εἶναι καθολικῆς ἰσχύος, ἀληθεύει δὲ μόνον ὑπὸ τὴν ἐξῆς προϋπόθεσιν (συνθήκην):

«Ἡ οἰκογένεια τῶν καμπύλων $y=f(x, \alpha, \beta)$ μεταξύ τῶν μελῶν τῆς ὁποίας ἀναζητεῖται — διὰ τῆς μεθόδου τῶν ἐλαχίστων τετραγώνων — ἢ συγκεκριμένη καμπύλη παλινδρομήσεως $\hat{y} = f(\hat{x}, \hat{\alpha}, \hat{\beta})$ δέον νὰ περιλαμβάνῃ ὡς μέλη αὐτῆς ἀπάσας τὰς παραλλήλους πρὸς τὸν ἄξονα τῶν x εὐθείας, ἐν ἄλλοις δηλαδὴ λόγοις ἢ ἐξίσωσις $y = f(x, \alpha, \beta)$ νὰ δύναται διὰ καταλλήλους τιμὰς τῶν παραμέτρων α καὶ β νὰ λάβῃ τὴν μορφήν $y = c$ ὅπου c μία αὐθαίρετος σταθερά».

Ὑπὸ τὴν ἀνωτέρω προϋπόθεσιν προβαίνομεν τώρα εἰς τὴν ἀπόδειξιν τῆς διπλῆς ἀνισότητος $0 < R^2 < 1$.

Πρὸς τὸν σκοπὸν αὐτὸν ἀρκεῖ νὰ ἀποδείξωμεν — ὑπὸ ὑπὸ τὴν ὡς ἄνω συνθήκην — ὅτι ἰσχύει πάντοτε ἡ ἀνισότης

$$\sigma^2 < \sigma_y^2 \quad (9)$$

καθ' ὅσον ἐκ τῆς (9) προκύπτει ἀμέσως ἡ σχέσις *

$$\frac{\sigma^2}{\sigma_y^2} < 1 \quad \text{ἢ} \quad 1 - \frac{\sigma^2}{\sigma_y^2} > 0 \quad \text{ἤτοι} \quad R^2 > 0$$

ἐνῶ παραλλήλως ἐκ τῆς προφανοῦς σχέσεως $\frac{\sigma^2}{\sigma_y^2} > 0$ θὰ ἔχωμεν ὅτι

$$-\frac{\sigma^2}{\sigma_y^2} < 0 \quad \text{ἢ} \quad 1 - \frac{\sigma^2}{\sigma_y^2} < 1 \quad \text{ἤτοι} \quad R^2 < 1$$

Πρὸς ἀπόδειξιν τῆς ἀνισότητος (9) ἐργαζόμεθα ὡς ἐξῆς: Ὑποθέσωμεν πρὸς στιγμὴν ὅτι ἡ ἐπιλογή τῆς γραμμῆς παλινδρομήσεως περιορίζεται μόνον μεταξύ τῶν παραλλήλων πρὸς τὸν ἄξονα τῶν x εὐθειῶν $y=c$. Τὸ μ.τ.σ. περὶ οἵανδήποτε τῶν εὐθειῶν αὐτῶν εἶναι ὡς γνωστὸν ἡ ποσότης

* Ἐκτὸς ἐὰν $\sigma_y^2 = 0$ πρᾶγμα τὸ ὁποῖον σημαίνει ὅτι $y_i = \mu_y$, $i = 1, 2, \dots, N$ καὶ κατὰ συνέπειαν ὅτι εὐρισκόμεθα εἰς τὴν ὀριακὴν περίπτωσιν κατὰ τὴν ὁποίαν ἅπαντα τὰ σημεῖα (x_i, y_i) , $i = 1, 2, \dots, N$ εὐρίσκονται ἐπὶ τῆς παραλλήλου πρὸς τὸν ἄξονα τῶν x εὐθείας $y = \mu_y$ καὶ αἱ μεταβληταὶ X καὶ Y εἶναι προφανῶς στατιστικῶς ἀσυσχέτιστοι.

$$\frac{1}{N} \sum_i (y_i - c)^2$$

Θέτοντες τὴν πρώτην παράγωγον τῆς ἐν λόγῳ ποσότητος — ἢ ἀπλούστερον τοῦ ἀριθμητοῦ αὐτῆς — ὡς πρὸς c ἴση πρὸς μηδὲν προκύπτει ἡ ἰσότης

$$(-2) \sum_i (y_i - c) = 0$$

ἐκ τῆς ὁποίας λαμβάνομεν

$$c = \frac{1}{N} \sum_i y_i = \mu_y$$

Οὕτως, ἡ ἐπιλεγομένη ἐν προκειμένῳ διὰ τῆς μεθόδου τῶν ἐλαχίστων τετραγώνων γραμμὴ παλινδρομήσεως εἶναι ἡ παράλληλος πρὸς τὸν ἄξονα τῶν x εὐθεΐα

$$y = \mu_y$$

τὸ δὲ μ.τ.σ. περὶ αὐτὴν

$$\sigma^2 = \frac{1}{N} \sum_i (y_i - \mu_y)^2$$

εἶναι ἴσον πρὸς τὴν διακύμανσιν σ_y^2 τῶν τιμῶν τῆς Y . Εἰς τὴν πραγματικότητα ὅμως ἡ γραμμὴ παλινδρομήσεως (3) ἐπιλέγεται μεταξὺ τῶν μελῶν τῆς οἰκογενείας (1), ἡ ὁποία πέραν τῶν εὐθειῶν $y=c$ — αἱ ὁποῖαι ἀποτελοῦν μέλη αὐτῆς συμφώνως πρὸς τὴν τεθεΐσαν συνθήκην—περιλαμβάνει ἐν γένει καὶ ἄλλας καμπύλας. Κατὰ συνέπειαν, τὸ μ.τ.σ. σ^2 περὶ τὴν ἐπιλεγείσαν καμπύλην παλινδρομήσεως (3) εἶναι ἀδύνατον νὰ ὑπερβαίῃ τὴν διακύμανσιν σ_y^2 , διότι ἐν τοιαύτῃ περιπτώσει ἡ μέθοδος τῶν ἐλαχίστων τετραγώνων θὰ ὀδήγει εἰς τὴν ἐπιλογὴν ὡς γραμμῆς παλινδρομήσεως τῆς εὐθείας $y=\mu_y$ τὸ μ.τ.σ. τῆς ὁποίας εἶναι, ὡς εἶδομεν ἄνωτέρω, ἴσον πρὸς σ_y^2 . Οὕτω συνάγεται τὸ συμπέρασμα ὅτι τὸ μ.τ.σ. σ^2 περὶ τὴν γραμμὴν παλινδρομήσεως (3), εἶναι πάντοτε μικρότερον ἢ τὸ πολὺ ἴσον πρὸς τὴν διακύμανσιν σ_y^2 , ἢτοι ἡ ἀνισότης $\sigma^2 \leq \sigma_y^2$ τὴν ὁποίαν ἐχρησιμοποίησαμεν ἄνωτέρω πρὸς ἀπόδειξιν τῆς διπλῆς ἀνισότητος $0 \leq R^2 \leq 1$.

Μετὰ τὴν ἀπόδειξιν τῆς διπλῆς ἀνισότητος (7) εἶναι χρήσιμον νὰ σχολιάσωμεν δι' ὀλίγων τὴν σημασίαν τῶν διαφόρων τιμῶν τοῦ δείκτου R^2 καὶ νὰ διευκρινισθοῦν τὰ ἑξῆς :

Κατ' ἀρχὴν εἶναι προφανὲς ὅτι ὅσον μεγαλυτέρα εἶναι ἡ τιμὴ τοῦ R^2 — ἡ ὁποία σημειωτέον ἐξαρτᾶται οὐσιαστικῶς μόνον ἐκ τοῦ μ.τ.σ. σ^2 — τόσον μικροτέρα εἶναι ἡ σχετικὴ διασπορὰ τῶν σημείων (x_i, y_i) , $i=1,2,\dots, N$ περὶ τὴν ἐπιλεγείσαν γραμμὴν παλινδρομήσεως καὶ κατὰ συνέπειαν τόσον μεγαλύτερος ὁ βαθμὸς προσαρμογῆς τῆς ἐν λόγῳ καμπύλης καὶ ἀκριβέστερα τὰ δι' αὐτῆς ἐξαγόμενα συμπεράσματα.

Ειδικώτερον, ἡ ἰσότης $R^2 = 1$ λαμβάνει προφανῶς χώραν μόνον ἐὰν ἡ ἐπιλεγείσα καμπύλη παλινδρομήσεως (3) διέρχεται δι' ὄλων τῶν σημείων (x_i, y_i) τοῦ ἀντιστοίχου στικτοῦ διαγράμματος, ἐὰν δηλαδὴ ἡ προσαρμογὴ αὐτῆς εἶναι πλήρης. Πράγματι, εἰς μίαν τοιαύτην περίπτωσιν — καὶ μόνον τότε — αἱ ἐξ ὑπολογισμοῦ — οἶονεῖ — τιμαὶ τῆς Y ταντίζονται πρὸς τὰς ἀντιστοίχους ἐμπειρικὰς τοιαύτας, τὸ μ.τ.σ. σ^2 μηδενίζεται καὶ ὁ δείκτης R^2 — ὡς προκύπτει ἐκ τοῦ τύπου (4) — γίνεται ἴσος πρὸς τὴν μονάδα.

Ἄντιστρόφως, ἡ ἰσότης $R^2 = 0$ λαμβάνει χώραν ἐὰν — καὶ μόνον ἐὰν — ἡ ἐπιλεγομένη διὰ τῆς μεθόδου τῶν ἐλαχίστων τετραγώνων γραμμὴ παλινδρομήσεως εἶναι ἡ παράλληλος πρὸς τὸν ἄξονα τῶν x εὐθεῖα $y = \mu_y$ — ὅτε τὸ ἀντίστοιχον μ.τ.σ. ἰσοῦται, ὡς εἶδομεν, πρὸς τὴν διακύμανσιν σ_y^2 — ἦτοι εἰς τὴν περίπτωσιν μὴ συσχετισμένων μεταβλητῶν.

Θὰ ἀποδείξωμεν τώρα — δι' ἐνὸς ἀπλοῦ ἀριθμητικοῦ παραδείγματος — ὅτι ἐὰν ἡ οἰκογένεια τῶν καμπύλων $y = f(x, \alpha, \beta)$ — ἐκ τῆς ὁποίας ἐπιλέγεται ἡ γραμμὴ παλινδρομήσεως — δὲν περιλαμβάνει τὰς παραλλήλους πρὸς τὸν ἄξονα τῶν x εὐθείας $y = c$ (δὲν πληροῦται δηλαδὴ ἡτεθεῖσα συνθήκη) εἶναι δυνατὸν ὁ δείκτης R^2 νὰ λάβῃ καὶ ἀρνητικὰς τιμὰς.

Ἐπιθέσωμεν ὅτι τὰ ἐμπειρικὰ δεδομένα συνίστανται ἐκ τῶν ἀριθμητικῶν ζευγῶν τῶν δύο πρώτων στηλῶν τοῦ κατωτέρου πίνακος (1).

Πίναξ 1

x_i	y_i	x_i^2	$x_i y_i$	y_i^2
1	9	1	9	81
2	8	4	16	64
3	10	9	30	100
4	5	16	20	25
10	32	30	75	270

Πρὸς τούτοις, ἐπιθέσωμεν ὅτι ὁ μελετητὴς ἀπεφάσισε νὰ ἐπιλέξῃ τὴν γραμμὴν παλινδρομήσεως μεταξὺ τῶν μελῶν τῆς οἰκογενείας $y = \beta x$ ἢ ὁποία προφανῶς δὲν περιλαμβάνει εὐθείας παραλλήλους πρὸς τὸν ἄξονα τῶν x . Τὸ σύστημα τῶν κανονικῶν ἐξισώσεων (2) συνίσταται ἐν προκειμένῳ ἐκ μόνης τῆς ἐξισώσεως

$$\beta \sum x_i^2 = \sum x_i y_i$$

Ἐπολογίζοντες ἐκ τῶν δεδομένων τῆς παρατηρήσεως τὰ ἀθροίσματα

$$\sum_i x_i^2 \text{ και } \sum_i x_i y_i$$

— ως ἐμφαίνεται ἀντιστοίχως εἰς τὴν τρίτην καὶ τετάρτην στήλην τοῦ πίνακος (1) — καὶ ἀντικαθιστῶντες τὰς τιμὰς αὐτῶν εἰς τὴν ὡς ἄνω ἐξίσωσιν λαμβάνομεν $\hat{\beta} = 2,5$. Οὕτως, ἡ ἐπιλεγείσα ἐν προκειμένῳ γραμμὴ παλινδρομήσεως εἶναι ἡ εὐθεῖα $\hat{y} = 2,5x$.

Τὸ μ.τ.σ. περὶ αὐτὴν ὑπολογιζόμενον ἐκ τοῦ τύπου (5), ὁ ὁποῖος εἰς τὴν παρούσαν συγκεκριμένην περίπτωσιν λαμβάνει τὴν μορφήν

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{\beta})^2 = \frac{1}{N} \sum_{i=1}^4 (y_i - 2,5x_i)^2$$

εἶναι $\sigma^2 = 20,625$.

Ἐξ ἄλλου, ἡ διακύμανσις σ_y^2 ὑπολογιζομένη ἐκ τοῦ τύπου (6) εἶναι $\sigma_y^2 = 3,5$. Κατὰ συνέπειαν, ὁ δείκτης R^2 ὑπολογιζόμενος ἐκ τοῦ τύπου (4) λαμβάνει ἐν προκειμένῳ τὴν ἀρνητικὴν τιμὴν

$$R^2 = 1 - \frac{20,625}{3,5} = -4,89$$

Ἐνταῦθα δεόν νά τονισθῇ ὅτι ἡ ὡς ἄνω σ υ ν θ ἡ κ η οὐδόλως ἀποτελεῖ δέσμευσιν εἰς τὴν διαδικασίαν ἐπιλογῆς τῆς καταλλήλου ἐκάστοτε γραμμῆς παλινδρομήσεως. Ἀντιθέτως, αὕτη εἶναι ἀπολύτως ἐπιβεβλημένη πρὸς ἀντιμετώπισιν τῶν περιπτώσεων ὅπου ἡ διαμόρφωσις τῶν τιμῶν τῆς Y δὲ ν σ χ ε τ ἰ ζ ε τ α ι καθ' οἷονδήποτε τρόπον πρὸς τὴν διαμόρφωσιν τῶν τιμῶν τῆς X καὶ κατὰ συνέπειαν μεταβαλλομένης τῆς X ἢ μεταβλητῆ Y λαμβάνει εἴτε τὴν αὐτὴν πάντοτε τιμὴν εἴτε γενικώτερον τιμὰς κυμαινομένης κατὰ μὴ συστηματικὸν τρόπον περίεξ μιᾶς εὐθείας παραλλήλου πρὸς τὸν ἄξονα τῶν x (περίπτωσις ἀσυσχετίστων μεταβλητῶν).

Ἐξ ἄλλου, αἱ πλείστα τῶν χρησιμοποιουμένων εἰς τὴν πρᾶξιν μορφαὶ καμπύλων παλινδρομήσεως πληροῦν τὴν ὡς ἄνω συνθήκην. Συγκεκριμένως ἡ εὐθεῖα $y = a + bx$ ὡς καὶ αἱ καμπύλαι πολυωνυμικῆς μορφῆς δευτέρου ἢ ἀνωτέρου βαθμοῦ, $y = a + bx + \gamma x^2$, $y = a + bx + \gamma x^2 + \delta x^3$ κ.λ.π. ὑπὸ τὴν προϋπόθεσιν ὅτι περιλαμβάνουν τὸν γνωστὸν ὡς σταθερὸν ὄρον — παράμετρος a — πληροῦν προφανῶς τὴν ὡς ἄνω συνθήκην καθ' ὅσον διὰ μηδενισμοῦ τῶν ὑπολοίπων παραμέτρων τῶν λαμβάνουν τὴν μορφήν $y = c$. Ὁμοίως αἱ καμπύλαι ὑπερβολικῆς μορφῆς $1/y = a + bx$, $y = a + \beta/x$ κ.λ.π. (διὰ $\beta = 0$), ἐκθετικῆς μορφῆς $y = a\beta^x$ (διὰ $\beta = 1$), γεωμετρικῆς μορφῆς $y = ax^\beta$ (διὰ $\beta = 0$), ἢ γενικευμένη ἐκθετικὴ καμπύλη $y = k + a\beta^x$ (διὰ $a = 0$, $\beta = 1$), ἢ λογιστικὴ καμπύλη

$$y = \frac{k}{1 + e^{a + \beta x}}$$

(διὰ $\alpha = \beta = 0$) περιλαμβάνουν προφανώς — ὡς ὑποοικογένειαν — τὰς παραλλήλους πρὸς τὸν ἄξονα τῶν x εὐθείας $y = c$. Ἐκ τῶν ἀνωτέρω βεβαίως καθίσταται προφανές ὅτι εἰς οὐδεμίαν περίπτωσιν ἢ καμπύλη παλινδρομήσεως θὰ πρέπει νὰ ἀναζητηθῆται μεταξύ οἰκογενειῶν μὲ ἐξίσωσιν τῆς μορφῆς $y = \beta x$ ἢ $y = \beta x + \gamma x^2$ ἢ $y = \beta x + \gamma x^2 + \delta x^3$ ἢ ἄλλην πολυωνυμικὴν μορφήν ἄνευ σταθεροῦ ὄρου ὡς ἐπίσης μεταξύ τῶν ἐκθετικῶν καμπύλων $y = \beta^x$, τῶν γεωμετρικῶν τοιούτων $y = x^\beta$ ἢ διαφόρων ἄλλων καμπύλων ὡς π.χ. $y = \beta \log x$, $y = \beta \log x + \gamma (\log x)^2$, $\sqrt{y} = \beta x$ κ.ο.κ. αἱ ὁποῖαι προφανώς δὲν περιλαμβάνουν τὰς εὐθείας $y = c$, καθ' ὅσον εἶναι δυνατόν νὰ ὀδηγηθῶμεν εἰς τὸ ἄτομον τοῦ προηγουμένου παραδείγματος, ἀρνητικὰς δηλαδὴ τιμὰς τοῦ δείκτη R^2 ἄνευ οὐδεμιᾶς πρακτικῆς ἀξίας.

3 ἡ Ἰδιότης. «Ὁ δείκτης R^2 εἶναι ἀνεξάρτητος τῶν χρησιμοποιουμένων μονάδων μετρήσεως, ὡς ἐπίσης καὶ τῆς λαμβανομένης ἐκάστοτε ὡς ἀρχῆς αὐτῶν. Ἐν ἄλλοις δηλαδὴ λόγοις ἢ τιμῇ τοῦ ἐν λόγῳ δείκτη παραμένει ἐν γένει ἀναλλοίωτος εἰς γραμμικοὺς μετασχηματισμοὺς τῶν μεταβλητῶν».

Ἡ ιδιότης αὕτη ἐπιτρέπουσα τὴν ἐρμηνείαν καὶ κατανόησιν τῆς σημασίας τοῦ ἐν λόγῳ δείκτη ἄνευ οἰωνδῆποτε προσθέτων πληροφοριῶν — ἀναφερομένων εἰς τὰς μονάδας μετρήσεως, τὴν ἀρχὴν αὐτῶν κ.λ.π. — ἰσχύει ὅπως καὶ ἡ προηγουμένη τοιαύτη ὑπὸ ὄρισμένως μόνον συνθήκας καὶ συγκεκριμένως τὰς ἐξῆς:

Διὰ τὴν ἀνεξαρτησίαν τοῦ δείκτη R^2 ἐκ τῶν μονάδων μετρήσεως θὰ πρέπει

«Ἡ οἰκογένεια τῶν καμπύλων $y = f(x, \alpha, \beta)$ — μεταξύ τῶν μελῶν τῆς ὁποίας ἀναζητεῖται ἢ συγκεκριμένη καμπύλη παλινδρομήσεως $\hat{y} = f(x, \hat{\alpha}, \hat{\beta})$ — νὰ εἶναι τοιαύτη ὥστε, ἐὰν ἡ καμπύλη $y = f(x, \alpha', \beta')$ ἀποτελεῖ μέλος αὐτῆς καὶ ἡ καμπύλη $y = \lambda f(x, \alpha', \beta')$, ὅπου λ αὐθαίρετος σταθερά, νὰ εἶναι ἐπίσης μέλος τῆς οἰκογενείας».

Γενικώτερον ὁμως ἵνα ὁ δείκτης R^2 εἶναι ἀνεξάρτητος — πέραν τῶν μονάδων μετρήσεως — καὶ τῆς λαμβανομένης ὡς ἀρχῆς αὐτῶν, δέον ὅπως:

«καὶ ἡ καμπύλη $y = k + \lambda f(x, \alpha', \beta')$, ὅπου k, λ αὐθαίρετοι σταθεραὶ, νὰ ἀποτελῇ ὡσαύτως μέλος τῆς ἀρχικῆς οἰκογενείας».

Ἐνταῦθα δέον νὰ σημειωθῇ ὅτι δι' ὄρισμένας οἰκογενείας καμπύλων * ἢ ἐν λόγῳ συνθήκῃ δὲν πληροῦται μὲ ἀποτέλεσμα ἢ τιμῇ τοῦ δείκτη R^2 εἰς τὰς περιπτώσεις αὐτάς νὰ ποικίλλῃ ἀναλόγως τῶν χρησιμοποιουμένων μονάδων μετρήσεως καὶ τῆς λαμβανομένης ἐκάστοτε ὡς ἀρχῆς (τῶν μετρήσεων).

Διὰ τὸν λόγον αὐτὸν πρὸ τῆς προσαρμογῆς — πρὸς τὰ ἐκάστοτε ἐμπειρικὰ δεδομένα — μιᾶς καμπύλης παλινδρομήσεως θὰ πρέπει νὰ ἐλέγχεται κατὰ πόσον ἢ ἀντίστοιχος ἐξίσωσις πληροῖ τὴν ὡς ἄνω συνθήκην καθ' ὅσον ἐν ἐναντία περιπτώσει ὁ δείκτης προσδιορισμοῦ R^2 τυγχάνει, ὡς εἶναι εὐνόητον, λίαν περιορισμένης — ἂν ὄχι ἄνευ οὐδεμιᾶς σημασίας — καὶ ἡ χρῆσις αὐτοῦ εἰς τὴν πρᾶξιν καθίσταται ἐξαιρετικῶς δυσχερῆς.

* Ἴδε σχετικὸν παράδειγμα κατωτέρω.

Ἡ ἀπόδειξις τῆς ὡς ἄνω ιδιότητος τοῦ δείκτη R^2 ὑπὸ τὴν γενικὴν μορφήν αὐτῆς — ἦτοι τὸ ἀναλλοίωτον αὐτοῦ εἰς ἀλλαγὴν τῶν μονάδων μετρήσεως καὶ ταυτόχρονον μεταφορὰν τῆς ἀρχῆς τῶν ἀξόνων — δίδεται κατωτέρω. Διὰ τὴν ἀπόδειξιν τῆς μερικῆς περιπτώσεως — ἦτοι τῆς ἀνεξαρτηρίας αὐτοῦ ἐκ τῶν μονάδων μετρήσεως — ἀρκεῖ εἰς ὅτι ἀκολουθεῖ νὰ ὑποθεθῇ ὅτι $k=0$.

Ὑποθέσωμεν ὅτι ἡ ἐξηρητημένη μεταβλητὴ Y μετρούμενη μὲ δύο διαφόρους μονάδας μετρήσεως καὶ μὲ δύο διαφορετικὰς ἀρχὰς τῶν μετρήσεων λαμβάνει ἀντιστοίχως τὰς τιμὰς y_i καὶ z_i ὅπου $i=1,2,\dots,N$ αἱ ἐπὶ μέρους μονάδες τοῦ ὑπὸ ἔρευναν συνόλου (πληθυσμοῦ). Ἐὰν λ εἶναι ὁ λόγος τῶν δύο μονάδων μετρήσεως καὶ k ἡ ἀπόστασις τῶν δύο σημείων — ἀρχῶν τῶν μετρήσεων, θὰ ἔχωμεν ὡς γνωστὸν ὅτι

$$z_i = k + \lambda y_i \quad \text{διὰ } i=1,2,\dots,N$$

Ὑπὸ τὴν προϋπόθεσιν λοιπὸν τῆς δευτέρας — τῆς γενικωτέρας — ἐκ τῶν ὡς ἄνω συνθηκῶν θὰ ἀποδείξωμεν ὅτι ὁ δείκτης R^2 λαμβάνει τὴν αὐτὴν ἀκριβῶς τιμὴν ἀνεξαρτήτως ἐὰν διὰ τὸν ὑπολογισμὸν αὐτοῦ χρησιμοποιηθοῦν αἱ τιμαὶ y_i ἢ αἱ τιμαὶ z_i , $i=1,2,\dots,N$. Πρὸς τοῦτο ἐργαζόμεθα ὡς ἑξῆς:

Ὑποθέσωμεν ὅτι χρησιμοποιουμένων τῶν τιμῶν y_i , $i=1,2,\dots,N$ ἡ ἐπιλεγομένη καμπύλη παλινδρομήσεως ἔχει ἐξίσωσιν

$$\hat{y} = f(x, \hat{\alpha}, \hat{\beta})$$

ἐνῶ χρησιμοποιουμένων τῶν τιμῶν z_i , $i=1,2,\dots,N$ ἐπιλέγεται ἀντιστοίχως ἡ καμπύλη

$$\hat{z} = f(x, \alpha', \beta')$$

Ἐστω ἀκόμη ὅτι τὸ μ.τ.σ. περὶ τὴν καμπύλην $\hat{y} = f(x, \hat{\alpha}, \hat{\beta})$ εἶναι σ^2 ἦτοι

$$\frac{1}{N} \sum_i [y_i - f(x_i, \hat{\alpha}, \hat{\beta})]^2 = \sigma^2$$

Θὰ δεῖξωμεν ὅτι

$$f(x, \alpha', \beta') = k + \lambda f(x, \hat{\alpha}, \hat{\beta}) \quad (10)$$

Τὸ μ.τ.σ. περὶ τὴν καμπύλην $\hat{z} = k + \lambda f(x, \hat{\alpha}, \hat{\beta})$ εἶναι

$$\frac{1}{N} \sum_i [z_i - k - \lambda f(x_i, \hat{\alpha}, \hat{\beta})]^2 = \frac{1}{N} \sum_i [\lambda y_i - \lambda f(x_i, \hat{\alpha}, \hat{\beta})]^2 = \lambda^2 \sigma^2$$

Κατὰ συνέπειαν, ἐὰν ὑποθέσωμεν ὅτι δὲν ἀληθεύει ἡ σχέσις (10) θὰ πρέπει τὸ μ.τ.σ. περὶ τὴν καμπύλην $\hat{z} = f(x, \alpha', \beta')$ νὰ εἶναι μικρότερον τοῦ $\lambda^2 \sigma^2$ ἦτοι

$$\frac{1}{N} \sum_i [z_i - f(x, a', \beta')]^2 < \lambda^2 \sigma^2$$

Τούτο όμως θα ὀδήγει εἰς τὸ ἄτοπον τὸ μ.τ.σ. περὶ τὴν καμπύλην

$$\hat{y} = \frac{1}{\lambda} [f(x, a', \beta') - k]$$

νὰ εἶναι μικρότερον τοῦ σ^2 καὶ κατὰ συνέπειαν ἡ καμπύλη $\hat{y} = f(x, \hat{a}, \hat{\beta})$ νὰ μὴ εἶναι, ὡς ὑπετέθη, ἡ καμπύλη παλινδρομῆσεως ἐλαχίστου μ.τ.σ. Πράγματι τὰ μ.τ.σ.

περὶ τὴν καμπύλην $\hat{y} = \frac{1}{\lambda} [f(x, a', \beta') - k]$ εἶναι

$$\begin{aligned} \frac{1}{N} \sum_i [y_i - \frac{1}{\lambda} (f(x_i, a', \beta') - k)]^2 &= \frac{1}{N} \sum_i [\frac{1}{\lambda} z_i - \frac{1}{\lambda} f(x_i, a', \beta')]^2 = \\ &= \frac{1}{\lambda^2} \frac{1}{N} \sum_i [z_i - f(x_i, a', \beta')]^2 < \sigma^2 \end{aligned}$$

Ἐκ τῶν ἀνωτέρω συνάγεται ὅτι ἡ σχέσις (10) ἀληθεύει καὶ κατὰ συνέπειαν τὸ μ.τ.σ. περὶ τὴν καμπύλην $\hat{z} = f(x, a', \beta')$ εἶναι ἴσον πρὸς $\lambda^2 \sigma^2$ ἦτοι

$$\frac{1}{N} \sum_i [z_i - f(x_i, a', \beta')]^2 = \lambda^2 \sigma^2$$

Ἐξ ἄλλου, ἐὰν ἡ διακύμανσις τῶν τιμῶν $y_i, i=1,2,\dots,N$ τῆς μεταβλητῆς Y εἶναι σ_y^2 ἡ διακύμανσις τῶν τιμῶν $z_i, i=1,2,\dots,N$ εἶναι ὡς γνωστὸν — λόγῳ τῆς σχέσεως $z_i = k + \lambda y_i$ — ἴση πρὸς $\lambda^2 \sigma^2$. Οὕτως, ὁ δείκτης R^2 χρησιμοποιουμένων τῶν τιμῶν $z_i, i=1,2,\dots,N$ εἶναι

$$R^2 = 1 - \frac{\lambda^2 \sigma^2}{\lambda^2 \sigma_y^2} = 1 - \frac{\sigma^2}{\sigma_y^2}$$

ἦτοι ἴσος πρὸς τὸν δείκτην R^2 ὑπολογιζομένου τῆ βοηθεῖα τῶν τιμῶν $y_i, i=1,2,\dots,N$ καὶ κατὰ συνέπειαν ὁ ἐν λόγῳ δείκτης εἶναι ἀνεξάρτητος τῶν χρησιμοποιουμένων κατὰ περίπτωσιν μονάδων μετρήσεως, ὡς ἐπίσης τοῦ σημείου τὸ ὁποῖον λαμβάνεται ὡς ἀρχὴ τῶν μετρήσεων.

Παραθέτομεν τώρα μερικὰς — ἐκ τῶν συνήθως χρησιμοποιουμένων εἰς τὴν πρᾶξιν — ἐξισώσεις ἡ ἄλλως οἰκογενεῖας καμπύλων αἱ ὁποῖαι δὲν πληροῦν τὴν ὡς ἄνω συνθήκην — ἦτοι ἐὰν περιλαμβάνουν ὡς μέλος τῶν μίαν καμπύλην $y = f(x, a', \beta')$ νὰ περιλαμβάνουν καὶ τὴν $y = k + \lambda f(x, a', \beta')$ — με ἄμεσον συνέπειαν ἡ τιμὴ τοῦ δείκτη R^2 — ἡ ὁποῖα ἀντιστοιχεῖ εἰς τὴν ἐπιλεγομένην μεταξὺ αὐτῶν καμπύλην παλινδρομῆσεως — νὰ ποικίλλῃ, ὡς θὰ ἴδωμεν, καὶ εἰς ἀντίστοιχα ἀριθμητικὰ παραδείγματα, ἀναλόγως τῶν χρησιμοποιουμένων μονάδων καὶ τῆς

ἀρχῆς τῶν μετρήσεων. Κατ' ἀρχὴν ἢ ὡς ἄνω συνθήκη δὲν πληροῦται ὑπὸ τῆς οἰκογενείας τῶν εὐθειῶν

$$y = \beta x$$

καὶ γενικώτερον ὑπὸ τῶν οἰκογενειῶν τῶν καμπύλων πολυωνυμικῆς μορφῆς

$$y = \beta x + \gamma x^2, \quad y = \beta x + \gamma x^2 + \delta x^3, \quad \text{κ.ο.κ.}$$

καθ' ὅσον αἱ ἐν λόγῳ οἰκογένειαι δὲν περιλαμβάνουν ὡς μέλος τῶν τὰς εὐθείας $y = \alpha + \beta x$ καὶ τὰς καμπύλας $y = \alpha + \beta x + \gamma x^2$, $y^2 = \alpha + \beta x + \gamma x^2 + \delta x^3$ κ.ο.κ.

Ὁμοίως, ἡ ἐν λόγῳ συνθήκη δὲν πληροῦται ὑπὸ τῆς οἰκογενείας τῶν καμπύλων ἐκθετικῆς καὶ γεωμετρικῆς μορφῆς, ἤτοι ὑπὸ τῶν ἐξισώσεων $y = \alpha \beta^x$ καὶ $y = \alpha x^\beta$ ἢ ἄλλως $\log y = A + Bx$ καὶ $\log y = A + \beta \log x$ ὅπου $A = \log \alpha$ καὶ $B = \log \beta$, καθ' ὅσον αἱ ἐν λόγῳ οἰκογένειαι δὲν περιλαμβάνουν μεταξὺ τῶν μελῶν τῶν τὰς καμπύλας $y = k + \alpha \beta^x$ (γενικευμένη ἐκθετικὴ καμπύλη) καὶ $y = k + \alpha x^\beta$ (γενικευμένη γεωμετρικὴ καμπύλη). Πέραν τῶν ἀνωτέρω, τὸ αὐτὸ πρόβλημα παρουσιάζεται μετὴν τῆν καλουμένην λογιστικὴν καμπύλην

$$y = \frac{c}{1 + e^{\alpha + \beta x}}$$

καθ' ὅσον ἡ ἐν λόγῳ οἰκογένεια δὲν περιλαμβάνει τὴν καμπύλην

$$y = k + \frac{c}{1 + e^{\alpha + \beta x}}$$

ὡς ἐπίσης μετ' ὀρισμένης ἄλλας οἰκογενείας καμπύλων ὡς π.χ. αἱ

$$y = \beta \log x$$

$$y = \beta \log x + \gamma (\log x)^2$$

$$\sqrt{y} = \beta x$$

$$\sqrt{y} = \beta x + \gamma x^2$$

$$y = \frac{\beta}{x}$$

$$y = \frac{\beta}{y + \delta x}$$

κ.ο.κ.

Πρὸς πληρεστέραν κατανόησιν τῶν ἀνωτέρω παραθέτομεν ἐνδεικτικῶς δύο ἀπλᾶ ἀριθμητικὰ παραδείγματα :

(Α) Χρησιμοποιοῦντες ἀντὶ τῶν τιμῶν τῆς μεταβλητῆς Y αἱ ὁποῖαι παρατίθενται εἰς τὸν ἀνωτέρω πίνακα (1) τὰς τιμὰς $z_i = y_i + 1$ λαμβάνομεν τὰ ἑξῆς :

$$\sum_i x_i^2 = 30, \quad \sum_i x_i z_i = 85, \quad \beta = \frac{\sum_i x_i z_i}{\sum_i x_i^2} = \frac{85}{30} = 2,833 \quad \text{καὶ μ.τ.σ. περὶ τὴν εὐθεῖαν}$$

$$\hat{\Lambda} = 2,833 \times \text{τὴν ποσότητα}$$

$$1/4 [(10 - 2,833)^2 + (9 - 5,666)^2 + (11 - 8,499)^2 + (6 - 11,332)^2] = 24,5$$

Ἐξ ἄλλου ἡ διακύμανσις τῶν τιμῶν $z_i = y_i + 1$ εἶναι ὡς γνωστὸν ἡ αὐτὴ μετ

τὴν ὑπολογισθεῖσαν διακύμανσιν τῶν τιμῶν y_i , ἥτοι 3,5. Οὕτως ἡ τιμὴ τοῦ δείκτου R^2 γίνεται ἐν προκειμένῳ

$$R^2 = 1 - \frac{24,5}{3,5} = -\frac{21}{3,5} = -6$$

διάφορος τῆς ὑπολογισθείσης προηγουμένης τιμῆς -4,89

(B) Ὑποθέσωμεν ὅτι τὰ ἐμπειρικά δεδομένα συνίστανται ἐκ τῶν ἀριθμητικῶν ζευγῶν (x_i, y_i) , $i=1, 2, \dots, 5$ τῶν δύο πρώτων στηλῶν τοῦ κατωτέρω πίνακος 2 καὶ ἀκόμη ὅτι ὁ μελετητὴς ἀπεφάσισε νὰ προσαρμόσῃ πρὸς αὐτὰ μίαν ἐκθετικὴν καμπύλην τῆς μορφῆς $y = a\beta^x$ ἢ ἄλλως $\log y = A + Bx$ ὅπου $A = \log a$ καὶ $B = \log \beta$.

Πίναξ 2

x_i	y_i	$y_i' = \log y_i$	x_i^2	$x_i y_i'$	$y_i'^2$
1	11.800	4,07188	1	4,07188	16,58118
2	19.200	4,28330	4	8,56660	18,34666
3	43.600	4,63849	9	13,91547	21,51104
4	92.600	4,96661	16	19,86644	24,66712
5	148.400	5,17143	25	25,85715	26,74338
15	—	23,13171	55	72,27754	107,84938

Τὸ σύστημα τῶν κανονικῶν ἐξισώσεων τὸ ὁποῖον ἐν προκειμένῳ λαμβάνει τὴν μορφήν

$$\Sigma y_i' = AN + B \Sigma x_i$$

$$\Sigma x_i y_i' = A \Sigma x_i + B \Sigma x_i^2$$

εἰς τὴν συγκεκριμένην περίπτωσιν γίνεται

$$23,13171 = 5A + 15B$$

$$72,27754 = 15A + 55B$$

ἢ ἐπίλυσις δὲ αὐτοῦ δίδει

$$\hat{A} = 3,76162 \quad \text{καὶ} \quad \hat{B} = 0,28824$$

ἐκ τῶν ὁποίων δι' ἀντιλογαριθμῆσεως λαμβάνομεν

$$\hat{a} = 5,776 \quad \text{καὶ} \quad \hat{\beta} = 1,94$$

Ούτως, η ζητούμενη καμπύλη παλινδρομήσεως έχει εξίσωσιν

$$\hat{y} = 5.776.1,94^x \quad \text{ή} \quad \log \hat{y} = 3,762 + 0,288x.$$

Το μ.τ.σ. περί τήν ως άνω καμπύλην υπολογιζόμενον ως γνωστόν εκ του τύπου

$$\sigma^2 = \frac{1}{N} (\Sigma y_i'^2 - \hat{A} \Sigma y_i' - \hat{B} \Sigma x_i y_i')$$

είναι $\sigma^2 = 0,0522$.

Έξ άλλου η διακύμανσις των τιμών y_i' , $i=1,2,\dots,N$ (όπου $y_i' = \log y_i$) είναι

$$\sigma_{y'}^2 = 0,1701$$

καί κατά συνέπειαν ο δείκτης προσδιορισμού R^2 οριζόμενος εκ του τύπου (4) είναι

$$R^2 = 1 - \frac{0,0522}{0,1701} = 0,69 \quad (\text{ή } 6\%)$$

Υποθέσωμεν τώρα ότι επί τής μεταβλητής Y εφαρμόζεται ο γραμμικός μετασχηματισμός

$$Z = \frac{Y - 10.000}{100}$$

έν άλλους δηλαδή λόγους ότι ως αρχή των μετρήσεων λαμβάνεται το 10.000 και ως μονάς το 100. Εφαρμοζομένης τής ως άνω διαδικασίας επί των νέων δεδομένων — τα όποια παρατίθενται κατωτέρω εις τον πίνακα 2α — λαμβάνονται αντίστοιχως τα εξής αποτελέσματα :

Πίναξ 2α

x_i	z_i	$z_i = \log z_i$	x_i^2	$x_i z_i'$	$z_i'^2$
1	18	1,25527	1	1,25527	1,57503
2	92	1,96379	4	3,92758	3,85729
3	336	2,52634	9	7,57902	6,38068
4	826	2,91698	16	11,66792	8,50888
5	1.384	3,14114	25	15,70570	9,86588
15	—	11,80352	55	40,13549	30,18776

Τὸ σύστημα τῶν κανονικῶν ἐξισώσεων γίνεται ἐν προκειμένῳ

$$11,80352 = 5A + 15B$$

$$40,13549 = 15A + 55B$$

ἐξ αὐτοῦ δὲ προκύπτει ὅτι

$$\hat{A} = 0,94323 \quad \hat{B} = 0,47249$$

ἀντιστοίχως δὲ

$$\hat{\alpha} = 8,78 \quad \hat{\beta} = 2,96.$$

Οὕτως, ἡ ἐξίσωσις τῆς καμπύλης παλινδρομήσεως γίνεται ἐν προκειμένῳ

$$\hat{y} = 8,78 \cdot 2,96^x \quad \text{ἢ} \quad \log \hat{y} = 0,943 + 0,472x$$

τὸ δὲ μ.τ.σ. περὶ αὐτὴν γίνεται ἀντιστοίχως $\sigma^2 = 0,1129$.

Ἐξ ἄλλου ἡ διακύμανσις τῶν $z_i' = \log z_i$ εἶναι $\sigma_{z'}^2 = 0,4646$ καὶ κατὰ συνέπειαν ἡ τιμὴ τοῦ δείκτου R^2 εἶναι ἐν προκειμένῳ

$$R^2 = 1 - \frac{0,1129}{0,4646} = 0,76 \quad (\text{ἢ} \quad 76\%)$$

ἥτοι σημαντικῶς διάφορος τῆς εὐρεθείσης προηγουμένως 0,69.

III. Ὁ συντελεστὴς γραμμικῆς συσχέτισεως καὶ αἱ ἐφαρμογαὶ τοῦ

Τὸ τετράγωνον τοῦ συντελεστοῦ — γραμμικῆς — συσχέτισεως δύο μεταβλητῶν X καὶ Y , ὀριζομένου ἐκ τῆς σχέσεως

$$\rho = \frac{\text{Cov}(X, Y)}{\sigma_x \sigma_y} \quad (11)$$

ἰσοῦται, ὡς γνωστόν, πρὸς τὸν δείκτην προσδιορισμοῦ R^2 ὁ ὁποῖος ἀναφέρεται ἀντιστοίχως εἰς τὴν εὐθεῖαν παλινδρομήσεως

$$\hat{y} = \hat{\alpha} + \hat{\beta}x \quad (12)$$

ἐπιλεγομένην διὰ τῆς μεθόδου τῶν ἐλαχίστων τετραγώνων ἐκ τῆς διπαραμετρικῆς * οἰκογενείας

$$y = \alpha + \beta x \quad (13)$$

* καὶ ὅχι ἐκ τῆς $y = \beta x$.

Οὕτω, δοθέντος ὅτι ἡ ἐξίσωσις (13) ἱκανοποιεῖ τὰς τεθείσας ὡς ἄνω συνθήκας, συνάγεται τὸ συμπέρασμα ὅτι ὁ συντελεστὴς συσχέτισεως ρ εἶναι καθαρὸς ἀριθμὸς ὁ ὁποῖος πληροῖ πάντοτε τὴν διπλὴν ἀνισότητα $-1 \leq \rho \leq +1$, ἐνῶ παραλλήλως εἶναι ἀνεξάρτητος τῶν χρησιμοποιουμένων μονάδων μετρήσεως, ὡς καὶ τῆς λαμβανομένης ἐκάστοτε ὡς ἀρχῆς αὐτῶν (ἀναλλοίωτος εἰς γραμμικοὺς μετασχηματισμοὺς τῶν μεταβλητῶν).

Πολλάκις ὁμοῦ εἰς τὴν πρᾶξιν ὁ ἐν λόγῳ συντελεστὴς χρησιμοποιεῖται καὶ ὡς μέτρον τῆς συναφείας δύο μὴ ποσοτικῶν ἀλλὰ ποιοτικῶν μεταβλητῶν — αἱ ὁποῖαι ὡς γνωστὸν ἐπιτρέπουν μόνον ἱεράρχησιν τῶν μονάδων τοῦ ὑπὸ ἔρευναν πληθυσμοῦ — λαμβανομένων ὡς τιμῶν τῶν μεταβλητῶν τῶν ἀντιστοιχῶν βαθμῶν ἢ ἄλλως κωδικακρίθμων.

Ἐν προκειμένῳ θὰ πρέπει νὰ τονισθῇ ὅτι ἡ τιμὴ τοῦ ἐν λόγῳ δείκτου εἶναι δυνατόν νὰ ποικίλῃ ἀναλόγως τοῦ χρησιμοποιουμένου συστήματος ἱεραρχήσεως ἢ ἄλλως κωδικογραφίσεως, ἐκτὸς ἐὰν οἱ χρησιμοποιούμενοι εἰς διαφόρους περιπτώσεις πρὸς ἱεράρχησιν τῶν μονάδων τοῦ πληθυσμοῦ βαθμοὶ (κωδικαριθμοὶ) εὐρίσκονται ἐν γραμμικῇ ἐξαρτήσει.

Πρὸς πληρεστέραν κατανόησιν τῶν ἀνωτέρω παραθέτομεν ἐν ἄπλοῦν ἀριθμητικὸν παράδειγμα. Ὑποθέσωμεν ὅτι 5 τροχαῖα ἀτυχήματα ἱεραρχοῦνται ἐξ ἀπόψεως σοβαρότητος αὐτῶν καὶ ἐμπειρίας τοῦ ὁδηγοῦ προκειμένου νὰ διαπιστωθῇ ἢ τυχὸν ὑφισταμένη μεταξὺ ἐμπειρίας τοῦ ὁδηγοῦ — μεταβλητὴ X — καὶ σοβαρότητος τοῦ ἀτυχήματος — μεταβλητὴ Y — σχέσις. Εἰς τοὺς κατωτέρω πίνακας 3, 3α καὶ 3β παρατίθενται τρεῖς διάφοροι τρόποι κωδικογραφίσεως (βαθμολογίας)* τῶν μεταβλητῶν καὶ ὑπολογίζονται οἱ ἀντίστοιχοι συντελεσταὶ συσχέτισεως ἐφαρμοζομένου τοῦ γνωστοῦ τύπου.

$$\rho = \frac{\sum x_i y_i - \frac{\sum x_i \sum y_i}{N}}{\sqrt{\sum x_i^2 - \frac{(\sum x_i)^2}{N}} \sqrt{\sum y_i^2 - \frac{(\sum y_i)^2}{N}}} \quad (14)$$

Πίναξ 3

x_i	y_i	x_i^2	$x_i y_i$	y_i
1	5	1	5	25
2	3	4	6	9
3	4	9	12	16
4	1	16	4	1
5	2	25	10	4
15	15	55	37	55

* Ὅσον μεγαλύτερα ἢ ἐμπειρία καὶ ἡ σοβαρότης τοῦ ἀτυχήματος, τόσον μεγαλύτερος ὁ ἀντίστοιχος βαθμὸς εἰς ἀπάσας τὰς περιπτώσεις.

Πίναξ 3α

x_i'	y_i'	$x_i'^2$	$x_i'y_i'$	$y_i'^2$
3	8	9	24	64
5	6	25	30	36
7	7	49	49	49
9	4	81	36	16
11	5	121	55	25
35	30	285	194	190

Πίναξ 3β

x_i''	y_i''	$x_i''^2$	$x_i''y_i''$	$y_i''^2$
2	8	4	16	64
5	5	25	25	25
7	7	49	49	49
8	1	64	8	1
10	3	100	30	9
32	24	242	128	148

Ἐκ τῶν δεδομένων τοῦ πίνακος (3) δι' ἐφαρμογῆς τοῦ τύπου (14) λαμβάνομεν

$$\rho = -0,8$$

Ἐκ τοῦ πίνακος (3α) ἔχομεν ὁμοίως

$$\rho = -0,8$$

ἐνῶ ἐκ τοῦ πίνακος (3β) λαμβάνομεν

$$\rho = -0,73$$

Ἡ ἰσότης τῶν συντελεστῶν συσχετίσεως οἱ ὁποῖοι προκύπτουν ἐκ τῶν δύο πρώτων πινάκων ὀφείλεται εἰς τὸ ὅτι οἱ βαθμοὶ (κώδικες) τοῦ πίνακος (3α) εὐρίσκονται ἐξ ἐκείνων τοῦ πίνακος (3) ἐκ τοῦ γραμμικῶν σχέσεων

$$x' = 2x+1 \quad \text{καὶ} \quad y' = y+3$$

Ἀντιθέτως ἡ διαφορά τοῦ ἐκ τοῦ πίνακος (3β) ἀποτελέσματος ὀφείλεται εἰς τὸ ὅτι οἱ βαθμοὶ x'' καὶ y'' — παρ' ὅτι διατηροῦν τὴν αὐτὴν ἱεράρχησιν—δὲν ἀποτελοῦν γραμμικοὺς μετασχηματισμοὺς τῶν x καὶ y ἢ x' καὶ y' .

Διὰ τὸν λόγον αὐτὸν ἡ χρῆσις τοῦ συντελεστοῦ ρ θὰ πρέπει ἐν προκειμένῳ νὰ ἀποφεύγηται διότι τὸ σχετικὸν ἀποτέλεσμα εἶναι κατὰ βάσιν ἄνευ σημασίας.