

Υπολογιστική Φυσική Στοιχειωδών Σωματιδίων

4ο Εξάμηνο 2005-2006

Στατιστική
Πιθανότητες-Κατανομές

Διδάσκοντες : Χαρά Πετρίδου
Δήμος Σαμψωνίδης

Πιθανότητες

- **Ορισμός 1 -Μαθηματικός:** $P(A)$ είναι αριθμός που πληρεί τα αξιώματα του Kolmogorov

$$P(A) \geq 0$$

$$P(A_1 \vee A_2) = P(A_1) + P(A_2)$$

$$\sum P(A_i) = 1$$

- ΔΕΝ δίνει πληροφορία ο μαθηματικός ορισμός!

Πιθανότητες

- Ορισμός 2 : Κλασσικός ορισμός

Η πιθανότητα $P(A)$ είναι η ιδιότητα ενός αντικειμένου που καθορίζει πόσο συχνά συμβαίνει ένα γεγονός A . Δίνεται από την συμμετρία για εξίσου πιθανά γεγονότα. Γεγονότα όχι το ίδιο πιθανά τα θεωρούμε εξίσου πιθανά


Παράδειγμα : ρίχνουμε ένα νομισμα : $P(H) = 1/2$

Ρίχνουμε δύο ζάρια : $P(8) = 5/36$? ή $P(8) = 6/36$?

Προβλήματα με τον κλασσικό ορισμό

1. Ποτε πρόκειται για εξισου πιθανές περιπτώσεις? Αν ρίξουμε δύο νομίσματα έχουμε 3 ή 4 ίσες δυνατότητες?
2. Τι κανουμε σε περιπτώσεις που έχουμε συνεχείς μεταβλητές? Πως να χωρίσουμε ένα τρίγωνο σε δύο τυχαία μέρη?

Έχουμε λύση



Δεν Έχουμε λύση

Πιθανότητες - Συχνότητα

- **Ορισμός 3 -Frequentist** ('συχνάζουσα' πιθανότητα)

Η πιθανότητα $P(A)$ είναι το όριο του λόγου $N(A)/N$ (σε ένα σύνολο N με ιδιότητα A)


$$P(A) \underset{N \rightarrow \infty}{=} \frac{N(A)}{N}$$

Πρόβλημα (περιορισμός) με τον ορισμό της 'συχνάζουσας' πιθανότητας


- Η $P(A)$ εξαρτάται και από το A και από το σύνολο N . Η πιθανότητα που υπολογίζουμε μπορεί να είναι παραπλανητική αν βασιστούμε στην συχνότητα του γεγονότος :
... 10 στους 30 ανθρώπους σε ένα σύνολο είναι 'πλούσιοι' $\Rightarrow P(\text{πλούσιος}) = 1/3$!!!

Συνέπειες για την Κβαντομηχανική (QM)

- Στην QM υπολογίζουμε πιθανότητες



- Οι πιθανότητες εξαρτώνται από το **είδος των γεγονότων** που έχουμε (π.χ. Λ^0) και **την αλληλεπίδραση**



PDG: $P(p\pi^-)=0.639$

$P(n\pi^0)=0.358$


Το πρόβλημα με τον ορισμό της 'συχνάζουσας' πιθανότητας

- ΔΕΝ μπορεί να εφαρμοστεί σε μεμονωμένα γεγονότα !
 - ... η έκφραση 'πιθανόν να βρέξει αύριο' ΔΕΝ είναι επιστημονική !!!
Ενω : 'η δήλωση "πιθανόν να βρέξει αύριο" είναι σωστή' είναι
 - Η ανακάλυψη ή όχι του Higgs
 - Η ανακάλυψη ή όχι σκοτεινής ύλης

Ορισμός της υποκειμενικής πιθανότητας (Bayesian)

- $P(A)$ είναι η πιθανότητα που **δίνουμε** στην ιδιότητα A να υπάρξει.
- Το A μπορεί να είναι ο,τιδήποτε. Νέα θεωρία, νέο σωματίδιο, διάσπαση σωματιδίου, ... βροχή, ... ένα στοίχημα...

Το Θεώρημα του Bayes



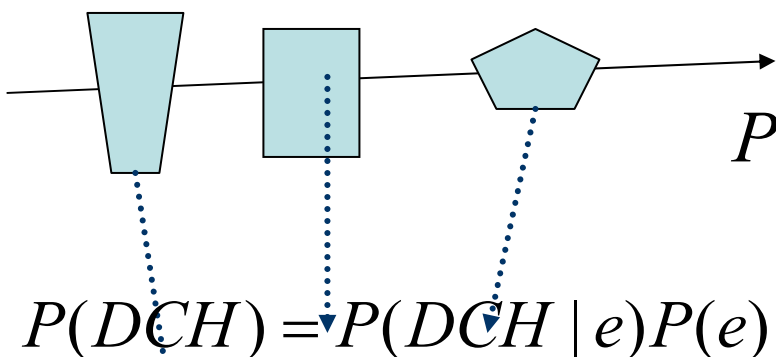
- Υπό όρους πιθανότητα (conditional probability) : $P(A|B)$ είναι η πιθανότητα των κοινών σημείων των A και B σε σχέση με το σύνολο B και η $P(A \cap B)$ σε σχέση με το Ω
- $P(A \cap B) = P(A|B) * P(B)$
 $= P(B|A) * P(A) \Rightarrow$

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

Γνωρίζουμε την πιθανότητα να συμβεί B όταν συμβαίνει A και υπολογίζουμε την αντίστροφη πιθανότητα

Εφαρμογή του Θεωρήματος Bayes για την συχνάζουσα πιθανότητα

- Ταυτοποίηση σωματιδίων
- -Τύποι σωματιδίων : e , π , μ , K , p
- -Σήματα απο ανιχνευτές: DCH, RICH, TOF, TRD




$$P'(e) = P(e | DCH) = \frac{P(DCH | e) P(e)}{P(DCH)}$$

$$P(DCH) = P(DCH | e)P(e) + P(DCH | \mu)P(\mu) + P(DCH | \pi)P(\pi) \dots$$

- Αντίστοιχα υπολογίζουμε την $P(e|RICH)$ κλπ (δηλ. σήμα στον ανιχνευτή να οφείλεται σε e)

Παράδειγμα χρήσης του θεωρήματος Bayes με την συχνάζουσα πιθανότητα



- Δεσμη αποτελείται από π's & e's
 $N_e/N_\pi=10^{-3}$
- Το σύστημα σκανδαλισμού:
 $\epsilon_e=0.98, \epsilon_\pi=0.03$
 $P(e)=10^{-3} P(\pi)=1-10^{-3}$
 $P(T|e)=0.98, P(T|\pi)=0.03$
- $P(e|T)=P(T|e)*P(e)/(P(T|e)*P(e)+P(T|\pi)P(\pi))$
είναι η πιθανότητα το εισερχόμενο σωματίο να είναι ηλεκτρόνιο όταν το σύστημα σκανδαλισμού λέει 'ναι'


Το θεώρημα Bayes και η υποκειμενική πιθανότητα

$$P(\textit{Theory}|\textit{Result}) = \frac{P(\textit{Result}|\textit{Theory})}{P(\textit{Result})} P(\textit{Theory})$$

- Η εκ των προτέρων 'πίστη' σε μια θεωρία αλλάζει με βάση τα πειραματικά αποτελέσματα :
- Εάν $(P(\textit{Result}|\textit{Theory}) = 0$, (η Θεωρία απαγορεύει το πειραματικό αποτέλεσμα) \Rightarrow η Θεωρία δεν ισχύει
- Εάν $(P(\textit{Result}|\textit{Theory}) = \text{Μεγάλο}$, ενισχύεται η πίστη μας στη Θεωρία

Πρόβλημα με την υποκειμενική πιθανότητα

- Η πιθανότητα 'μου' $P(A)$ και η πιθανότητα $P(A)$ ενός τρίτου μπορεί να διαφέρουν...
- **Αλλα** οι επιστήμονες θάπρεπε να είναι αντικειμενικοί!
- Δικαιολογείται η άγνοια να δηλώνεται με $P(A)=flat?$ (αν το A παίρνει διακριτές τιμές το ίδιο πιθανές, ναι. Αν συνεχής μεταβλητή, π.χ. M_{higgs} διαφορετική υπόθεση θα δώσει άλλα αποτελέσματα)



Συνάρτηση Πυκνότητας Πιθανότητας-Κατανομές

- Ορίσαμε τη Πιθανότητα
- Όταν μετρούμε ένα παρατηρήσιμο μέγεθος πολλές φορές, το αποτέλεσμα x κατανέμεται σύμφωνα με μία **κατανομή πιθανότητας (probability distribution)**
- Το αποτέλεσμα έχει μια διακύμανση είτε λόγω κατ'οίκον παραμέτρων (π.χ. ηλεκτρονικό θόρυβο) είτε λόγω διακύμανσης του φυσικού φαινομένου (π.χ. διάσπαση ή σκέδαση σωματιδίων)
- Οι κατανομές πιθανότητας μπορεί να είναι διακριτές ή συνεχείς.

Πιθανότητα vs Στατιστικής

- **Πιθανότητα: απο την θεωρία στα δεδομένα**
 - Υπολογίζουμε όλα τα πιθανά αποτελέσματα (συνέπειες) ενός πειράματος για συγκεκριμένο πρόβλημα
- **Στατιστική: απο τα δεδομένα στη θεωρία**
 - Λύνουμε το αντίστροφο πρόβλημα: απο τα δεδομένα προσπαθούμε να βρούμε τους κανόνες-νόμους=> **ανάλυση των δεδομένων**
 - => Υπολογισμός παραμέτρων και του σφάλματος
 - => έλεγχος της υπόθεσης: πιστότητα, συμφωνία...

Συναρτήσεις Πυκνότητας Πιθανότητας

- Επανειλημμένη μέτρηση -πειραματικά- μιας συνεχούς μεταβλητής x
- Ορισμός : η πιθανότητα P να μετρήσουμε μια τιμή x στο διάστημα $(x, x+dx)$ δίνεται από την συνάρτηση πυκνότητας πιθανότητας :
probability density function $f(x)$ (p.d.f.) :
 $P=f(x) dx$
 - Είναι το μέτρο του πόσο συχνά η τιμή x εμφανίζεται σένα δείγμα

$$Norm = \int_{x \min}^{x \max} f(x') \cdot dx' = 1$$

Κατανομές-ιδιότητες

- Αναμενόμενη τιμή = Μέση τιμή

$$E[x] \equiv \int_{x \min}^{x \max} x \cdot f(x) \cdot dx = \langle x \rangle = \mu$$


- Διασπορά -Variance = σ^2 = το τετράγωνο της απόκλισης σ Μετράει την διασπορά του x σε σχέση με την μέση τιμή

$$V[x] = E((x - \mu)^2) \equiv \int_{x \min}^{x \max} (x - \mu)^2 f(x) \cdot dx = \sigma^2$$

$$\equiv \langle (x - \mu)^2 \rangle \equiv \langle x^2 \rangle - \mu^2$$

Παραδείγματα

- Ο χρόνος ζωής t σωματιδίου στο σύστημα ηρεμίας του π.χ. Το πιόνιο : μέσος χρόνος ζωής $\tau_{\pi} = 2.6 \cdot 10^{-8}$ sec





$$f(t; \tau) = \frac{1}{\tau} e^{-\frac{t}{\tau}}$$

$$E[t] = \tau$$

$$V[t] = \tau^2$$

Παραδείγματα

- Κατανομή της πολικής γωνίας θ του μιονίου στην σκέδαση $ee \rightarrow \mu\mu$




$$\frac{1}{\sigma_{tot}} \frac{d\sigma}{d\cos\theta} =$$
$$\equiv f(\cos\theta) = \frac{3}{8} [1 + (\cos\theta)^2]$$

Κατανομές-Διακριτές κατανομές

- Διωνυμη κατανομή: η τυχαία μεταβλητή έχει δύο δυνατότητες

η προσπάθειες και r επιτυχίες p η μεμονωμένη πιθανότητα για επιτυχία



$$P(r ; n, p) = \frac{n!}{r!(n-r)!} p^r (1-p)^{n-r}$$

Mean

$$\mu = \langle r \rangle = \sum r P(r)$$


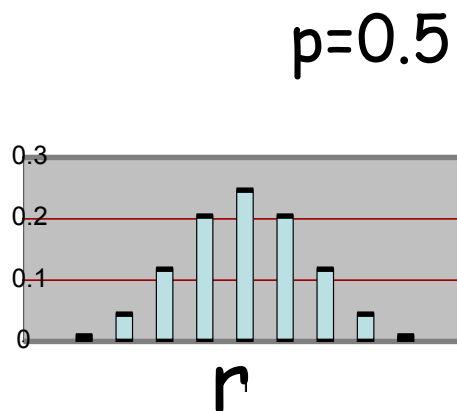

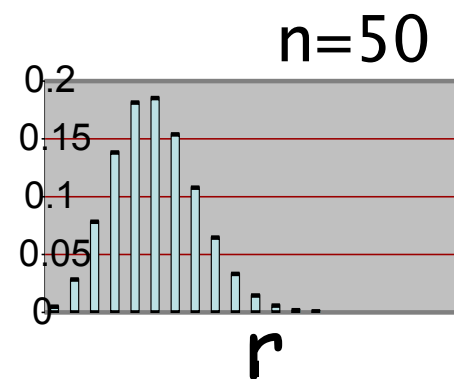


$$= np$$

Variance

$$V \equiv \sigma^2 = \langle (r - \mu)^2 \rangle = \langle r^2 \rangle - \langle r \rangle^2$$


$$= np(1-p)$$

Παραδείγματα διώνυμης κατανομής



Κατανομή Poisson

- Δίνει την πιθανότητα να συμβούν r γεγονότα όταν ο ρυθμός των γεγονότων κατά μέσον όρο είναι λ (είναι το όριο της διωνυμικής κατανομής όταν $n \rightarrow \infty$ $p \rightarrow 0$, $np = \lambda$)



$$P(r; \lambda) = e^{-\lambda} \frac{\lambda^r}{r!}$$


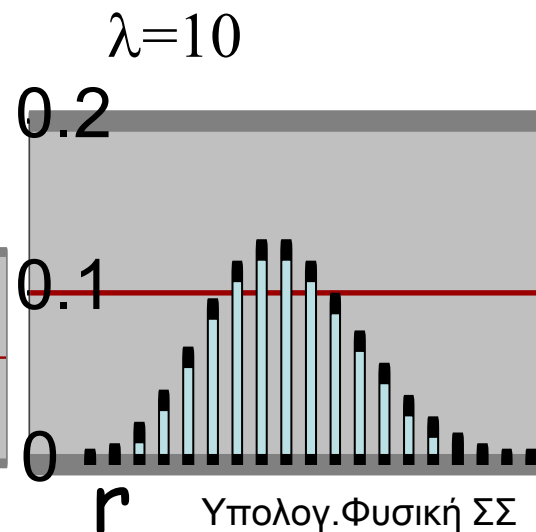




Mean

$$\begin{aligned} \mu &= \langle r \rangle = \sum r P(r) \\ &= \lambda \end{aligned}$$

Variance

$$\begin{aligned} V \equiv \sigma^2 &= \langle (r - \mu)^2 \rangle = \langle r^2 \rangle - \langle r \rangle^2 \\ &= \lambda \end{aligned}$$

Παραδείγματα κατανομής Poisson


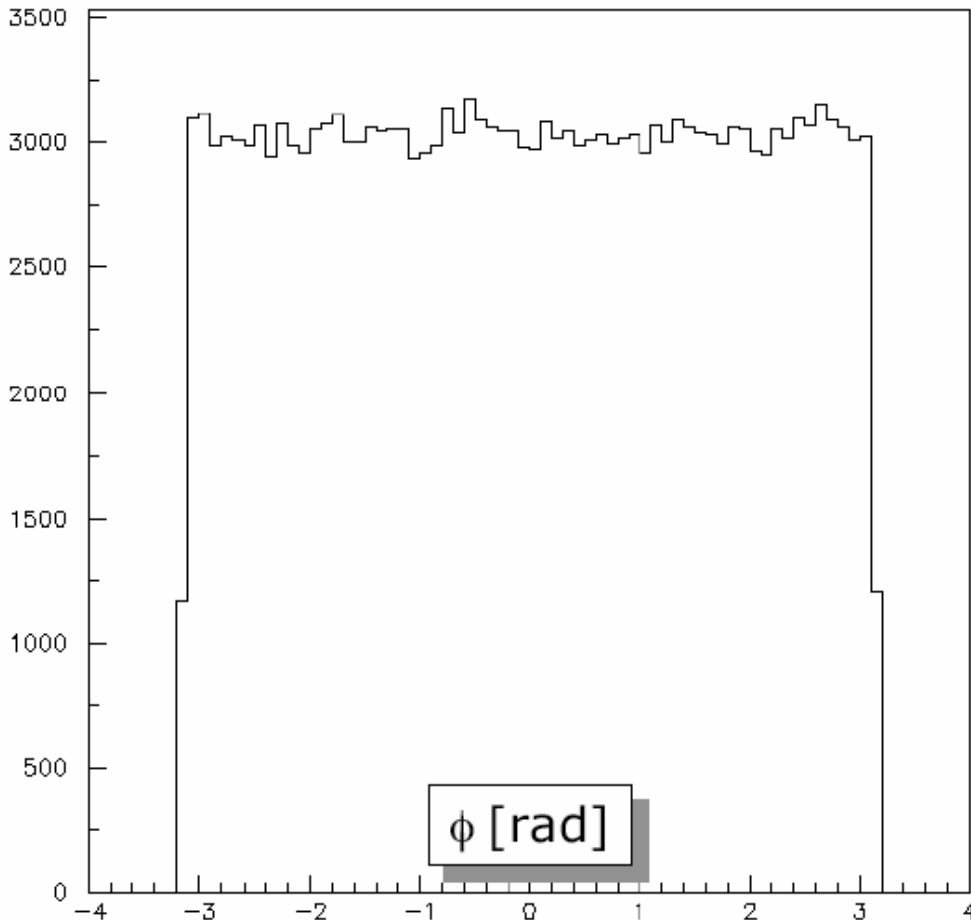


Κατανομές Poisson

- Το πλήθος των ραδιενεργών διασπάσεων σε ορισμένο χρόνο t , **μικρό** σε σχέση με τον χρόνο διάσπασης
- Το πλήθος συγκεκριμένου τύπου σωματιδίων σε σκέδαση σωματιδίου-σωματιδίου όταν ο **συνολικός αριθμός των γεγονότων είναι πολύ μεγάλος** και η συγκεκριμένη διαδικασία **σπάνια**
- Η πιθανότητα παρατήρησης n γεγονότων σε χρόνο t , όταν ο μέσος ρυθμός είναι μ : **$\lambda = \mu t$** . Η μέση τιμή **λ -αναμενόμενη τιμή-** και η διακύμανση : **variance** στην κατανομή Poisson είναι **ισες!**
- Απο δώ προκύπτει **ο τύπος : $n \pm \sqrt{n}$** που χρησιμοποιείται στα στατιστικά σφάλματα όταν μετρούμε σε συγκεκριμένο χρονικό διάστημα

Ομοιόμορφες Κατανομές (Uniform Distributions)

- Η πιθανότητα είναι σταθερή σε ένα διάστημα : πχ η κατανομή των μιονίων κατα την αζιμουθιακή γωνία ϕ στη σκέδαση : $ee \rightarrow \mu\mu$



$$f(x; \alpha, \beta) = \begin{cases} \frac{1}{\beta - \alpha} & \alpha \leq x \leq \beta \\ 0 & \text{otherwise} \end{cases}$$

E : αναμενόμενη τιμή

$$E[x] = \frac{1}{2}(\alpha + \beta)$$

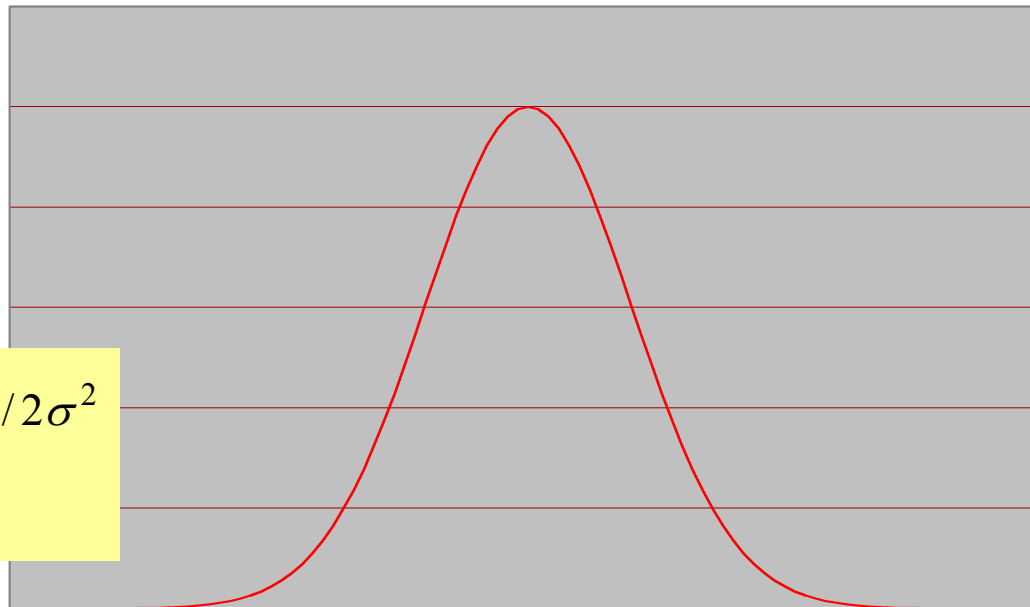
V : variance

$$V[x] = \frac{1}{12}(\beta - \alpha)^2$$

Κατανομή Gauss ή Normal

Πυκνότητα πιθανότητας

$$P(x; \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$



Mean







$$\begin{aligned} \mu &= \langle x \rangle = \int x P(x) dx \\ &= \mu \end{aligned}$$

Variance

$$\begin{aligned} V \equiv \sigma^2 &= \langle (x - \mu)^2 \rangle = \langle x^2 \rangle - \langle x \rangle^2 \\ &= \sigma^2 \end{aligned}$$

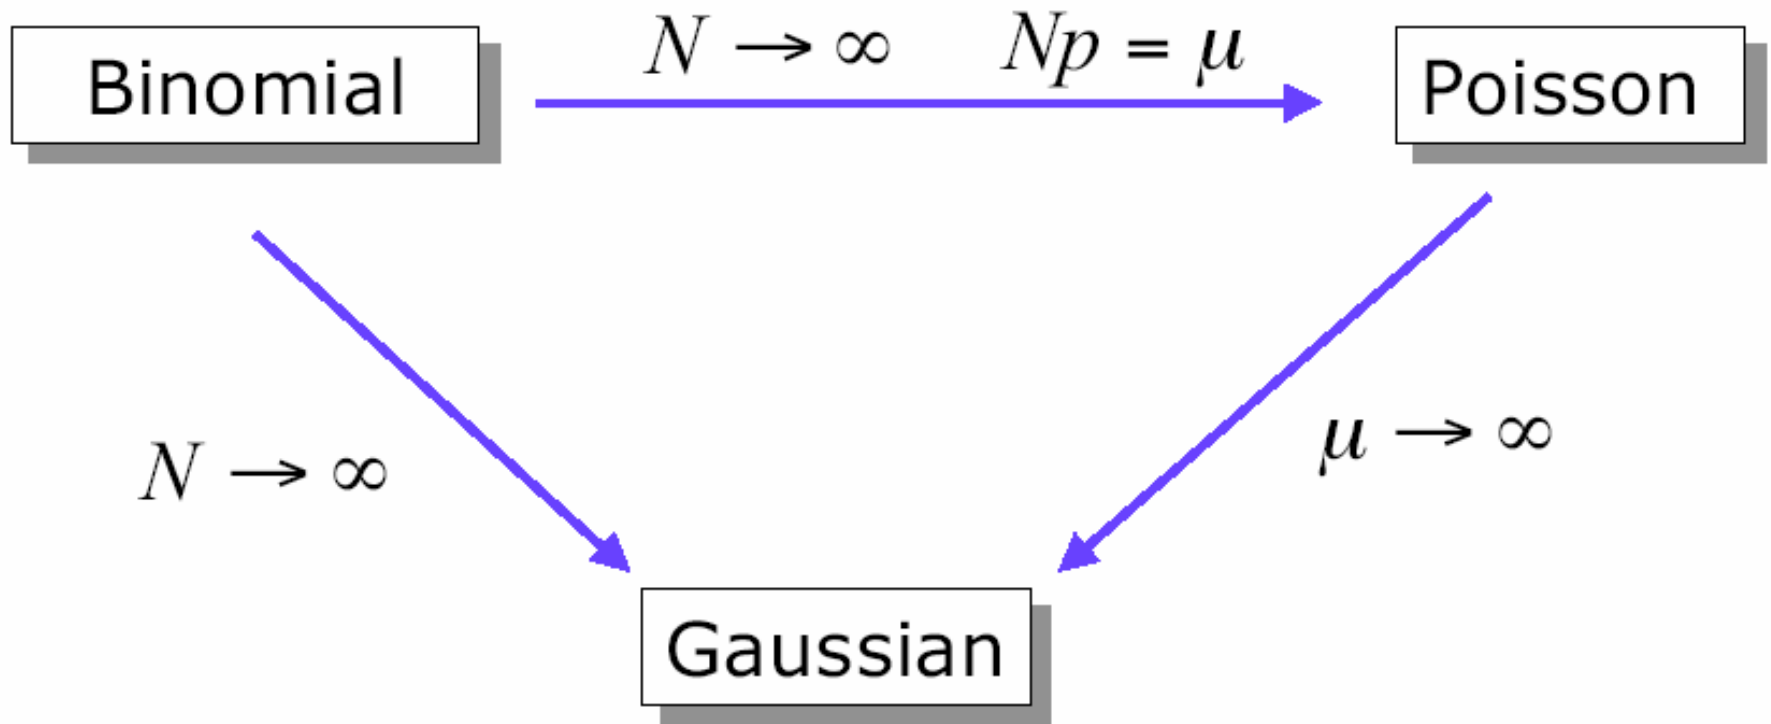
Central Limit Theorem (CLT)

- Το άθροισμα y , n τυχαίων, ανεξάρτητων αριθμών x_i είναι gaussian ($n \rightarrow \infty$) όποια κι αν είναι η κατανομή των x_i
- Convolute uniform distribution με τον εαυτό της



Σχέσεις μεταξύ κατανομών

Διωνυμη : N =το πλήθος των δοκιμών, p =η πιθανότητα επιτυχίας σε κάθε δοκιμή



Τύποι κατανομών Gauss

Μια μόνο κατανομή υπάρχει!

68.27% within 1σ

95.45% within 2σ

99.73% within 3σ


Normalisation
(if
required)

90% within 1.645σ

95% within 1.960σ

99% within 2.576σ


99.9% within 3.290σ



Κατανομή Chi-Squared (χ^2)

$$Z = \chi^2 = \sum_{i=1}^n \left(\frac{x_i - \mu_i}{\sigma_i} \right)^2$$

x_i : ανεξαρτητες μεταβλητές
με κατανομή Gauss



$$f(z; n) = \frac{1}{2^{n/2} \Gamma(n/2)} z^{n/2-1} e^{-z/2} ; n = 1, 2, \dots$$

$$E[z] = n$$

$$V[z] = 2n$$

Το πλήθος των βαθμών ελευθερίας

$$\Gamma(x) = e^{-Cx} \frac{1}{x} \prod_{n=1}^{+\infty} \frac{e^{x/n}}{1 + x/n}$$

$$C = \lim_{n \rightarrow \infty} \left(1 + \frac{1}{2} + \frac{1}{3} + \dots + \frac{1}{n} - \ln(n) \right)$$

Υπολογιστική Φυσική Στοιχειωδών Σωματιδίων



4ο Εξάμηνο 2005-2006

Ιστογράμματα
(Histograms)

Διδάσκοντες : Χαρά Πετρίδου
Δήμος Σαμψωνίδης

Ιστογράμματα

- Συνήθως οι μεταβλητές που χρησιμοποιούμε είναι διακριτές μεταβλητές x_1, x_2, \dots, x_n που προέρχονται από πειραματικές μετρήσεις
- Παράδειγμα: κατανομή **πολικής γωνίας θ**



Σύγκριση των δεδομένων
με ομαλή κατανομή


Ιστογράμματα

- Entries, normalization,...

- Bin width(s) (στο παράδειγμα ισαπέχουσες bins)

- Πλήθος των bins

- Περιοχή (Range)



Process group: alephz h1cc h1nc l3higgs189

Histogram definition:


Title: polar angle Number of Bins: 10

Lower edge: 0 Upper edge: 1

Ιστογράμματα


- Εάν N (*entries*) μεγάλος αριθμός το ιστόγραμμα αντιπροσωπεύει κατανομή πιθανότητας (*pdf*)
- Ενδιαφέρει το πλήθος των γεγονότων σε κάθε *bin* και το σφάλμα
- Η κανονικοποίηση του ιστογράμματος
- Η μέση τιμή του ιστογράμματος

Σφάλματα στο Ιστόγραμμα




Σφάλματα στο Ιστόγραμμα

- Προσθέτουμε **error bars** στο ιστόγραμμα



Σφάλματα στο Ιστόγραμμα

- Προσοχή! Περίπτωση μικρού πλήθους γεγονότων

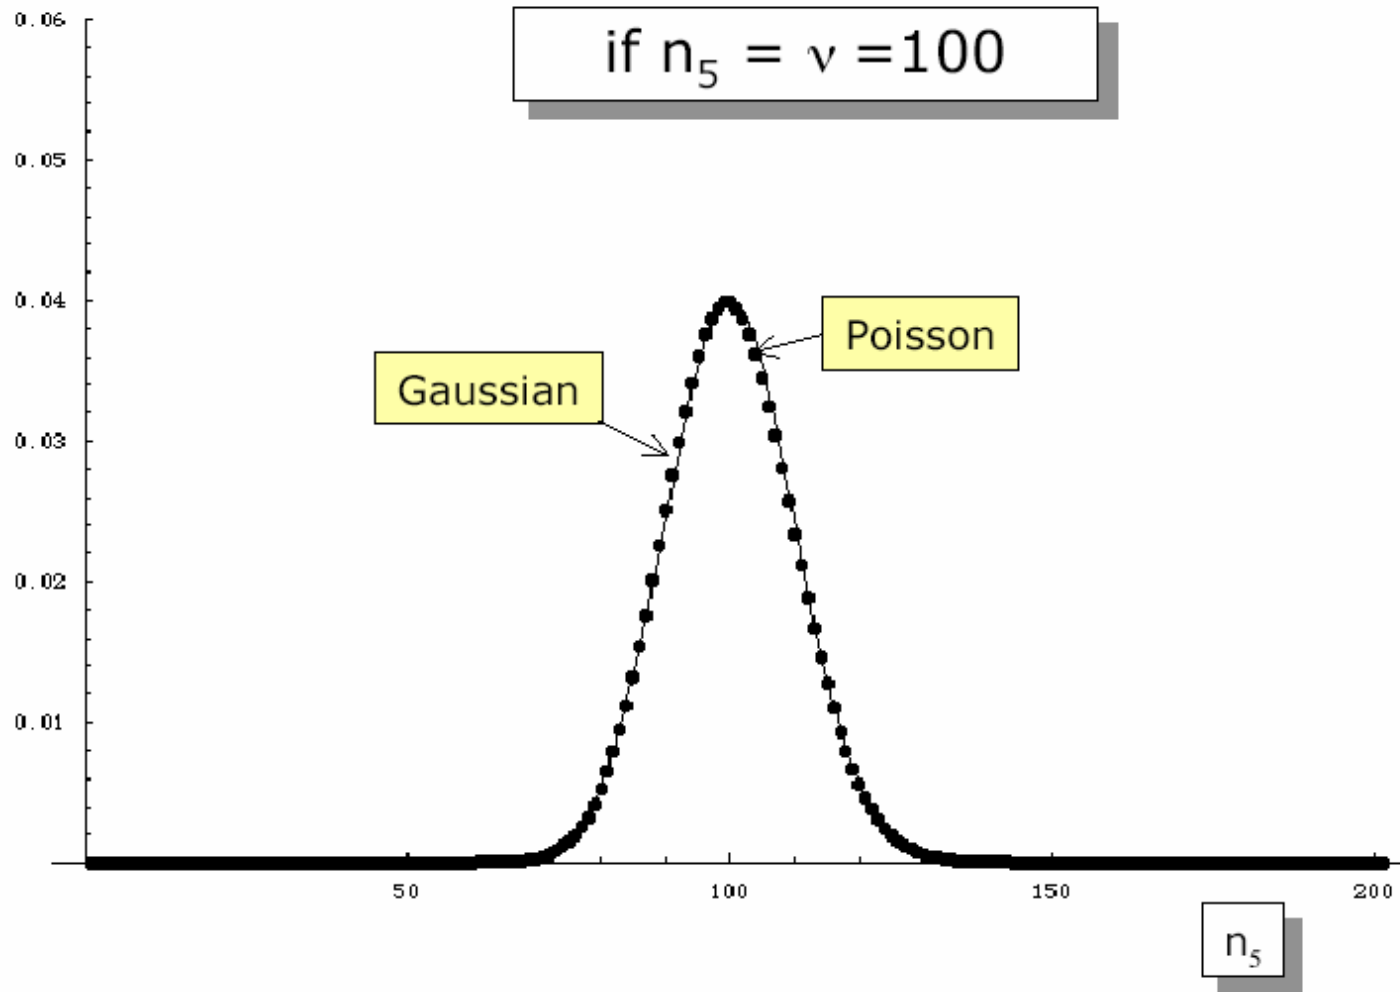


$\cos\theta$


Prob(to see 0) \ll 0 for Gaussian

Prob(to see 0) $=$ 0 for Poisson !!

Poisson vs Gaussian



Σφάλματα στο Ιστόγραμμα



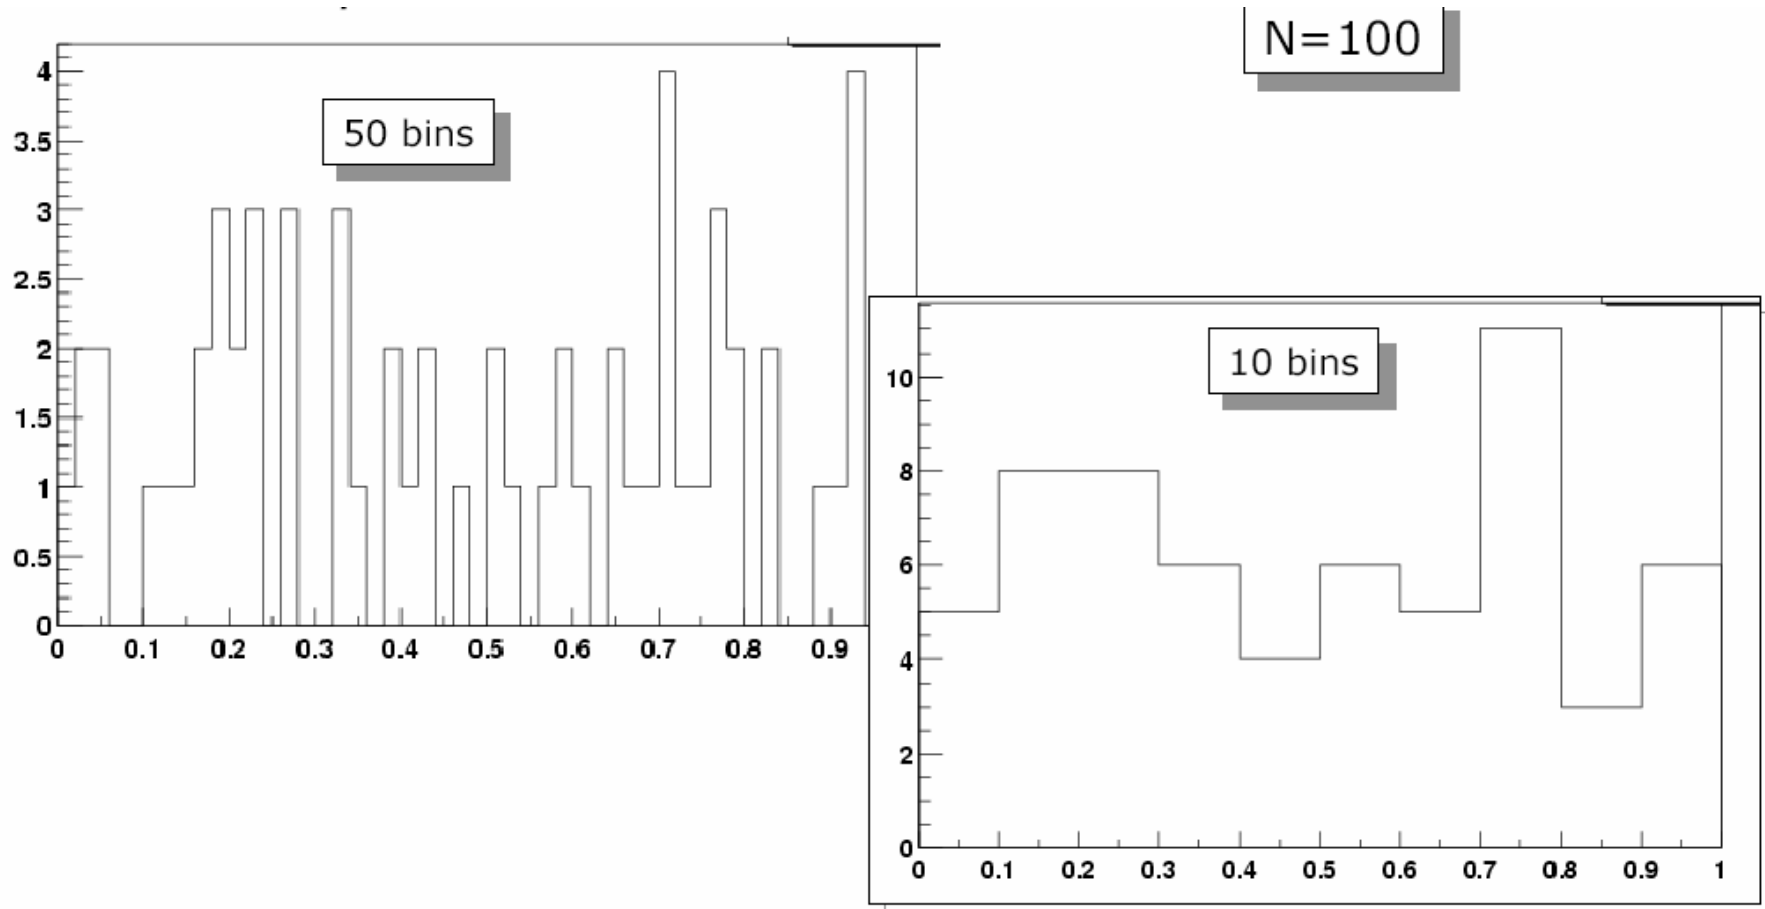
Ιστογράμματα

Τι θα πρέπει να προσέχουμε?

- Το μέγεθος του bin (**bin size**)
- Γεγονότα εκτός των ορίων του ιστογράμματος (**underflows, overflows**)
- Κατανομές με γρήγορες μεταβολές (**steeply falling/fast varying functions**)

Επιλογή του bin width

- Επιλέγουμε την υποδιαίρεση της κλίμακας (bin width) έτσι ώστε το πλήθος των γεγονότων ανά υποδιαίρεση να είναι 'λογικό'




Επιλογή του bin width

- Ο αριθμός των γεγονότων που μετατοπίζονται εντός και εκτός της υποδιαίρεσης πρέπει να είναι παρόμοιος (**bin migration**-σταθερότητα και καθαρότητα του δείγματος)
- Το bin width πρέπει να ταιριάζει με την πειραματική διακριτική ικανότητα στην συγκεκριμένη μεταβλητή (**experimental resolution**)
- Να υπάρχει αρκετή στατιστική για κάθε υποδιαίρεση (**bin statistics**)

Επιλογή του bin width

- Σημαντικό για συναρτήσεις με απότομη κλίση
- Παράδειγμα: η κατανομή της ορμής του σωματιδίου-συντονισμού ρ





logarithmic scale!

Επιλογή της κλίμακας (Histogram range)

- Κακή επιλογή κλίμακας μπορεί να οδηγήσει σε παραπλανητικά συμπεράσματα
- =>Πρέπει να ελέγχουμε να μην υπάρχουν **overflows** και **underflows**
- Η κλίμακα είναι σημαντική και στην περίπτωση κανονικοποίησης





Σύγκριση ιστογράμματος με ομαλή συνάρτηση

- Προσοχή στις συναρτήσεις με απότομες ή γρήγορες μεταβολές



Συσχετίσεις-Συμμεταβολή (correlations-covariance)

- Ιστογράμματα 2-διαστάσεων (**scatterplots**)
- =>Χρήσιμο εργαλείο για να μελετήσουμε συσχετισμούς δύο μεταβλητών (**correlations**)



Ιδιότητες-Συσχετισμοί (correlations)


- Για συναρτήσεις με διάφορες μεταβλητές μπορεί να υπάρχουν συσχετίσεις μεταξύ των μεταβλητών
- Παράδειγμα : για συναρτήσεις δύο τυχαίων μεταβλητών x, y η συμμεταβολή (covariance) $V(x,y)$ (ή $\text{cov}(x,y)$) -error matrix- ορίζεται ως:

$$V[xy] = E((x - \mu_x)(y - \mu_y)) \equiv E[xy] - \mu_x \mu_y$$

$$E[xy] = \int_{y \min}^{y \max} \int_{x \min}^{x \max} x \cdot y \cdot f(x,y) \cdot dx \cdot dy$$

$$V(x,y) = \begin{pmatrix} \sigma_x^2 & V[xy] \\ V[yx] & \sigma_y^2 \end{pmatrix}$$

$$28/3/2005 \quad \rho_{xy} = \frac{V[xy]}{\sigma_x \sigma_y} \quad -1 \leq \rho_{xy} \leq +1 \quad \rho=1 \text{ για } y=ax+b$$



Ιδιότητες-Συσχετισμοί (correlations)

- Υπολογισμός του σφάλματος για συναρτήσεις με συσχετιζόμενες μεταβλητές: **παίρνουμε υπόψη την συσχέτιση**

$$\sigma_f^2 = \sum_{i=1}^n \left(\frac{\partial f}{\partial x_i} \right)^2 \cdot \sigma_{x_i}^2 + \sum_{i=1}^n \sum_{j \neq i}^n \left(\frac{\partial f}{\partial x_i} \frac{\partial f}{\partial x_j} \right) \cdot \text{cov}(x_i, x_j)$$