

Στατιστική II

Γιώργος Τσιρογιάννης

Τμήμα Διοίκησης Επιχειρήσεων Αγροτικών
Προϊόντων και Τροφίμων,
Πανεπιστήμιο Πατρών




Διάλεξη 5η

- Στατιστικός έλεγχος υποθέσεων
- Μηδενικές και εναλλακτικές υποθέσεις
- Κανόνας απόφασης
- Ο έλεγχος z


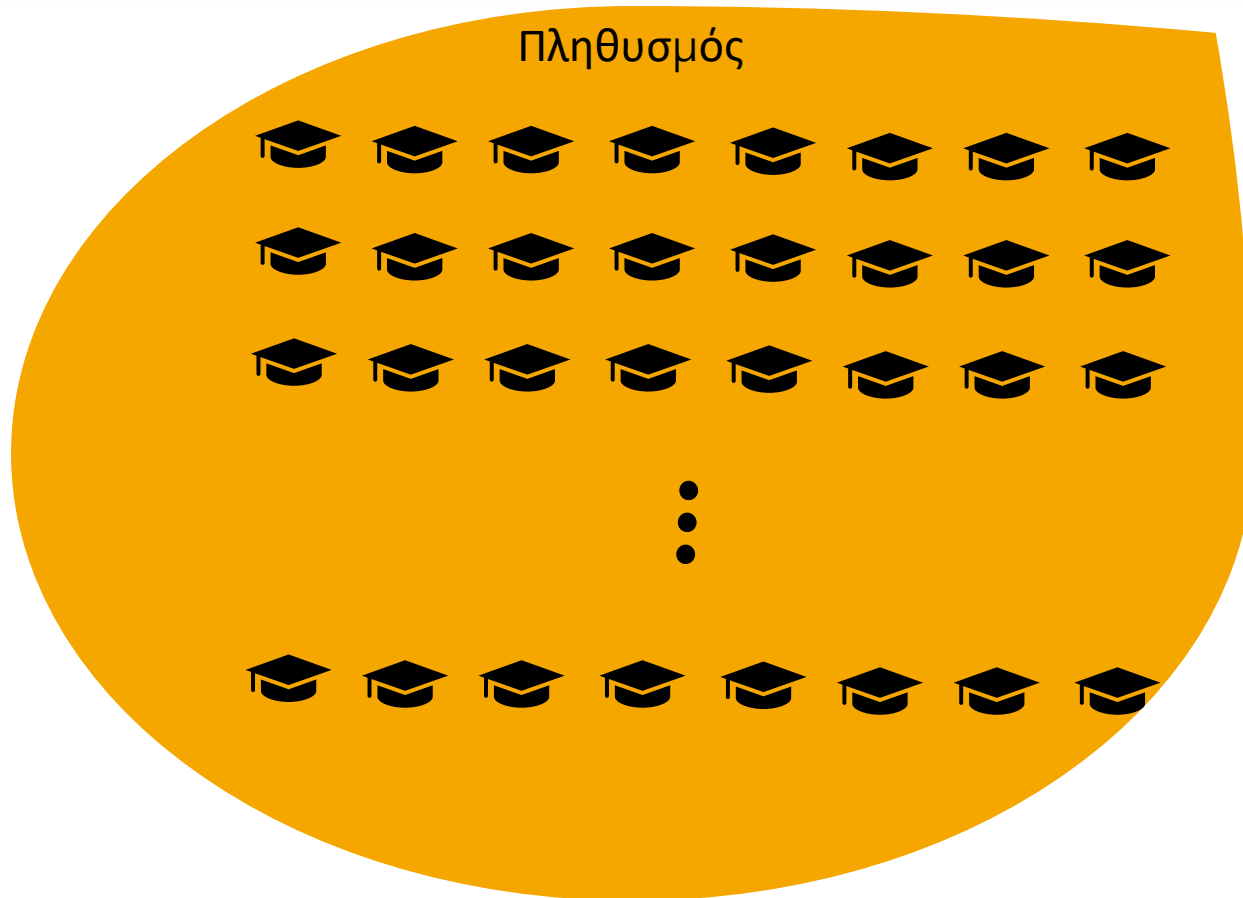


10^ο κεφάλαιο



Βασική ιδέα




Βασική ιδέα



Βασική ιδέα



Βασική ιδέα



Βασική ιδέα



Τυχαίο δείγμα



Τι μπορούμε να πούμε
για τον πληθυσμός
βασισμένοι στο δείγμα;

Βασική ιδέα



Τυχαίο δείγμα



Πρέπει να λάβουμε υπόψη
τον ρόλο της τυχαιότητας
κατά την επιλογή του δείγματος

Βασική ιδέα



Τυχαίο δείγμα



Η κατανομή της δειγματοληψίας
θα είναι το σημείο αναφοράς

Παράδειγμα



- Έστω ότι οι φοιτητές που λαμβάνουν μέρος στις εθνικές εξετάσεις έχουν μέσο 500 και τυπική απόκλιση 110 σε εθνικό επίπεδο.
- Σε τυχαίο δείγμα (τ.δ.) 100 τοπικών φοιτητών έχουν μέσο 533.
- Υπάρχει/συμβαίνει κάτι ιδιαίτερο στον τοπικό πληθυσμό σε σχέση με τον εθνικό;

Τρόπος εργασίας



- Καταρτίζουμε μια μηδενική υπόθεση: πχ οι τοπικοί φοιτητές δεν διαφέρουν από εκείνους σε εθνικό επίπεδο
- Η κατανομή δειγματοληψίας του μέσου για όλα τα πιθανά τυχαία δείγματα (πχ μεγέθους 100) αποτελεί το σημείο αναφοράς μας
- «Συγκρίνουμε» τον μέσο του δείγματος με την θέση του στην κατανομή δειγματοληψίας

ΣΚΕΠΤΙΚΟ

- Ο μέσος της κατανομής δειγματοληψίας του μέσου, ισούται με το μέσο το πληθυσμού
- Λαμβάνουμε υπόψη τον ρόλο του μεγέθους του δείγματος στην διακύμανση
- Αν το δείγμα «τοποθετείται» μεταξύ των εξαιρετικά σπάνιων τιμών λαμβάνουμε το κατάλληλο συμπέρασμα

Ιδιότητες



$\mu_{\bar{x}} = \mu$ Ο μέσος της κατανομής δειγματοληψίας του μέσου, ισούται με το μέσο το πληθυσμού

$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$ Το τυπικό σφάλμα του μέσου ισούται με την τυπική απόκλιση του πληθυσμού δια της τετραγωνικής ρίζας του μεγέθους του δείγματος



Παράδειγμα

- Αν λαμβάναμε δείγματα μεγέθους 100 από τον εθνικό πληθυσμό η υποθετική κατανομή δειγματοληψίας θα ήταν



$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}} = \frac{110}{\sqrt{100}} = \frac{110}{10} = 11$$

(για καλύτερη απεικόνιση σημειώνουμε αποστάσεις με βάση το τυπικό σφάλμα του τοπικού δείγματος)


Κοινά αποτελέσματα

- Ένας παρατηρούμενος δειγματικός μέσος θεωρείται κοινό αποτέλεσμα αν δεν διαφέρει πολύ από τον μέσο της κατανομής δειγματοληψίας
- Υποδηλώνει έλλειψη απόδειξης ότι συμβαίνει κάτι ιδιαίτερο σε σχέση με το δείγμα του προς εξέταση πληθυσμού
- Ενδεχομένως η μικρή διαφορά είναι αποτέλεσμα της δειγματοληψίας

Σπάνια αποτελέσματα





- Ένας παρατηρούμενος δειγματικός μέσος θεωρείται σπάνιο αποτέλεσμα αν διαφέρει σημαντικά από τον μέσο της κατανομής δειγματοληψίας
- Υποδηλώνει την ύπαρξη απόδειξης ότι συμβαίνει κάτι ιδιαίτερο σε σχέση με το δείγμα του προς εξέταση πληθυσμού

Τα όρια σηματικά



Τυποποίηση της κατανομής δειγματοληψίας

- Για λόγους κοινής αντιμετώπισης μετατρέπουμε την κατανομή δειγματοληψίας σε τυποποιημένη μορφή




0.00	0.0000	5000	0.56	2123	2877	1.12	3585	1314
0.01	0.0040	4950	0.57	2157	2843	1.13	3709	1292
0.02	0.0080	4900	0.58	2190	2800	1.14	3729	1271
0.03	0.0120	4850	0.59	2224	2756	1.15	3749	1251
0.04	0.0160	4800	0.60	2257	2713	1.16	3770	1230
0.05	0.0199	4801	0.61	2291	2670	1.17	3790	1210
0.06	0.0239	4761	0.62	2324	2626	1.18	3810	1190
0.07	0.0279	4721	0.63	2357	2583	1.19	3830	1170
0.08	0.0319	4681	0.64	2389	2541	1.20	3849	1151
0.09	0.0359	4641	0.65	2422	2500	1.21	3869	1131
0.10	0.0398	4602	0.66	2454	2458	1.22	3888	1112
0.11	0.0438	4562	0.67	2486	2416	1.23	3907	1093
0.12	0.0478	4522	0.68	2517	2375	1.24	3925	1075
0.13	0.0517	4483	0.69	2549	2334	1.25	3944	1056
0.14	0.0557	4443	0.70	2580	2293	1.26	3962	1038
0.15	0.0596	4404	0.71	2611	2253	1.27	3980	1020
0.16	0.0636	4364	0.72	2642	2213	1.28	3997	1003
0.17	0.0675	4325	0.73	2673	2173	1.29	4015	985
0.18	0.0714	4286	0.74	2704	2134	1.30	4032	968
0.19	0.0753	4247	0.75	2734	2095	1.31	4049	951
0.20	0.0793	4207	0.76	2764	2056	1.32	4066	934
0.21	0.0832	4168	0.77	2794	2017	1.33	4082	918
0.22	0.0871	4129	0.78	2823	1978	1.34	4099	901
0.23	0.0910	4090	0.79	2852	1939	1.35	4115	885
0.24	0.0949	4052	0.80	2881	1900	1.36	4131	869
0.25	0.0987	4013	0.81	2910	1861	1.37	4147	853
0.26	0.1026	3974	0.82	2939	1822	1.38	4162	838
0.27	0.1064	3936	0.83	2967	1783	1.39	4177	823
0.28	0.1103	3897	0.84	2995	1744	1.40	4192	808
0.29	0.1141	3859	0.85	3023	1705	1.41	4207	793
0.30	0.1179	3821	0.86	3051	1666	1.42	4222	778
0.31	0.1217	3783	0.87	3079	1627	1.43	4236	764
0.32	0.1255	3745	0.88	3106	1588	1.44	4251	749
0.33	0.1293	3707	0.89	3133	1549	1.45	4265	735
0.34	0.1331	3669	0.90	3159	1510	1.46	4279	721
0.35	0.1368	3632	0.91	3186	1471	1.47	4292	708
0.36	0.1406	3594	0.92	3212	1432	1.48	4306	694
0.37	0.1443	3557	0.93	3238	1393	1.49	4319	681
0.38	0.1480	3520	0.94	3264	1354	1.50	4332	668
0.39	0.1517	3483	0.95	3289	1315	1.51	4345	655
0.40	0.1554	3446	0.96	3315	1276	1.52	4357	643
0.41	0.1591	3409	0.97	3340	1237	1.53	4370	630
0.42	0.1628	3372	0.98	3365	1198	1.54	4382	618
0.43	0.1664	3335	0.99	3389	1159	1.55	4394	606
0.44	0.1700	3300	1.00	3413	1120	1.56	4406	594
0.45	0.1736	3264	1.01	3438	1081	1.57	4418	582
0.46	0.1772	3229	1.02	3461	1042	1.58	4429	571
0.47	0.1808	3192	1.03	3485	1003	1.59	4440	559
0.48	0.1844	3156	1.04	3508	964	1.60	4450	548
0.49	0.1879	3121	1.05	3531	925	1.61	4460	537
0.50	0.1915	3085	1.06	3554	886	1.62	4474	526
0.51	0.1950	3050	1.07	3577	847	1.63	4484	516
0.52	0.1985	3015	1.08	3599	808	1.64	4495	505
0.53	0.2019	2981	1.09	3621	769	1.65	4505	495
0.54	0.2054	2946	1.10	3643	730	1.66	4515	485
0.55	0.2088	2912	1.11	3665	691	1.67	4525	475

Μετατροπή δειγματικού μέσου σε συμβατή μορφή

$$z = \frac{\bar{X} - \mu_{hyp}}{\sigma_{\bar{x}}}$$



$$z = \frac{533 - 500}{11} = \frac{33}{11} = 3$$



«Σιωπηρές» υποθέσεις



- Ο έλεγχος z (δηλαδή ο στατιστικός έλεγχος που εκτιμά πόσο αποκλίνει ο παρατηρούμενος δειγματικός μέσος σε μονάδες τυπικού σφάλματος σε σχέση με το την υποτιθέμενη κατανομή δειγματοληψίας του μέσου), είναι ακριβής όταν:
- Ο πληθυσμός κατανέμεται κανονικά ή το δείγμα είναι μεγάλο ώστε να εφαρμόζεται με ακρίβεια το κεντρικό οριακό θεώρημα
- Η τυπική απόκλιση του πληθυσμού είναι γνωστή

Ερωτήσεις

- Υπολογίστε την τιμή του z-test για τις παρακάτω περιπτώσεις:

$$z = \frac{\bar{X} - \mu_{\text{hyp}}}{\sigma_{\bar{X}}}$$

(a) $\bar{X} = 566; \sigma = 30; n = 36; \mu_{\text{hyp}} = 560$

(b) $\bar{X} = 24; \sigma = 4; n = 64; \mu_{\text{hyp}} = 25$

(c) $\bar{X} = 82; \sigma = 14; n = 49; \mu_{\text{hyp}} = 75$

(d) $\bar{X} = 136; \sigma = 15; n = 25; \mu_{\text{hyp}} = 146$

$$z = \frac{533 - 500}{11} = \frac{33}{11} = 3$$

Ερωτήσεις

$$(a) \quad z = \frac{566 - 560}{30 / \sqrt{36}} = \frac{6}{5} = 1.20$$

$$(b) \quad z = \frac{24 - 25}{4 / \sqrt{64}} = \frac{-1}{.5} = -2.00$$

$$(c) \quad z = \frac{82 - 75}{14 / \sqrt{49}} = \frac{7}{2} = 3.50$$

$$(d) \quad z = \frac{136 - 146}{15 / \sqrt{25}} = \frac{-10}{3} = -3.33$$

$$z = \frac{\bar{X} - \mu_{\text{hyp}}}{\sigma_{\bar{X}}}$$

Η διαδικασία βήμα προς βήμα 1/5

Διατύπωση του προβλήματος σαν ερώτημα έρευνας

Πχ ο μέσος όρος των ντόπιων φοιτητών διαφέρει από τον εθνικό μέσο

Η διαδικασία βήμα προς βήμα 2/5

Διατύπωση στατιστικών υποθέσεων:

Μηδενική υπόθεση (null-hypothesis) H_0

Εναλλακτική υπόθεση (alternative-hypothesis) H_1

Πχ $H_0: \mu=500$ και $H_1: \mu \neq 500$

Η διαδικασία βήμα προς βήμα 2/5

- Η μηδενική υπόθεση H_0 είναι το σημείο εστίασης της ερευνάς
- Υποστηρίζει ότι τίποτα διαφορετικό/ιδιαίτερο δεν συμβαίνει με το προς εξέταση πληθυσμό
- Η H_0 κάνει μια ακριβής δήλωση για ένα χαρακτηριστικό του προς εξέταση πληθυσμού
- Πρέπει να είναι διατυπωμένος με τέτοιο τρόπο ώστε να απαντά στο αρχικό πρόβλημα (1/5) μέσω της εξέτασης αν ο δειγματικός μέσος προκύπτει όντως από την υποθετική κατανομή δειγματοληψίας


Η διαδικασία βήμα προς βήμα 2/5

- Η εναλλακτική υπόθεση υποστηρίζει το αντίθετο από το H_0
- Η H_1 είναι η υπόθεση εκείνη που συνήθως ελπίζει να απόδειξη η στατιστική έρευνα και ονομάζεται και «υπόθεση έρευνας»
- Μπορεί να λάβει 3 μορφές (επόμενες διαλέξεις)

Η διαδικασία βήμα προς βήμα 3/5


Διατύπωση του κανόνα απόφασης βασισμένη σε επίπεδο σημαντικότητας α .
Η τιμή του α καθορίζει το όριο για την z -τιμή

Πχ για επίπεδο σημαντικότητας $\alpha=0.05$,
κινούμαστε σε εύρος $z \geq 1.96$ και $z \leq -1.96$



Η διαδικασία βήμα προς βήμα 3/5

- Μέσω της τιμής του επιπέδου σημαντικότητας α , καθορίζουμε το πόσο ιδιαίτερο πρέπει να είναι το παρατηρούμενο δείγμα (δηλαδή τον βαθμό σπανιότητας του παρατηρούμενου αποτελέσματος)
- Η τιμή του α , μεταφράζεται σε «πιθανότητα σπανιότητας»
- Από την επιλογή του α , υπολογίζουμε τις κρίσιμες τιμές για την τιμή του z



Η διαδικασία βήμα προς βήμα 4/5

Κάνοντας χρήση του τύπου $\sigma_{\bar{X}} = \sigma / \sqrt{n}$, όπου σ είναι η τυπική απόκλιση του πληθυσμού και n το μέγεθος του δείγματος μετατρέουμε τον δειγματικού μέσο \bar{X} σε z-μορφή

$$z = (\bar{X} - \mu) / \sigma_{\bar{X}}$$

Πχ για το δείγμα ντόπιων φοιτητών

$$\bar{X} = 533; \mu_{\text{hyp}} = 500; \sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}} = \frac{110}{\sqrt{100}} = 11$$
$$z = \frac{533 - 500}{11} = 3$$

Η διαδικασία βήμα προς βήμα 5/5

Εφαρμόζουμε τον κανόνα απόφασης κάνοντας χρήση της z -τιμής και των ορίων βάσει του επιπέδου σημαντικότητας και απορρίπτουμε ή όχι την μηδενική υπόθεση.

Πχ για $z=3 \rightarrow z \geq 1.96 \rightarrow$ απορρίπτουμε το H_0

Η διαδικασία βήμα προς βήμα 5/5

- Αξιολογούμε την σπανιότητα των παρατηρήσεων
- Το κάνουμε ποσοτικά
- Στηριζόμαστε σε προ-αποφασισμένα κατώφλια (δηλ. τιμές του α)
- Γενική αρχή «με βάση την υποθετική κατανομή δειγματοληψίας διαπιστώνουμε πόσο κεντρικά-ακραία είναι η παρατήρησή μας»
- Για ευκολία τυποποιούμε την κατανομή και την παρατήρηση

Ερωτήσεις

- Τι θα πείτε για τη H_1 για έναν στατιστικό έλεγχο z με κρίσιμες τιμές ± 1.96
 - (a) $z=1.74$
 - (b) $z=0.13$
 - (z) $z=-2.51$



Ερωτήσεις

- Οι κρίσιμες τιμές ± 1.96 αντιστοιχούν σε επίπεδο σημαντικότητας $\alpha=0.05$

(a) Διατήρηση του H_0 γιατί για $z=1.74$ ισχύει $-1.96 \leq z \leq 1.96$

(b) Διατήρηση του H_0 γιατί για $z=0.13$ ισχύει $-1.96 \leq z \leq 1.96$


(c) Απόρριψη του H_0 γιατί για $z=-2.51$ ισχύει $z \leq -1.96$



Ερμηνεία της απόφασης σε σχέση την αρχική ερώτηση

- Ανάλογα με την απόφαση ένα από τα παρακάτω συμβαίνουν:
 - Αν αποφασίσαμε να διατηρήσουμε την H_0 τότε η αρχική ερώτηση έρευνα (ανάλογα με την διατύπωσή της) λαμβάνει αρνητική απάντηση (πχ η παρακολούθηση κινουμένων σχεδίων μειώνει την επίδοση των μαθητών)
 - Αν αποφασίσαμε να απορρίψουμε την H_0 , τότε συνήθως λαμβάνουμε θετική απάντηση στην αρχική ερώτηση (πχ ο μέσος των ντόπιων φοιτητών διαφέρει από τον εθνικό μέσο)
 - Ανάλογα με το ποιον τρόπο κάνουμε την απόρριψη (πχ. $z \leq -1.96$ ή $z \geq 1.96$) μπορούμε να αποφανθούμε αν ο μέσος είναι σπάνιος/ιδιαίτερος μικρός ή μεγάλος (πχ οι ντόπιοι φοιτητές έχουν υψηλότερη μέση βαθμολογία)

Ερωτήσεις



- Από μελέτη βρέθηκε ότι το μέσο ετήσιο εισόδημα των αποφοίτων είναι \$82500 με τυπικό απόκλιση \$6000.
- Έρευνα αν οι γυναίκες αμείβονται παρομοίως
- Είναι ο μέσος αυτός ίδιος για τις γυναίκες
- Ρωτήθηκαν 100 γυναίκες και ο μέσος μισθός βρέθηκε \$80100

Συγγράμματα online (δωρεάν)

- http://courses.washington.edu/psy315/tutorials/z_test_tutorial.pdf


Σχετικά video

- <https://www.youtube.com/watch?v=0oc49DyA3hU>

**Hypothesis Testing
and the
Null Hypothesis!!!**

Σχετικά video

- https://www.youtube.com/watch?v=zJ8e_wAWUzE



Ιδιότητες

$\mu_{\bar{X}} = \mu$ Ο μέσος της κατανομής δειγματοληψίας του μέσου, ισούται με το μέσο το πληθυσμού

$\sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$ Το τυπικό σφάλμα του μέσου ισούται με την τυπική απόκλιση του πληθυσμού δια της τετραγωνικής ρίζας του μεγέθους του δείγματος