

Βασικές Γνώσεις Πιθανότητας και Στατιστικής

→ Τυχαίες μεταβλητές

- Συνεχείς
- Διακριτές → μετρήσιμο πλήθος τιμών

→ Διακριτή

$$P(X_i) = P(X=x_i) \quad \sum_{i=1}^n P(X_i) = 1.$$

→ Συνεχής

$$P(X \in B) = \int_B f(x) dx \quad \int_{-\infty}^{\infty} f(x) dx = 1$$

$$P(X=x) = P(X \in [x, x]) = \int_x^x f(y) dy = 0$$

→ $E(X)$: μέση τιμή (αναμενόμενη τιμή)

→ $\sigma^2 = E[(X-\mu)^2] = E(X^2) - \mu^2$: διασπορά ($\text{Var}(X)$)

→ $\sigma = \sqrt{\sigma^2}$: τυπική απόκλιση

$$E(X) = \sum_{i=1}^n x_i P(X_i)$$

Διακριτή

$$E(X) = \int_{-\infty}^{\infty} x f(x) dx$$

συνεχής

→ Ανελαρτυσία μεταβλητών X_i, X_j

$$E(X_i X_j) = E(X_i) \cdot E(X_j) \quad \text{αηλάρτυηη}$$

αλλιώς συσχετισμένη (correlated)

→ Μήτρικη συσχετισμώ μεταβλητών
Συδιασμανω (covariance)

$$Cov(X_i, X_j) = C_{ij} = E(X_i X_j) - \mu_i \mu_j$$

$$C_{ij} = C_{ji}$$

$C_{ij} > 0$ θετική συσχετισω ($X_i > \mu_i, X_j > \mu_j$)
τήνω μαζί

αρνητική συσχετισω
 C_{ij} δην είναι καθαρός αριθμός
Συσχετισω (correlation)

$$\rho_{ij} = \frac{C_{ij}}{\sqrt{\sigma_i^2 \sigma_j^2}}$$

Έλεγχος προσομοίωσης και στακαστικής διαρροής

Παράδειγμα

M_1/M_1 , A_1, A_2, A_3, \dots S_1, S_2, S_3, \dots

output data P_1, P_2, P_3, \dots

λογική ότι $P_1 = 0$

$$D_{i+1} = \max \{ D_i + S_i - A_{i+1}, 0 \}$$

D_i : διακριτή μεταβλητή
χρόνου

$q(t)$: συνεχής μεταβλητή
χρόνου



(α) περίπτωση



(β) περίπτωση

(β) περίπτωση $x_p A q_{i+1} > t + S_i$

$$\Rightarrow D_i = 0$$

Υπόθεση για στατιστική ανάλυση στοχαστικής διασποράς
 → σταθερή ενδοσυμμεταβολή (covariance stationary)


$$\begin{aligned} \mu_i &= \mu, & i=1,2,\dots & \quad -\infty < \mu < \infty \\ \sigma_i^2 &= \sigma^2, & i=1,2,\dots & \quad \sigma^2 < \infty \end{aligned}$$

και $\text{Cov}(X_i, X_{i+j}) = \text{Cov}_i, i+j$ ανεξαρτησία i, j

Στατιστική διασπορά, το μέσο και η διασπορά είναι σταθερά στο χρόνο, και φιλάρη:

$$\rho_j = \frac{C_{i, i+j}}{\sqrt{C_i^2 C_{i+j}^2}} = \frac{C_j}{\sigma^2} = \frac{C_j}{C_0}, \quad j=0,1,2,\dots$$

Παρατήρηση (προφανές) . $M|ML, P_1, P_2, \dots$



$$\rho = \frac{1}{\omega}$$

Ταπεινωμένο το 0 μεγαλύτερη όταν το ρ είναι μικρότερο

Όταν τα δείγματα των διασπορών αρχίζουν να φεύγουν, μάλλον δεν είναι σταθερή ενδοσυμμεταβολή (πριν ληφθεί το κενό)

Η ανωτέρω υπόθεση είναι σημαντική γιατί μετράει τον επηρεασμό των οποίων κινείται αυθαίρετα με σταθερή ενδοσυμμεταβολή τέτοι.

Επιτιμήσει μέσων, διασποράς, συσχέτιστων

Υπόθεση: X_1, X_2, X_3 τυχαίες μεταβλητές (παρατηρήσεις).

Ζητούμενο:

με μ, σ^2 , αξία μεταβλητών

Θέλουμε να υπολογίσουμε (επιτιμήσουμε) τα μ, σ^2

$$\bar{X}(n) = \sum_{i=1}^n X_i / n \leftarrow \text{συμμεσώι επιτιμητιύτату μ .$$

(για n πληράματα, $n \rightarrow \infty$, ο μ.σ των $\bar{X}(n)$ είναι το μ)

$$S^2(n) = \frac{\sum_{i=1}^n [X_i - \bar{X}(n)]^2}{n-1} \leftarrow \text{συμμεσώι επιτιμητιύτату σ^2 .$$

Πόσο υποβή είναι το $\bar{X}(n)$ στο μ ?

→ υποσυνθηή διασπώματα ηριστοσώμη για το μ .

→ άρα πρέπει να υποβήσεται το $\text{Var}[X(n)] = \frac{1}{n^2} n \sigma^2 = \frac{\sigma^2}{n}$.

$$\text{Αρα } \hat{\text{Var}}[X(n)] = \frac{\sum_{i=1}^n [X_i - \bar{X}(n)]^2}{n(n-1)}.$$

Αν X_i ανεπίτητα, $\rho_j = 0$

Επισηρία διακρηστί X_1, X_2, X_3, \dots είναι λήσση ανεπίτητα μέσων (simulation output data).

Αρα X_1, X_2, \dots είναι σπομσ σποδτήρη ανεπίσσημσσώμη διακρηστίσση

Συγχτίλημα Output Data

Αρα: $\bar{X}(n)$ παρατήρη σημασιολογική τιμή των μ
Ακρίβεια για το $S^2(n)$ ισχύει ότι

$$E(S^2(n)) = \sigma^2 \left[1 - 2 \frac{\sum_{i=1}^{n-1} (1 - i/n) \rho^i}{n-1} \right]$$

Αρα $E(S^2(n)) < \sigma^2$

$$\text{Ισχύει επίσης ότι } \text{Var}[\bar{X}(n)] = \sigma^2 \frac{\sum_{i=1}^{n-1} (1 - i/n) \rho^i}{n}$$

Αρα για τον εκτιμητή του $\text{Var}[\bar{X}(n)]$, ισχύουν τα ακόλουθα

1. $\text{Var}[\bar{X}(n)] \neq \frac{\sigma^2}{n}$

2. Το $S^2(n)$ δεν αποτελεί εκτιμητή του σ^2 .

Τελικά ισχύει ότι $E(S^2(n)) = \frac{[n/d(n)] - 1}{n-1} \text{Var}[\bar{X}(n)]$.

↑
ακριβή εκτίμηση

Παραδειγμα π.ρ. τιμές

Συμπέρασμα

1. Output data correlated
2. κλασική στατ. μέθοδο για απ. διαφορών δε εφαρμόζονται
3. Η κλασική ομαδοποίηση εφαρμόζεται (indirectly applicable) ώστε να εφαρμοστούν οι τύποι της κλασικής στατιστικής.

Διαστήματα εμπιστοσύνης και Τέτα Υπόθεσι διαστήματος

X_1, X_2, X_3, \dots IID τυχαίες μεταβλητές, με μ, σ^2 .
Ζητούμενο: κατασκευή διαστήματος εμπιστοσύνης για το μ .
Θεώρημα κεντρικού ορίου

$$Z_n = [\bar{X}(n) - \mu] / \sqrt{\sigma^2/n}$$

Αν το $n \rightarrow \infty$, η Z_n θα καταistribείται σύμφωνα με την τυπική κανονική κατανομή, άρα κατανομή των X_i .

Επίσης $X(n) \sim N(\mu, \frac{\sigma^2}{n})$

Ερώτημα: πού είναι το σ^2 ?

Υποθέτουμε $S^2(n)$ προσεγγίζει το σ^2 , $n \rightarrow \infty$

Άρα $t_n = [\bar{X}(n) - \mu] / \sqrt{\frac{S^2(n)}{n}} \sim$ τυπική κανονική

Άρα $P(-z_{1-\alpha/2} \leq t_n \leq z_{1-\alpha/2}) = P(\bar{X}(n) - \dots \leq \mu \leq \bar{X}(n) + \dots)$
 $\approx 1 - \alpha$

Άρα $100(1-\alpha)\%$ δ.ε. για το μ είναι το:

$$\bar{X}(n) \pm z_{1-\alpha/2} \sqrt{\frac{S^2(n)}{n}}$$

Πρακτική:

Αν υποθέσουμε ότι μ δ.ε., το ποσοστό που καλύπτεται το μ είναι $1-\alpha$. (coverage)

Δηλαδή, επιλέγεται η κλίμακα υπολογισμού η δ.ε. και το ποσοστό $1-\alpha$ το μ θα κληρονομηθεί σταυτά.

Διαστήματα εμπιστοσύνης και φίλτρα υπόθεσης στατιστικό

Διαστήματα προσδιορισμού του 'αριθμού μεγάλων' n .

Ευχαιριστική, αν $X_i \sim N(\mu, \sigma^2)$, τη ακολουθία των t κατανομών και $100(1-\alpha)\%$ είναι το

$$\bar{X}(n) \pm t_{n-1, 1-\alpha/2} \sqrt{\frac{S^2(n)}{n}}$$

το διάστημα εμπιστοσύνης

Το ανώτερο δ.ε. είναι μεγαλύτερο εποστοπραχάρινο και η μεγαλύτερη κλάση, άρα από την κατανομή X_i . Συνίσταται, συνήθως, η χρήση απλά τα δ.ε.

παράδειγμα 1: 10 τιμές παρατηρήσεων X_1, X_2, \dots, X_{10}

συνολός: υποθετική 90% δ.ε. για το μ .

$$\bar{X}(10) = 1.34 \quad S^2(10) = 0.17$$

$$\text{δ.ε.} : \bar{X}(10) \pm t_{9, 0.05} \sqrt{\frac{S^2(10)}{10}} = 1.34 \pm 0.24 = [1.10, 1.58]$$

παράδειγμα 2: επιμήκειν βελιερνεις σε 500 κηράματα διαφορετική κατανομή, 10 παρατηρήσεις / κηράμα

ωστε $n \rightarrow 90\%$ όταν $n \rightarrow \infty$.

ωστε n μικρά όταν μεγάλωσα η ασυμμετρία (σκέωκερ)

$$v = \frac{E[(X-\mu)^3]}{(s^2)^{3/2}}, \quad -\infty < v < \infty.$$

Ελεγχος υπόθεσης για το μέσο

$X_1, X_2, X_3, \dots \sim$ κοινή κατανομή, μ, σ^2

Ελεγχος υπόθεσης $H_0: \mu = \mu_0$

Αν $|\bar{X}(n) - \mu|$ μεγάλο, υπόθεση δεικνύει
point estimator

→ Θέλουμε στατιστική μέθοδο με δυνατή κατανομή
όταν το H_0 αληθινό.

$t_n = \frac{[\bar{X}(n) - \mu_0] \sqrt{n}}{S^2(n)} \sim t$ κατανομή

Υπόθεση $t_n \begin{cases} > t_{n, 1-\alpha/2} & \text{απορριψη } H_0 \\ < t_{n, \alpha/2} & \text{αποδοχή } H_0 \end{cases}$

Το ποσοστό στατιστικά υπέρ $|x| > t_{n, 1-\alpha/2}$ ονομάζεται
υπίσχυση κριτικής για τον έλεγχο.

Αν H_0 αληθινό, ποσοστό = α (level of the test)

Δύο είδη λαθών: Type I απορριψη αληθινού (α)
Type II αποδοχή ψευδούς (β)

$\beta = 1 - \alpha$: δύναμη του τεστ (power)
← απορριψη όταν ψευδής υπόθεση

→ Παράδειγμα

→ Το β αποτελεί καθάρτητα της διαφοράς σ^2

Απιναστάσταση κατανομής λιθανότητας με το μέσο της

• Πρακτική με αλγόριθμο αποκρίσματα?

→ A_1, A_2, A_3, \dots interval times \sim exponential

→ Αππ για διαγραμμίση, $A_i =$ μέσο κατανομής (1)

Παράδειγμα

M|M|L

$A_1, A_2, A_3, \dots \sim$ exponential(1)

$S_1, S_2, S_3, \dots \sim$ exponential(0.99)

Utilisation = 0.99.

$d = 98.01$ (προκύπτει από αναλυτικούς υπολογισμούς)

Αν όμως $A_1 = 1, A_2 = L$ κτλ., δαλ γίνεται εκκρίση
1, 2, 3. και $S_1 = 0.99 = S_2 = S_3$ κτλ., τότε

$d = 0$. (προφανής αποτυχία).

Κατασκευή Αξιόπιστων Μοντέλων Προσομοίωσης

- Αξιοπιστία μοντέλου
- Αποτίμηση (validation) και επαλήθευση (verification)
- Διαδικασία ελέγχου αξιοπιστίας κατά τις φάσεις μοντελοποίησης
- Ανάλυση εξόδου προϋποθέτει διασφάλιση της αξιοπιστίας
 - στατιστικό πρόβλημα που περιλαμβάνει τον καθορισμό:
 - μήκος τρεξίματος (run length)
 - αριθμός επαναλήψεων (replication number)

Κατευθυντήριες Γραμμές για την Κατασκευή Αξιόπιστων Μοντέλων

- Προσδιορισμός χαρακτηριστικών μοντέλου που πρέπει να περιληφθούν και μπορεί να αγνοηθούν
- Προσδιορισμός αντικείμενου μελέτης, μεγεθών απόδοσης, τρόπου αξιοποίησης μοντέλου, εναλλακτικών τρόπων σύνθεσης συστήματος, ...
- Αξιοποίηση ειδικών για τον καθορισμό του επιπέδου λεπτομέρειας.
 - όχι μεγαλύτερο από το αναγκαίο
 - περιορισμοί κόστους και χρόνου
- Χρήση μη τελικού μοντέλου ή αναλυτικού μοντέλου για τον προσδιορισμό των σημαντικών παραγόντων απόδοσης του συστήματος
- Αντιστοιχία με την ανάλυση συστημάτων
 - διάθεση ανθρώπινων πόρων για την ορθή περιγραφή του συστήματος

Επαλήθευση

- Οικτώ προτεινόμενες τεχνικές
 1. Τμηματοποιημένη ανάπτυξη προγράμματος
 2. Ομάδα ανάπτυξης λογισμικού - όχι μονομελής
 3. Τρέξιμο μοντέλου υπό διαφορετικές συνθήκες εισόδου
 4. Ιχνηλάτηση (tracing)
 5. Τρέξιμο υπό απλοποιημένες συνθήκες με γνωστή συμπεριφορά
 6. Κινητική απεικόνιση
 7. Αντιπαράβολή θεωρητικού μέσου και διασποράς και αντίστοιχων τιμών κατανομών εισόδου
 8. Πακέτα προσομοίωσης

Αποτίμηση

- Πειραματισμός αποτελεί προσέγγιση πραγματικής εξέλιξης του συστήματος
- Ευκολία αποτίμησης συναρτάται από την πολυπλοκότητα και τη φύση του συστήματος
- Μοντέλο αποτελεί μια προσέγγιση του συστήματος
- Μοντέλο αναπτύσσεται για ένα αντικειμενικό σκοπό (objective)
- Υποθέσεις κατά την ανάπτυξη του μοντέλου πρέπει να συνοδεύσουν την τελική του τεκμηρίωση
- Αποτίμηση πρέπει να πραγματοποιείται πάντα για τα μεγέθη που αξιολογούνται στη λήψη αποφάσεων
- Αποτίμηση δεν πραγματοποιείται στο τέλος της ανάπτυξης, και αν υπάρξουν διαθέσιμα κονδύλια
- Μη εφικτή η τυπική στατιστική σύγκριση μεταξύ δεδομένων προσομοίωσης και συστήματος

Προσέγγιση Τριών Φάσεων για την Ανάπτυξη Αξιόπιστων Μοντέλων

1. Ανάπτυξη μοντέλου με υψηλό βαθμό αξιοπιστίας προς τα έξω
 - συζητήσεις με τους ειδικούς του συστήματος
 - συλλογή παρατηρήσεων από το σύστημα ή παρεμφερή προς αυτό συστήματα
 - αξιοποίηση θεωρητικής γνώσης
 - αξιοποίηση αποτελεσμάτων από συναφή μοντέλα προσομοίωσης
 - εμπειρία/διαίσθηση
- Αλληλεπίδραση με την διοίκηση του υπό μελέτη συστήματος
- Εκτέλεση βήμα-προς-βήμα του ιδεατού μοντέλου πριν την έναρξη της κωδικοποίησης του

Προσέγγιση Τριών Φάσεων για την Ανάπτυξη Αξιόπιστων Μοντέλων

2. Εμπειρικός έλεγχος των υποθέσεων του μοντέλου

- Ποσοτικός έλεγχος υποθέσεων
- Ανάλυση ευαισθησίας (sensitivity analysis)
 - βαθμός επίδρασης μεταβολής παραμέτρου εισόδου στην συμπεριφορά του μοντέλου.
 - χρήση κοινών τυχαίων αριθμών για τους ελέγχους για επιμέρους παράγοντες

Προσέγγιση Τριών Φάσεων για την Ανάπτυξη Αξιόπιστων Μοντέλων

3. Προσδιορισμός ορθότητας αναπαράστασης του συστήματος μέσω των δεδομένων προσομοίωσης
- Για υφιστάμενο σύστημα, σύγκριση δεδομένων και ενδεχόμενη μεταβολή μοντέλου
 - Στατιστικά τεστ για τον έλεγχο μεταξύ των δεδομένων μοντέλου και συστήματος
 - Συμβατικές μέθοδοι όχι άμεσα εφαρμόσιμες (προϋποθέτουν IID data)
 - συσχετιζόμενα δεδομένα (correlated)
 - μεταβολή παραμέτρων κατανομών κατά την εκτέλεση του πειράματος (non stationary)
 - έλεγχος πεδίου (field test) μεταξύ μοντέλου και συστήματος υπό καθορισμένες συνθήκες. Στη συνέχεια τρέξιμο μοντέλου υπό νέες συνθήκες
 - αξιοποίηση μοντέλου για πρόβλεψη
 - model calibration
 - πρέπει να πραγματοποιείται με περισσότερα από ένα σύνολα δεδομένων εισόδου.

Στατιστική Διαδικασία για τη σύγκριση
αποκλεισμένων Προσομοιώσεων και Πραγματικών Παρατηρήσεων

$R_1, R_2, R_3, \dots, R_k$ πρ. παρατηρήσεις

$M_1, M_2, M_3, \dots, M_l$ δεδομένα προσομοίωσης

Ζητούμενο

Αναπαρέσταση των πρ. συστημάτων είναι αυριβής?

→ Τα γνωστά στατιστικά εργαλεία (t , 2-sample chi-square)
δεν είναι άμεσα εφαρμόσιμα.

→ Προσομοίωση - συχνηθισμένα δεδομένα.

Προσεγγίσεις

1. Κιωδολογία

2. Διαστήματα \leftarrow συχνηθισμένα προσέγγιση κιωδολογίας
Εμπιστοσύνη

3. Χρονοβελτιστές βερσιές

Πρακτική Επισκόπηση

- Ευρύτερα διαδεδομένη
- Σύγκριση 2 ενώσεων δεδομένων πόδων (μαπίλα, βυστήματα) χωρίς τυπική στατιστική μέθοδο
- Κάθε στατιστική σύγκριση γίνεται μερικό ενός δείγματος μεγέθους n , άρα υπόκειται στην τυχαίατητα των κριτών ληφθέντων και δείγματος του πραγματικού συστήματος.

Παράδειγμα

Σύστημα M/M/1 $p=0.6$

Μαπίλο M/M/1 $p=0.5$

output process $D: D_1, D_2, \dots$

$$X = \frac{\sum_{i=1}^n D_i}{n} \quad (\text{βύστημα}) \quad Y = \frac{\sum_{i=1}^n D_i}{n} \quad (\text{μαπίλο})$$

Αριθμοί παρατηρήσεων: 200

$\mu_x = E(X) = 0.87$
 $\mu_y = E(Y) = 0.49$
 (< 44% λιγότερο)

Πόσο κοντά είναι το μαπίλο στο βύστημα?
 \rightarrow πόσο κοντά είναι η εκτίμηση τα μ_y στην εκτίμηση τα μ_x .

Πείραξη	$\hat{\mu}_x$	$\hat{\mu}_y$	$\hat{\mu}_x \hat{\mu}_y$
1	0.9	0.7	0.2
2	0.7	0.71	0.01 \leftarrow
3	1.08	0.35	0.73

Συσχετισμένη προσέγγιση τρισδιάστατα

- Συστήμα και μοντέλο δεχονται τα ίδια δεδομένα κώδων
- Συμπίεση δεδομένων κώδων
- Ιστορικά δεδομένα κώδων
→ αυξάνεται για χρήση σε "παραγωγικά" λειτουργία
- Δεδομένα κώδων κωδικοποιούνται πριν συμπίεση σε μεγαλύτερο βαθμό

Παράδειγμα

Σύστημα M|M|S (bank, steller) + jockeying
Μοντέλο M|M|S με jockeying

χ : average delay in system

γ : average delay in model (συσχετισμένη)

γ' : average delay in model (όχι συσχετισμένη)

- Καλύτερη επίδοση της διαφοράς μεταξύ μικρής και μεγάλης διαφοράς.

- Αριθμός παραμέτρων : 500

Μέσος $\chi_j - \gamma_j = 0.75$ $\chi_j - \gamma_j' = 0.60$

Διασπορά $\chi_j - \gamma_j = 0.08$ $\chi_j - \gamma_j' = 4.08$