

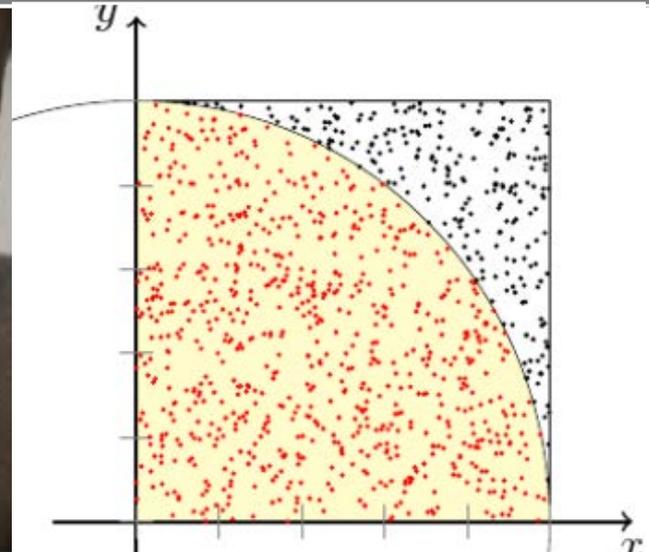
Moderne Methoden der Datenanalyse

Zufallszahlen und Monte Carlo Methoden

Andreas B.Meyer  

9. Mai 2017

Fakultät für Physik
Institut für Experimentelle Kernphysik - IEKP



Vorlesungsprogramm

- Einführung: Überblick und grundlegende Konzepte (1)
- Einführung: Überblick und grundlegende Konzepte (2)
- Zufallszahlen und Monte-Carlo Methoden

A.MEYER

- Hypothesentests (1)
- Parameterschätzung
- Parameterschätzung (Goodness-of-fit)
- Optimierungs- und Parametrisierungsmethoden

R.ULRICH

- Konfidenzintervalle
- Hypothesentests (2)
- Klassifikation
- Klassifikation
- Klassifikation
- Messen und Entfalten
- Systematische Unsicherheiten

A.MEYER



2.

ZUFALLSZAHLEN UND MONTE-CARLO METHODEN

2. Zufallszahlen und Monte Carlo Methoden

- Grundsätzliches 2.1
- Beispiele und Anwendungen 2.1
DIE MC METHODE

- Gleichverteilte (Pseudo-)Zufallszahlen 2.2
- Tests und Eigenschaften 2.2
ZUFALLSZAHLEN

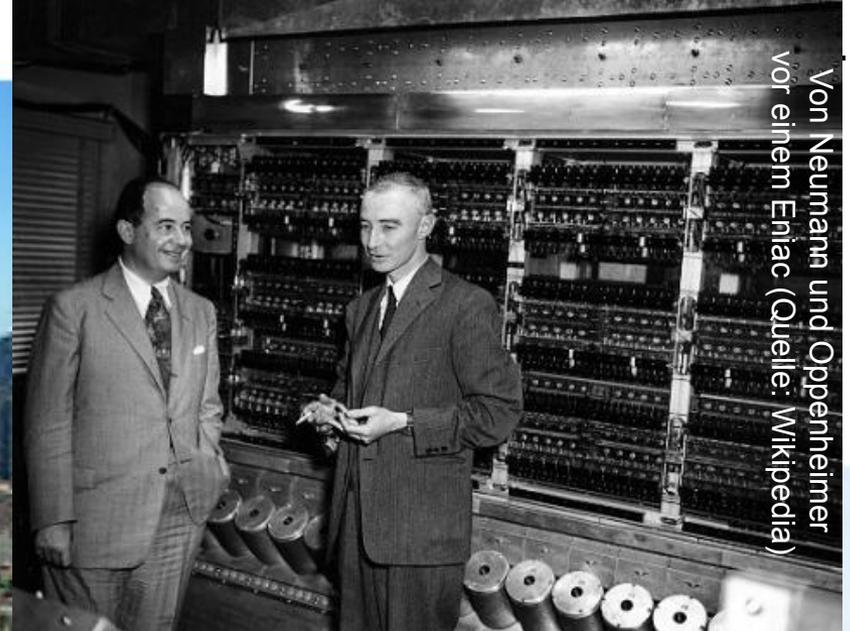
- Verfahren zur Erzeugung von Verteilungen 2.3
- Korrelierte Zufallszahlen 2.3
ERZEUGUNG VON
VERTEILUNGEN

- Literatur:
 - Globel/Lohrmann: *Statistische und numerische Methoden der Datenanalyse (Kap. 5)*
 - Bohm/Zech: *Einführung in die Statistik und Messwertanalyse (Kap. 4)*
 - Brandt: *Datenanalyse (Kap. 4)*
 - Cowan: *Statistical Data Analysis (Kap. 3)*

2.1

DIE MONTE-CARLO METHODE

Monaco



Von Neumann und Oppenheimer
vor einem Eniac (Quelle: Wikipedia)



Fermi, Ulam, van Neumann, Metropolis, ...

Ursprung in den 1940er Jahren: siehe z.B. <http://lib-www.lanl.gov/la-pubs/00326866.pdf>

Die Monte Carlo Methode

- Auf (Pseudo-)Zufallszahlen basierende numerische Methode
 - Bestimmung der Eigenschaften von Verteilungen von Zufallszahlen (PDF), z.B. für Messgrößen in Experimenten
 - Lösung viel-dimensionaler Integrale (Transport-, Differential und Integral-Gleichungen)
 - Beispiele bisher: Würfel, Fehlerfortpflanzung, Wettervorhersage, Ziegenproblem

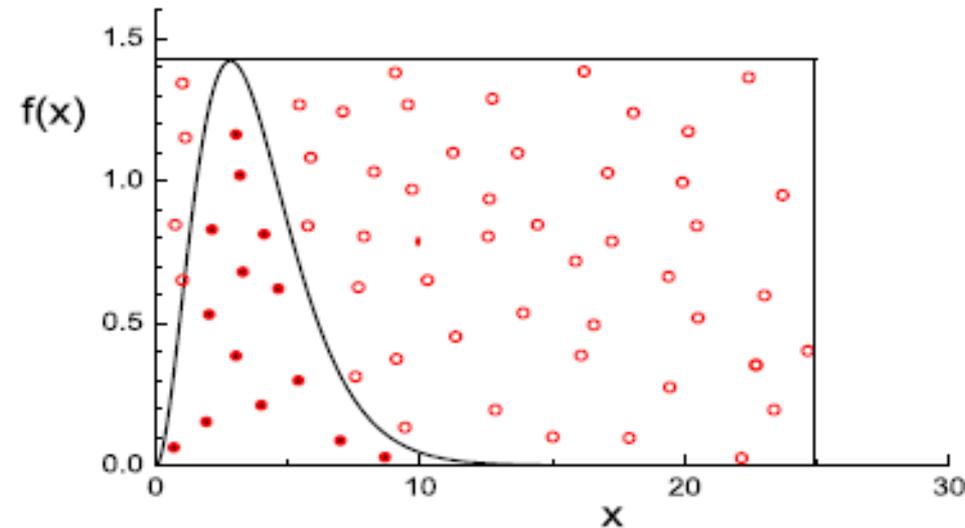
- Vorteile der Methode:
 - Einfache Formulierung der Problemstellungen
 - Unabhängige Kontrolle analytischer Lösungen
 - Kontinuierliche Verbesserung der Genauigkeit (mit mehr CPU)

- Aus der Teilchenphysik ist MC nicht wegzudenken:
 - Simulation von Physik-Ereignissen und Detektoreigenschaften
 - Entwerfen und Planen von Experimenten
 - Test von Analyse-Methoden (statistische Tests / “Pseudo-Experimente”)
 - Matrix-Elemente und Phasenraum-Integrale

■ Erzeuge Folge von Zufallszahlen r_1, r_2, \dots, r_m gleichverteilt in $]0,1]$

■ Transformiere r_i in $x_i = x_1, \dots, x_m$, so dass x_i der gewünschten Verteilungsdichte $f(x)$ folgen.

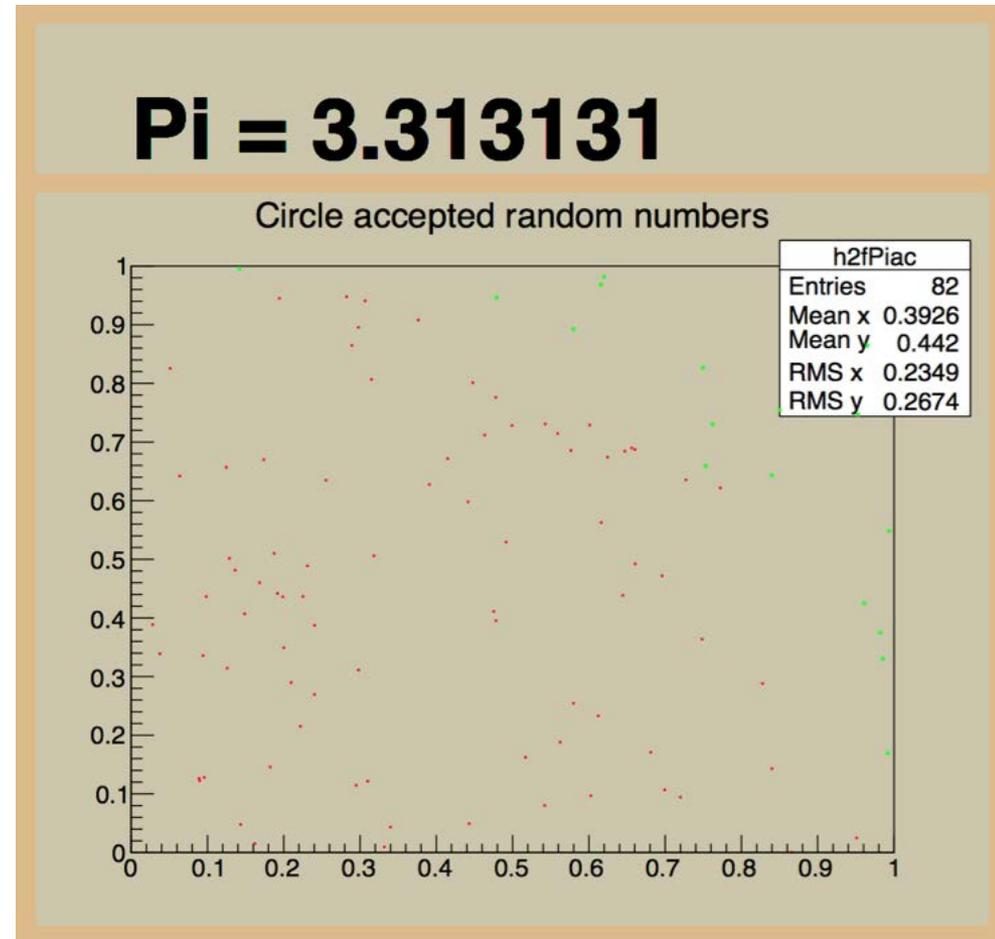
■ Aus den x_i werden dann Eigenschaften von $f(x)$ bestimmt, z.B. das Integral $\int_a^b f(x)dx = \text{Anteil der } x_i \text{ mit } a < x_i < b$



Beispiel: Bestimmung der Fläche eines Kreises

- Rot: Punkte, für die $x^2+y^2 < 1$
- Ersetzt Quadratur des Kreises:
Verhältnis der roten Punkte zur
Gesamtzahl aller Punkte
entspricht Verhältnis der
Flächen von Viertelkreis und
Quadrat

$$N = 10^2: 3.313131$$



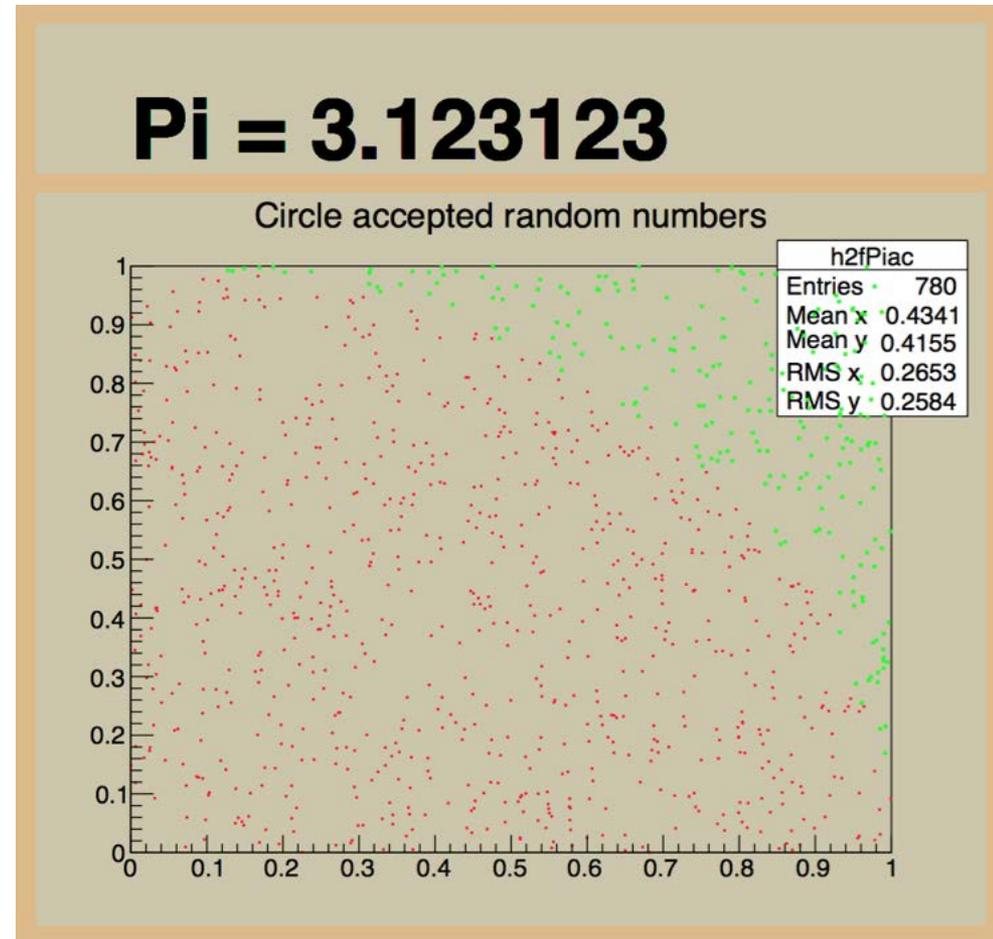
Beispiele: [calc_pi.C](#) [animate_pi.py](#)

Beispiel: Bestimmung der Fläche eines Kreises

- Rot: Punkte, für die $x^2+y^2 < 1$
- Ersetzt Quadratur des Kreises: Verhältnis der roten Punkte zur Gesamtzahl aller Punkte entspricht Verhältnis der Flächen von Viertelkreis und Quadrat

$$N = 10^2: 3.313131$$

$$N = 10^3: 3.123123$$



Beispiele: [calc_pi.C](#) [animate_pi.py](#)

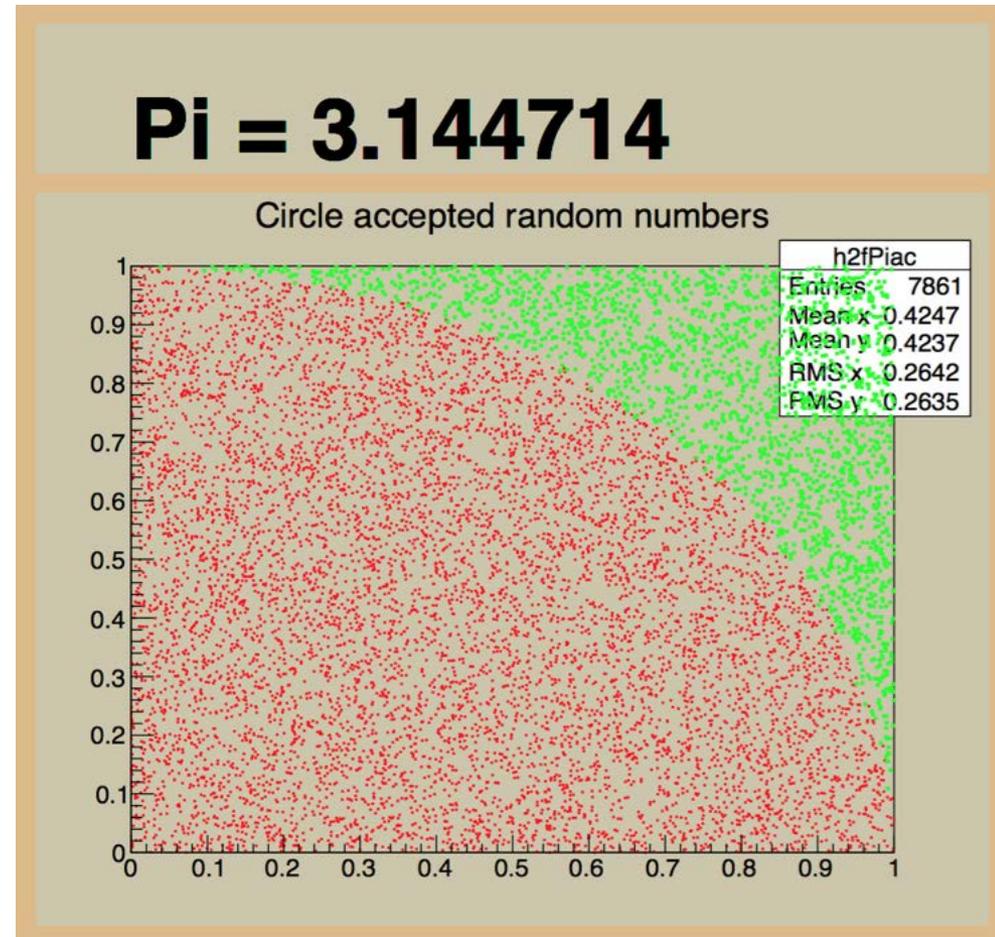
Beispiel: Bestimmung der Fläche eines Kreises

- Rot: Punkte, für die $x^2+y^2 < 1$
- Ersetzt Quadratur des Kreises: Verhältnis der roten Punkte zur Gesamtzahl aller Punkte entspricht Verhältnis der Flächen von Viertelkreis und Quadrat

$$N = 10^2: 3.313131$$

$$N = 10^3: 3.123123$$

$$N = 10^4: 3.144714$$



Beispiele: [calc_pi.C](#) [animate_pi.py](#)

Beispiel: Bestimmung der Fläche eines Kreises

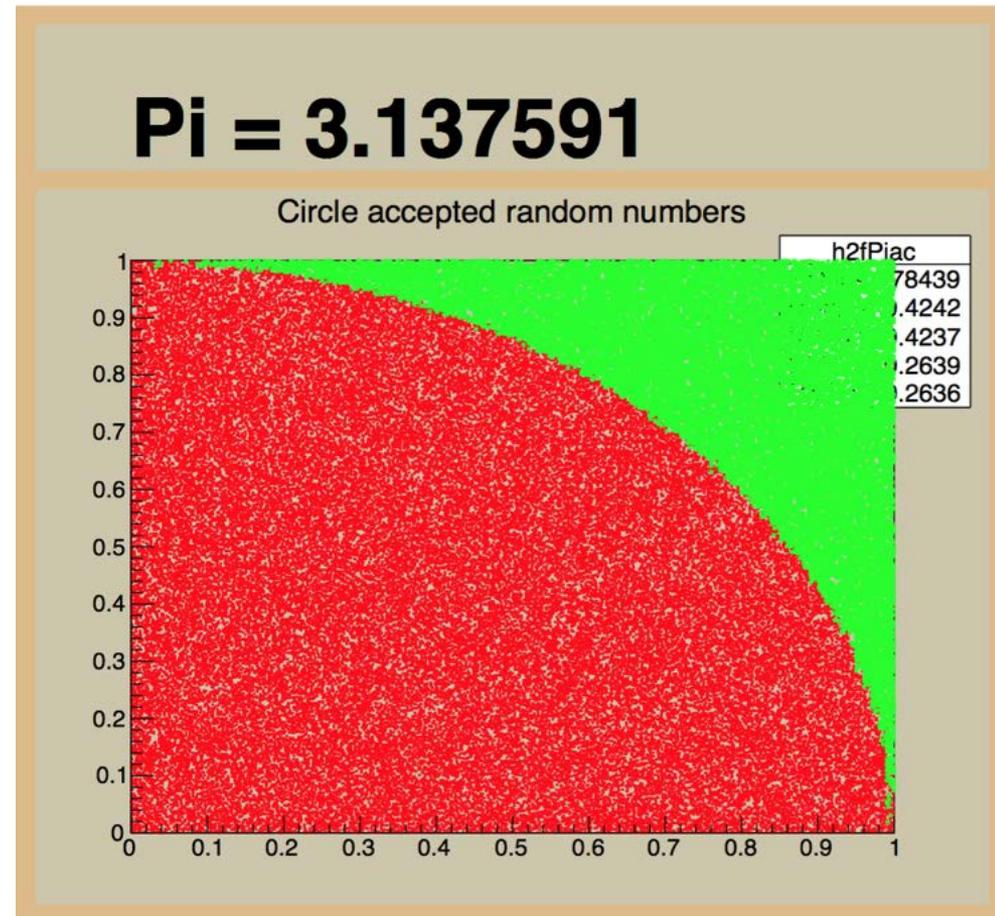
- Rot: Punkte, für die $x^2+y^2 < 1$
- Ersetzt Quadratur des Kreises: Verhältnis der roten Punkte zur Gesamtzahl aller Punkte entspricht Verhältnis der Flächen von Viertelkreis und Quadrat

$$N = 10^2: 3.313131$$

$$N = 10^3: 3.123123$$

$$N = 10^4: 3.144714$$

$$N = 10^5: 3.137591$$



Beispiele: [calc_pi.C](#) [animate_pi.py](#)

Beispiel: Bestimmung der Fläche eines Kreises

- Rot: Punkte, für die $x^2+y^2 < 1$
- Ersetzt Quadratur des Kreises:
Verhältnis der roten Punkte zur
Gesamtzahl aller Punkte
entspricht Verhältnis der
Flächen von Viertelkreis und
Quadrat

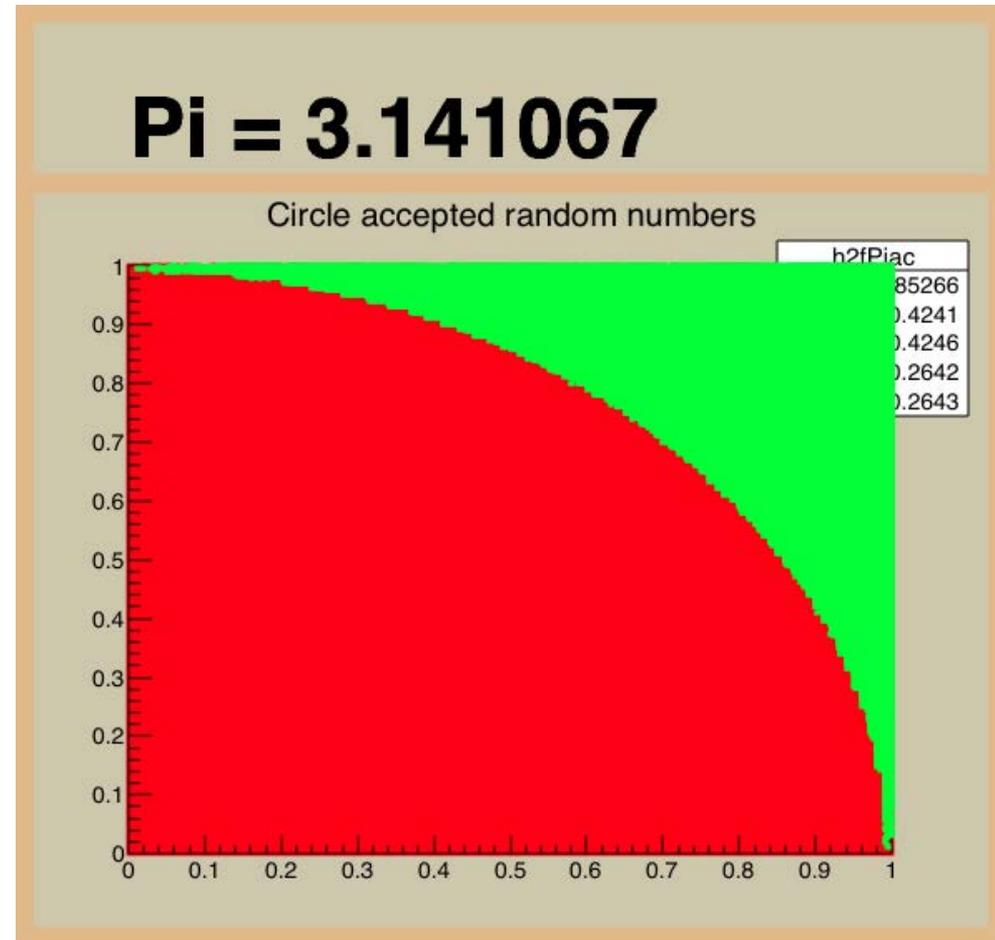
$$N = 10^2: 3.313131$$

$$N = 10^3: 3.123123$$

$$N = 10^4: 3.144714$$

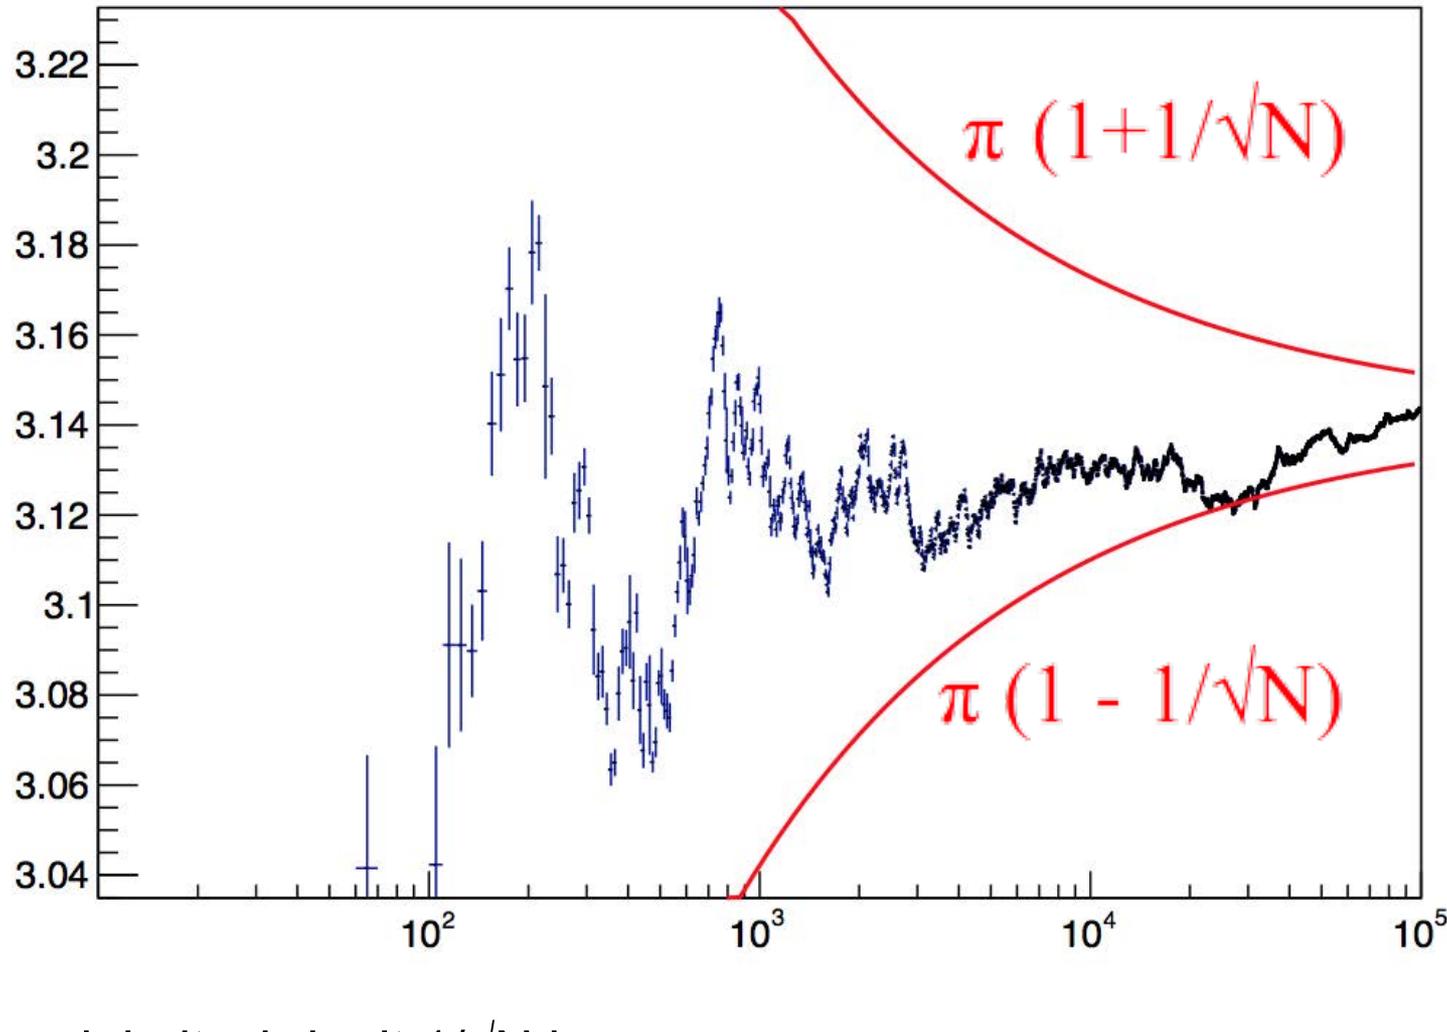
$$N = 10^5: 3.137591$$

$$N = 10^6: 3.141067$$



Beispiele: [calc_pi.C](#) [animate_pi.py](#)

Beispiel: Bestimmung der Fläche eines Kreises

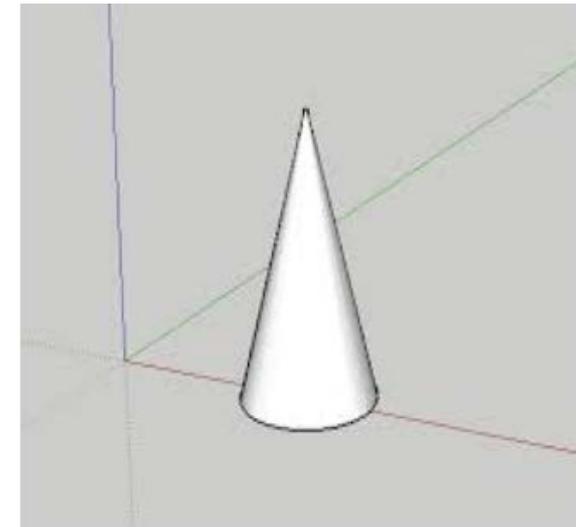


■ Genauigkeit wird mit $1/\sqrt{N}$ besser

Beispiel: `calc_pi.C`

Beispiel: Schnittvolumen eines Kegels mit einem Torus

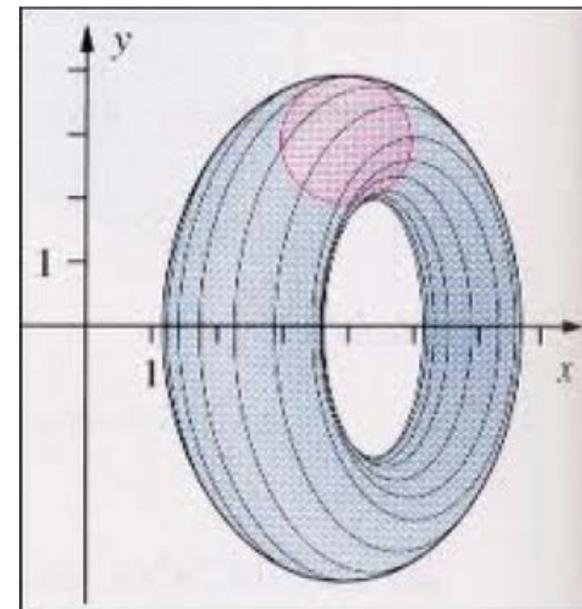
- Definiere Quader, der Schnittvolumen einschließt
- Erzeuge zufällig gleichverteilte Punkte im Quadervolumen
- Teste, ob Punkt im Schnittvolumen liegt, also im Torus und im Kegel.
- Zähle Zahl der Punkte im Schnittvolumen.



Verhältnis der Punkte zur Gesamtzahl der Versuche entspricht dem Verhältnis des Schnittvolumens zum Quadervolumen

- Extrem einfache Rechenvorschrift
- Funktioniert auch für viel-dimensionale Probleme

Statistischer Fehler (Binomialverteilung).
Genauigkeit steigt mit \sqrt{N}



$$I = \int_a^b \phi(x) dx$$

- Erwartungswert von $\phi(x)$ für eine zwischen a und b gleichförmige PDF:

$$\int_a^b 1 \cdot \phi(x) dx = (b - a) \langle \phi \rangle$$

- Für N gleichverteilte Zufallszahlen $x_i \in [a, b]$ und N groß geht der Mittelwert gegen den Erwartungswert

$$\bar{\phi} = \frac{1}{N} \sum_{i=1}^N \phi(x_i) \rightarrow \langle \phi \rangle$$

- Also ist:

$$I = \int_a^b \phi(x) dx \simeq (b - a) \frac{1}{N} \sum_{i=1}^N \phi(x_i)$$

Blobel/Lohrmann Abschnitt 5.6

$$I = \int_a^b \phi(x) dx \simeq (b - a) \frac{1}{N} \sum_{i=1}^N \phi(x_i)$$

■ Varianz von I_{MC} :

$$V(I_{MC}) = \sigma_{I_{MC}}^2 = V \left[\frac{b-a}{N} \sum_{i=1}^N \phi(x_i) \right] = \left(\frac{b-a}{N} \right)^2 V \left[\sum_{i=1}^N \phi(x_i) \right]$$

(Zentraler Grenzwertsatz)

$$= \frac{(b-a)^2}{N} V[\phi(x_i)]$$

■ $V[I_{MC}]$ ist proportional zu $V[\phi]$ und $1/N$

■ D.h Genauigkeit σ verbessert sich mit $1/\sqrt{N}$

■ Gilt auch für mehrdimensionale Integrale

$$\sigma \propto 1/\sqrt{N}$$

Vergleich MC-Methode mit Trapezregel

- Trapezregel: Integration durch Summation über Funktionswerte f in n Intervallen der Länge $h=(b-a)/n$

$$I_T = h \left(\frac{1}{2} f_0 + f_1 + \dots + f_{n-1} + \frac{1}{2} f_n \right)$$

- Abschätzung des Fehlers ΔI_T (durch Taylor-Entwicklung von I und I_T):
→ In einer Dimension: n Intervalle pro Dimension

ΔI_T nimmt mit $1/n^2 = n^{-2}$ ab

→ In d Dimensionen: $n^{1/d} = \sqrt[d]{n}$ Intervalle pro Dimension

ΔI_T nimmt mit $1/n^{2/d} = n^{-2/d}$ ab.

- MC-Methode ist dann besser, wenn gilt: $-2/d < -1/2$, also für $d > 4$

In hochdimensionalen Räumen ist Monte Carlo Integration anderen Methoden überlegen

MC-Methode: Einige Beispiele und Anwendungen

- Matrix-Elemente und Phasenraum-Integrale
- Vollständige Simulation von Physik-Ereignissen und Detektor
- Test und Optimierung von Analyse-Methoden (verdeckte Analyse)
- Design von Experimenten
- Korrekturfaktoren, Untergrundabschätzungen
- Statistische Tests / Pseudo-Experimente

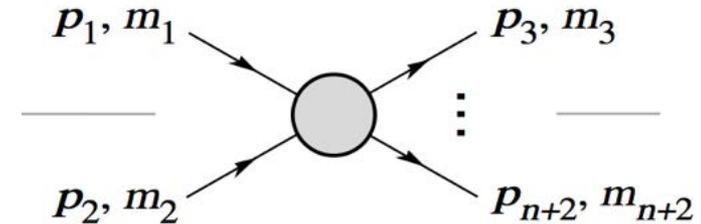
Beispiel: Berechnung eines Wirkungsquerschnitts

Matrixelement

$$d\hat{\sigma} = \frac{(2\pi)^4 |\mathcal{M}|^2}{4\sqrt{(p_1 p_2)^2 - m_1^2 m_2^2}} \text{ Flussfaktor}$$

$$\times d\Phi_n(p_1 + p_2; p_3 \dots p_{n+2})$$

Phasenraum

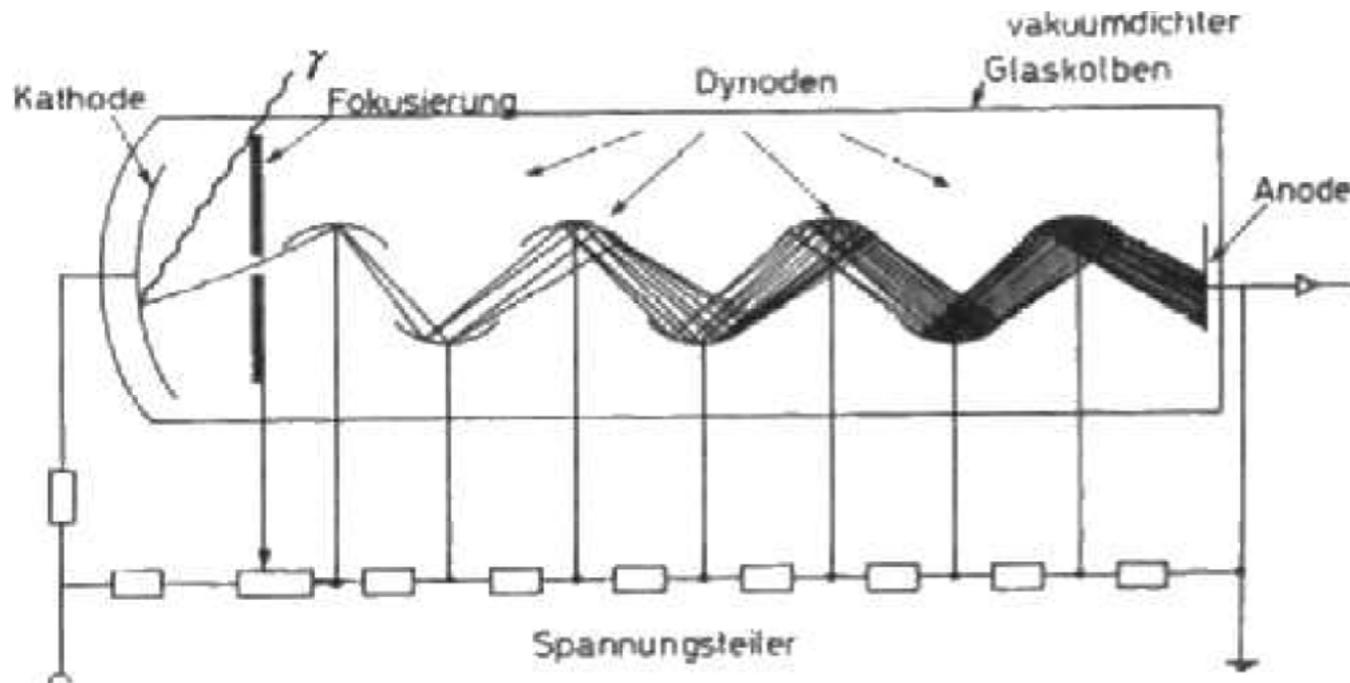


- Multidimensionales Integral, analytische Integration nur in einfachsten Fällen möglich.
- Hadron-Kollisionen (z.B. LHC): Zusätzlich Integration über Anfangszustände (Partonverteilungsfunktionen)

$$\sum_{ij} \int dx_1 dx_2 f_i(x_1, Q^2) f_j(x_2, Q^2) \hat{\sigma}(Q^2)$$

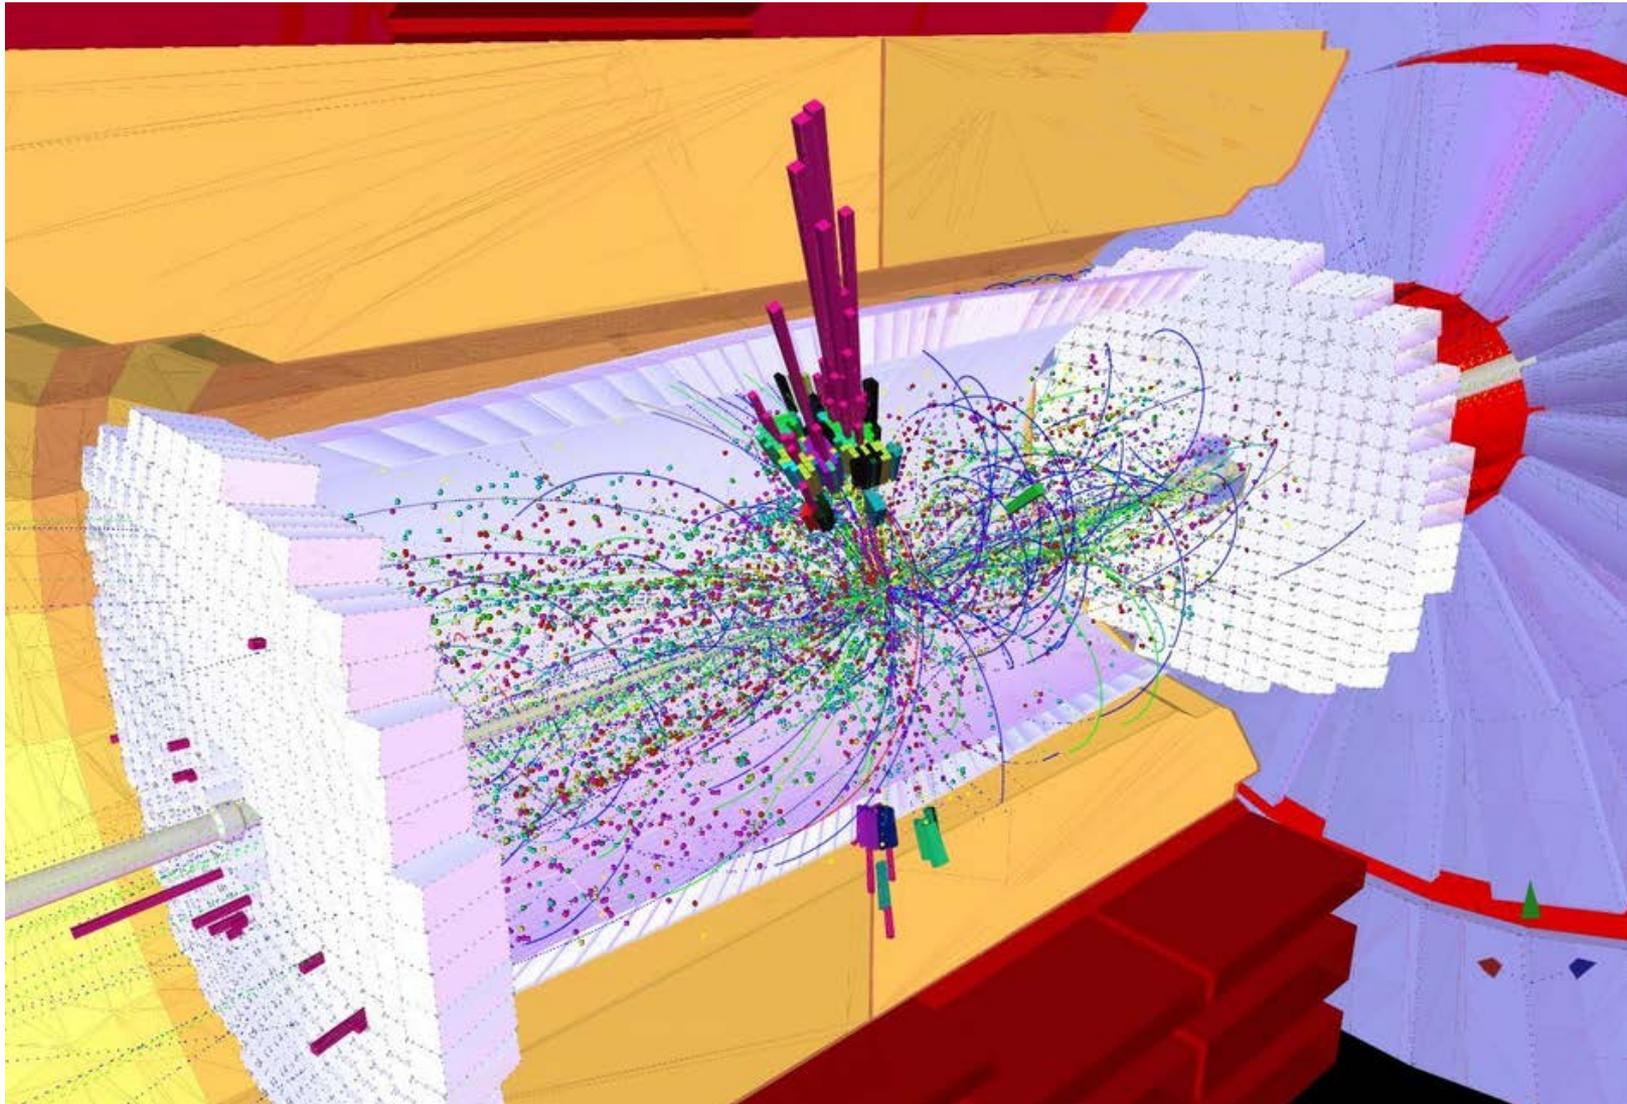
Beispiel: Detektorsimulation

- Simulation der Zahl der Elektronen in der letzten Stufe einer “Sekundärelektronenvervielfacher-Röhre” (Photomultiplier)



- Zahl der an einer Dynode ausgelösten Elektronen folgt einer Poisson-Verteilung
- Signal: Zahl der Elektronen an der Anode
- Hoher Rechenaufwand bei großer Anzahl von Teilchen → Parametrisierung

Beispiel: Teilchenphysikexperiment



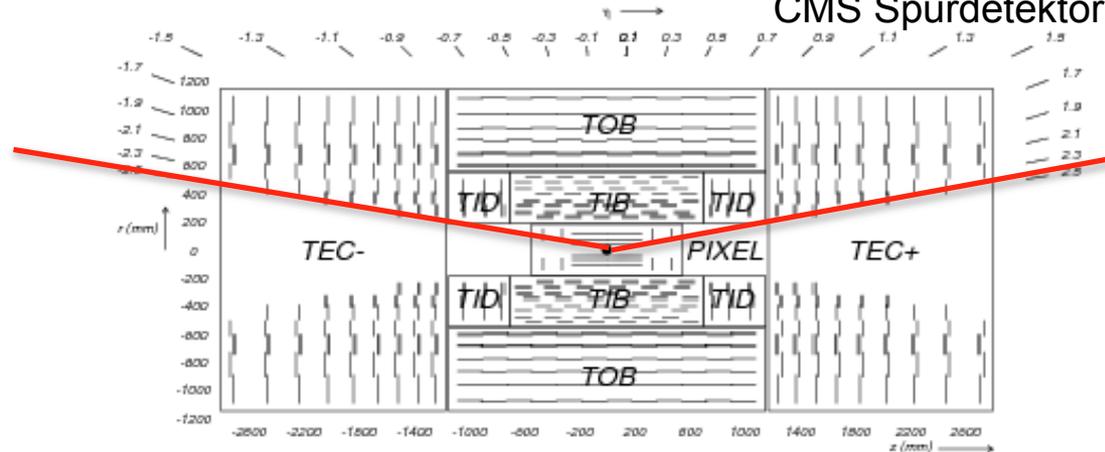
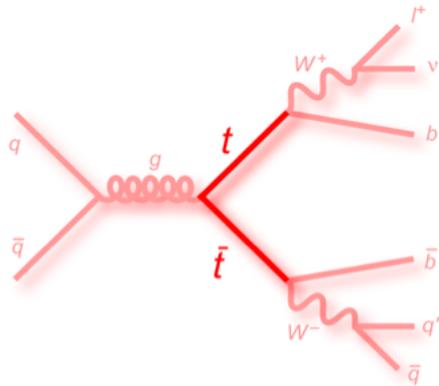
Beispiel: Faltungsintegral

- Detektorauflösung wird i.a. durch ein Faltungsintegral beschrieben: Statt des wahren Werts x wird ein durch Auflösungseffekte $t(x, x')$ verschmierter Wert x' gemessen.

$$f'(x') = \int_{-\infty}^{\infty} t(x, x') f(x) dx$$

- In der Praxis werden Messwerte durch eine große Zahl von Einzel-Effekten verfälscht (Auflösung, Rauschen, Digitalisierung, systematische Effekte usw.) d.h. die zu bestimmenden Faltungsintegrale sind hochdimensional.
- Bei der MC-Simulation werden die Effekte der Reihe nach aufaddiert. Serie von Faltungsintegralen wird zu einer Summe von Zufallsvariablen

Beispiel: Detektorakzeptanz

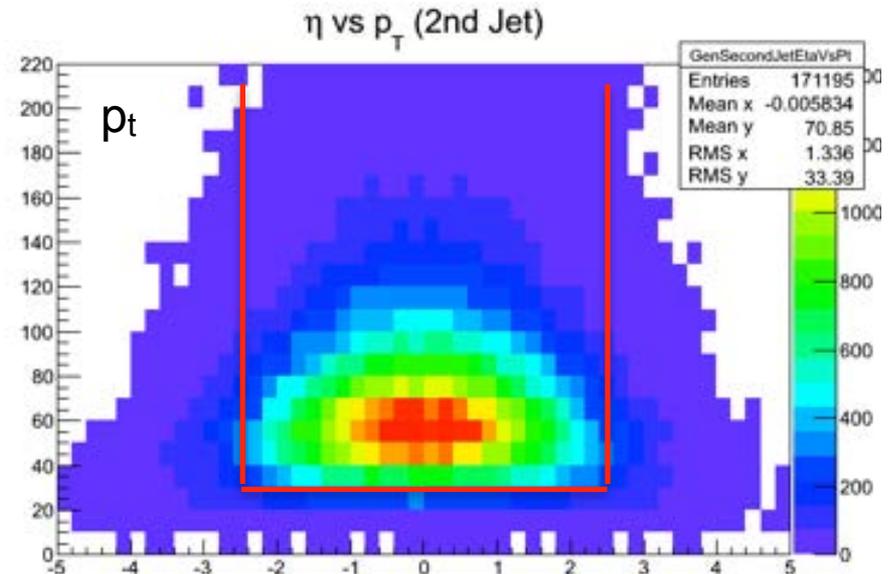


■ Vollständige Simulation von

■ Physik-Prozess

■ Detektorgeometrie,
Ansprechverhalten und
Auflösung

ermöglicht Messung, Korrektur
für Verluste und Abschätzung
der systematischen Fehler



$$\eta = -\ln \tan(\theta/2)$$

2.2 **ZUFALLSZAHLEN**

Erzeugung von Pseudo-Zufallszahlen

- Computer liefern deterministische Zahlenfolgen “Pseudo”-Zufallszahlen:
 - Möglichst gute Verteilung (unkorrelierte Folgen)
 - Lange Periode
 - Schnelle Erzeugung
 - Reproduzierbarkeit (für vorgegebenen Startwert)

- Einfachster Algorithmus:

$$x_n = (a x_{n-1}) \bmod 2^k \quad (\text{wählt die letzten } k \text{ bits aus, d.h. bit-weises UND mit } 2^k-1)$$

- Allgemeiner und besser: (“linear kongruenter Generator, LCG”)

$$x_n = (a x_{n-1} + c) \bmod m$$

Dann ist $u_n = x_n/m$ gleichverteilt im Intervall $[0,1[$

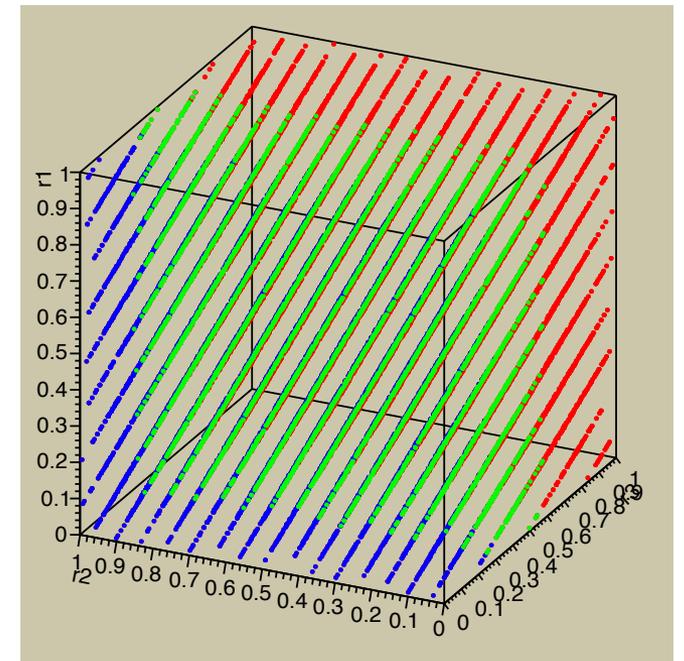
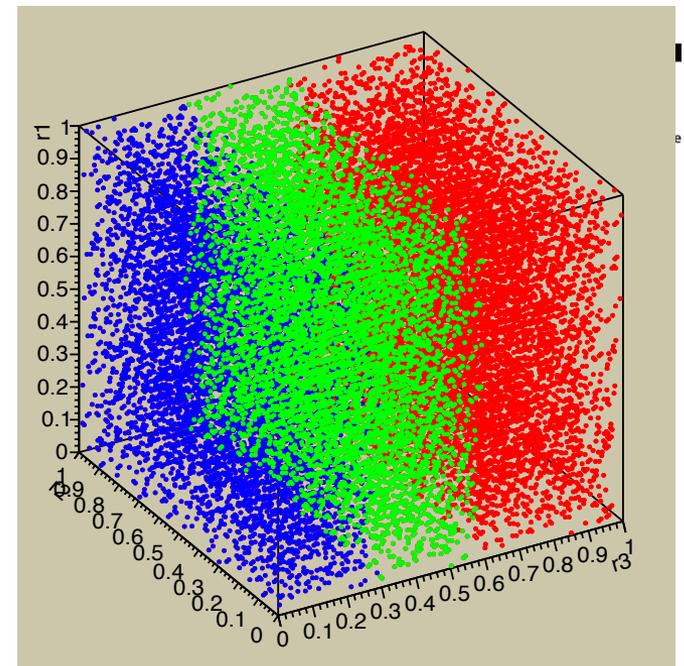
- Periode ist höchstens m . Die Parameter a und c müssen geeignet gewählt werden.

Zufallszahlen mit LCG

- Sind diese Zufallszahlen gut?
- Gibt es Korrelationen zwischen aufeinanderfolgenden Zahlen?
- Betrachte k -tuples (d.h. Paare, Triplets, ...) von n benachbarten Zahlen
- Allgemein gilt für LCG: k -Tupel aufeinander folgender Zahlen liegen auf $k-1$ dimensionalen Hyperebenen.
G.Marsaglia, PNAS 1968 61(1) 25-28
- Gute Wahl von a, c und m liefert gleichmäßige Verteilung der Ebenen

siehe z.B. Brandt, Datenanalyse

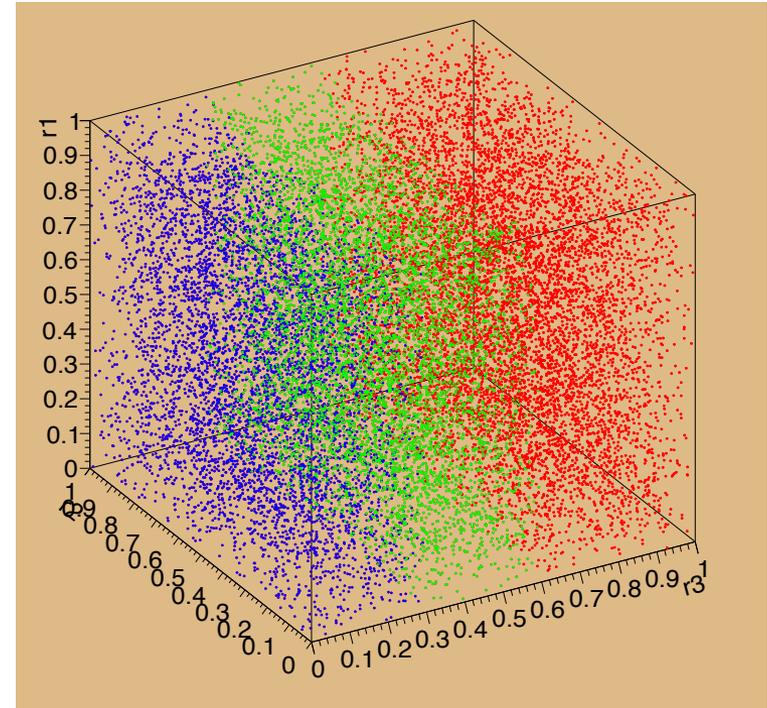
Beispiel: myrand.C



Mersenne-Twister Algorithmus

Matsumoto, Nishimura (1998)

- basiert auf Mersenne-Primzahlen (2^n-1)
- Zustand wird beschrieben durch 624 Integer Zahlen (32 bit), die als Startwerte mit einem einfachen Generator initialisiert werden können.
- Extrem lange Periode ($2^{19937}-1 \approx 10^{6000}$)
- Gute Gleichverteilung bis zu 623 Dimensionen (bewiesen)
- Hinreichend schnell



Root-Klasse TRandom3
Standard-Generator in Python

Beispiel: [mertwist.C](#)

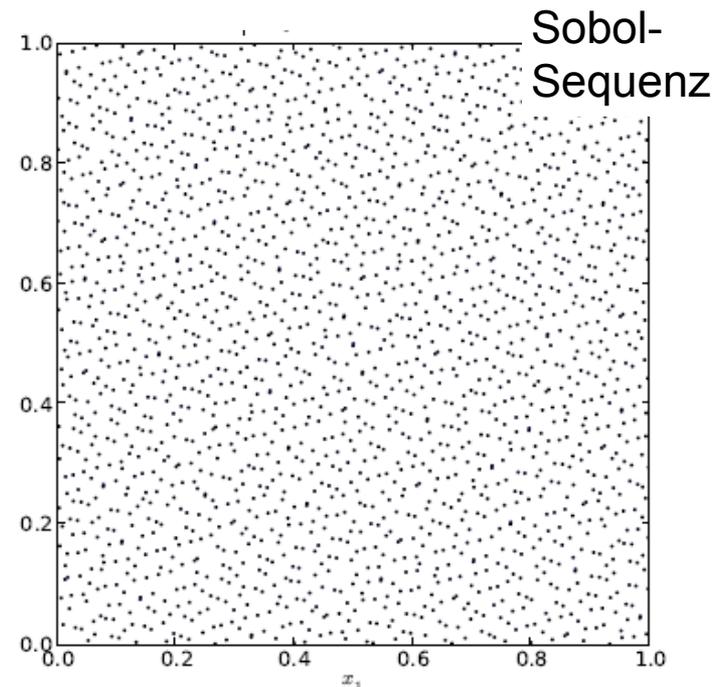
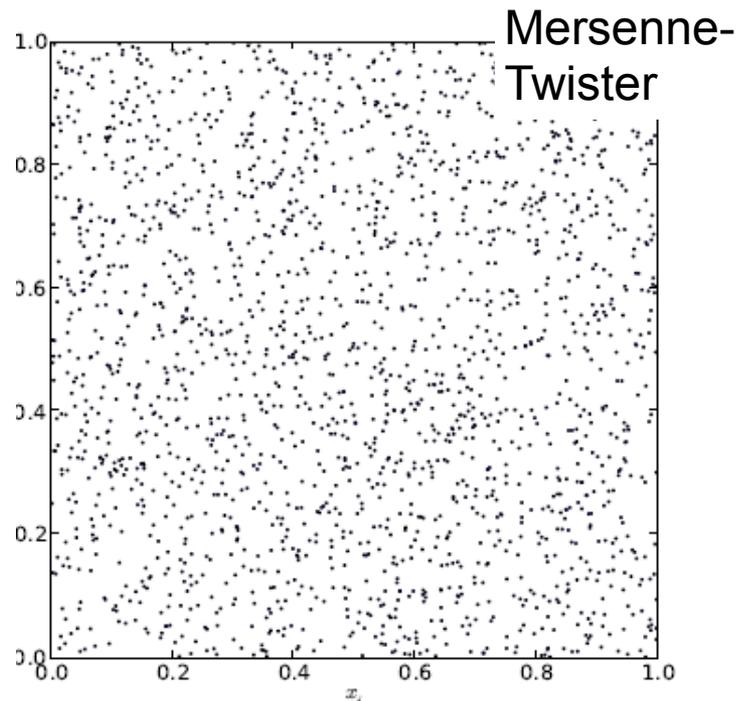
Tests für Zufallszahlengeneratoren

- Trivialer Test: Histogramm der Zufallszahlen und Anpassung. Summe der Abstandsquadrate χ^2 sollte nahe $1/d.o.f$ sein
- Moderne, avancierte Tests:
 - G.Marsaglia: “Die-Hard Battery of Tests of Randomness” (1995)
15 verschiedene Tests (einschl. eines Satzes von guten Zufallszahlen)
 - P.L.Ecuyer und R.Simard: TestU01 (2007)
Small Crush (10 Tests), Crush (96 Tests), Big Crush (106 Tests)
<http://dl.acm.org/citation.cfm?doid=1268776.1268777>
- Es gibt Generatoren, die TestU01 überstehen.
- Ergebnisse für Mersenne-Twister:
 - erfüllt nicht alle Tests der “Big Crush” Suite
 - gilt inzwischen als kryptographisch unsicher, da vorhersagbar

Diese Einschränkungen von MT sind aber für unsere Zwecke nicht relevant

Quasi-Zufallszahlen

- Eine gleichmäßigere Abdeckung eines n-dimensionalen Raumes als mit Pseudo-Zufallszahlen lässt sich mit Quasi-Zufallszahlen erreichen
- Pseudo-Zufallszahlen “klumpen”



- Konvergenz $\sim 1/N$, besser als für Pseudo-Zufallszahlen
- Quasi-Zufallszahlen sind korreliert. Nur für Integration!
- Sequenz muß fortgesetzt werden. Dimension nachträglich nicht veränderbar

S.Press et al

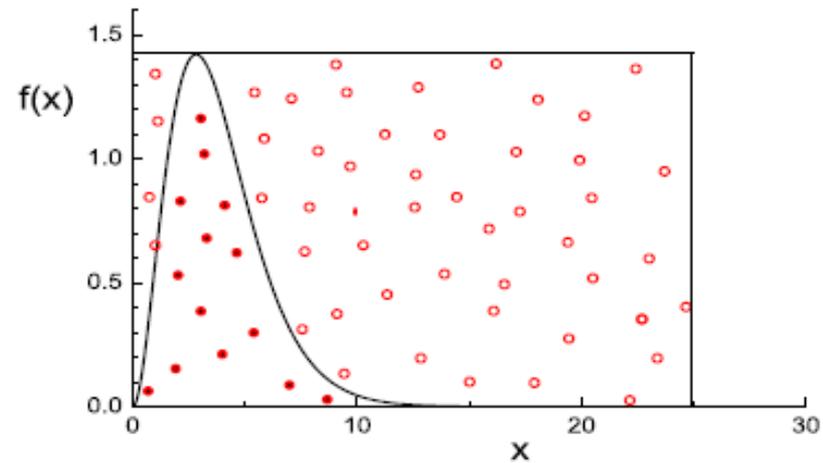
2.3

ERZEUGUNG VON VERTEILUNGEN

Beliebig verteilte Zufallszahlen

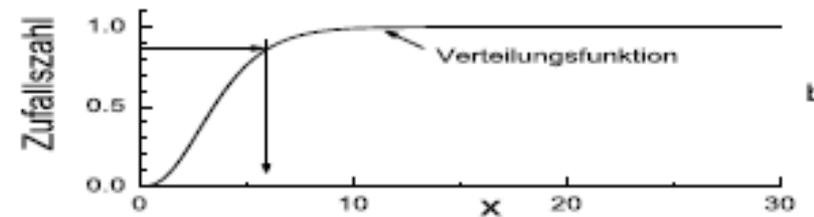
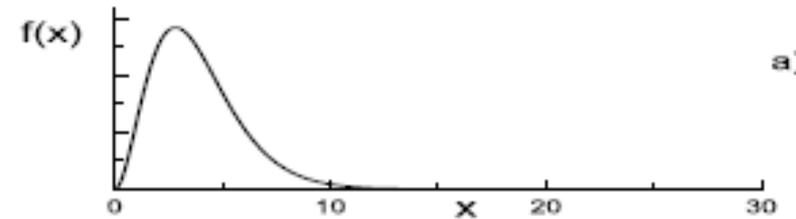
- Von Neumann'sches Rückweisungsverfahren ("Wegwerfmethode")

Generiere zwei Zufallszahlen r_1, r_2 , akzeptiere $x=r_1$, wenn $r_2 < f(x)$, x ist dann gemäß $f(x)$ verteilt



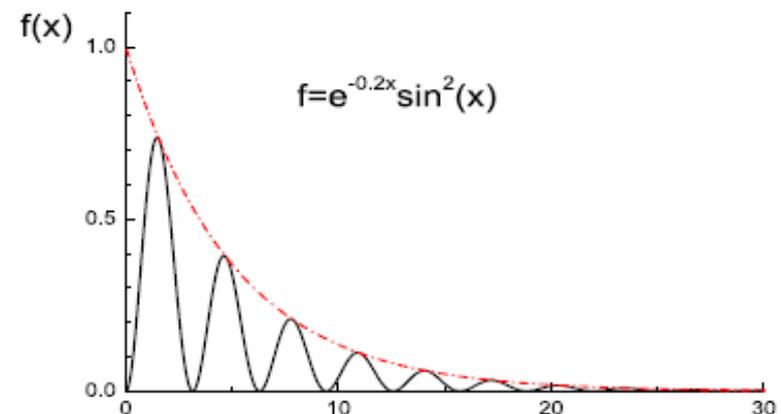
- Transformationsmethode

Transformiere gleichverteilte $r_i \in [0,1[$, so dass für eine geeignete Funktion $t(r)$, $x_i=t(r)$ der Verteilung $f(x)$ folgt. $t(r)$ ist die Inverse der Verteilungsfunktion $F(x)$



- Majoranten-Verfahren (Importance Sampling)

Kombination von 1) und 2): finde Einhüllende $m(x) \geq f(x)$, die mit 2) erzeugt werden kann. Erzeuge Zufallszahl x , und wende dann 1) an, d.h. erzeuge zweite Zufallszahl $r_2 \in [0,1]$ und akzeptiere x , wenn $r_2 \cdot m(x) < f(x)$



Von Neumannsches Rückweisungsverfahren

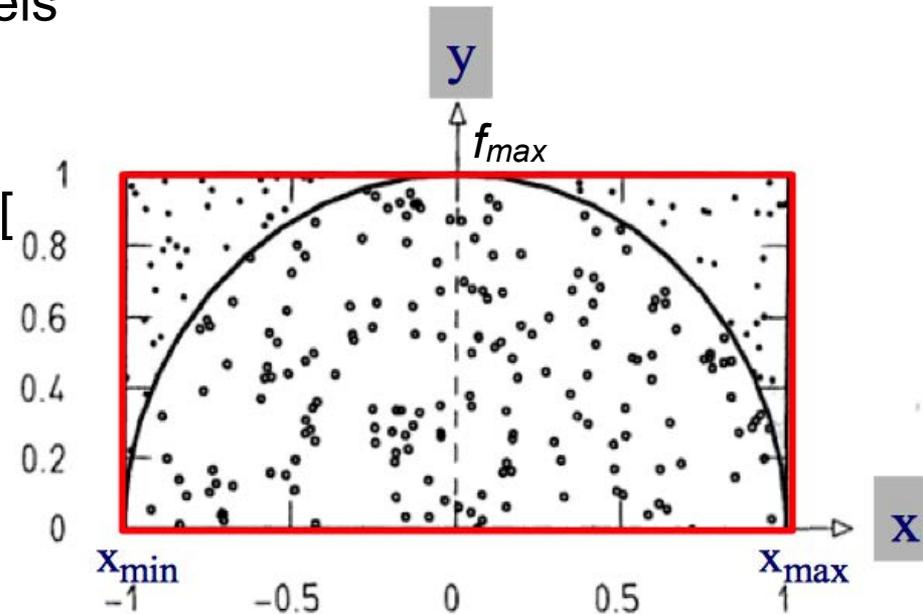
■ Beispiel: Verteilungsfunktion $f(x)$ Kreis

■ Erzeuge gleichmäßig in der Box verteilte Zufallszahlen $r_{2i}, r_{2i+1} \in]0, 1[$

■ $x_i = x_{\min} + r_{2i} (x_{\max} - x_{\min})$

■ $y_i = r_{2i+1} f_{\max}$

■ Akzeptiere x -Werte aus Paaren mit $y_i < f(x_i) = \sqrt{(R^2 - x_i^2)}$



■ Die Häufigkeitsverteilung der akzeptierten x -Werte folgt der gewünschten Verteilung $f(x)$

■ Für dieses Beispiel funktioniert das Verfahren gut. Wenn die Verteilung steil abfällt, und Werte von $x \rightarrow \infty$ benötigt werden, kann die Zahl der verworfenen Zufallszahlen aber unakzeptabel groß werden

Transformationsmethode

- Erzeuge gleichverteilte Zufallszahlen $r_i \in]0,1[$
- Variablentransformation: $r \rightarrow x$

$$f(x)dx = R(0,1)dr$$

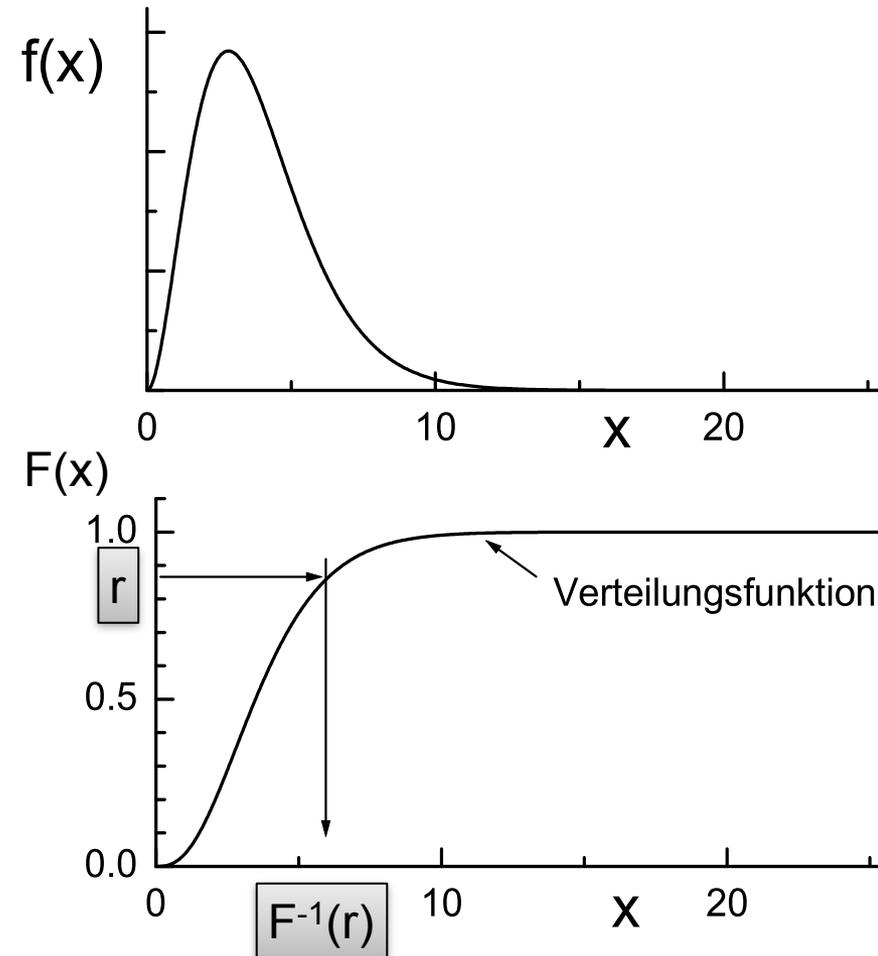
$$\int_{-\infty}^x f(x')dx' = \int_0^{r(x)} dr' = r(x)$$

$$F(x) = r$$

$$x = F^{-1}(r)$$

- Die Zufallszahlen $x_i = F^{-1}(r_i)$ folgen der PDF $f(x)$
- Anschaulich: Dichte $f(x)$ entspricht Steigung (Ableitung) $F'(x) = dF(x)/dx$

- Bedingung: $f(x)$ muss integrierbar und $F(x)$ invertierbar sein



Dreieck-Verteilung

$$f(x) = 2x \quad 0 \leq x \leq 1$$
$$x(r) = \sqrt{r}$$

$$f(x) = (n+1)x^n \quad 0 \leq x \leq 1, n > -1$$
$$x(r) = r^{1/(n+1)}$$

Exponentialverteilung

$$f(x) = \gamma e^{-\gamma x}$$
$$x(r) = -\frac{1}{\gamma} \ln(1-r)$$

Breit-Wigner-Verteilung

$$f(x) = \frac{1}{\pi\Gamma/2} \frac{(\Gamma/2)^2}{x^2 + (\Gamma/2)^2}$$
$$x(r) = -\frac{\Gamma}{2} \tan \left[\pi \left(r - \frac{1}{2} \right) \right]$$

Log-Weibull-Verteilung

$$f(x) = e^{-x-e^{-x}}$$
$$x(r) = -\ln(-\ln r)$$

Paar von Gauß-Zahlen (Herl. s. später)

$$f(x, y) = \frac{1}{2\pi} \exp \left[-\frac{x^2 + y^2}{2} \right]$$
$$x(r_1, r_2) = \sqrt{2 \ln(r_1 - 1)} \cos(2\pi r_2)$$
$$y(r_1, r_2) = \sqrt{2 \ln(r_1 - 1)} \sin(2\pi r_2)$$

Anmerkung:
r kann auch durch
1-r ersetzt werden

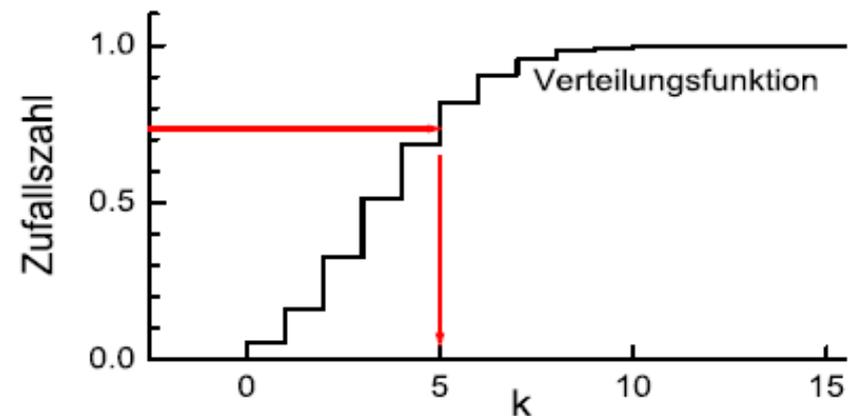
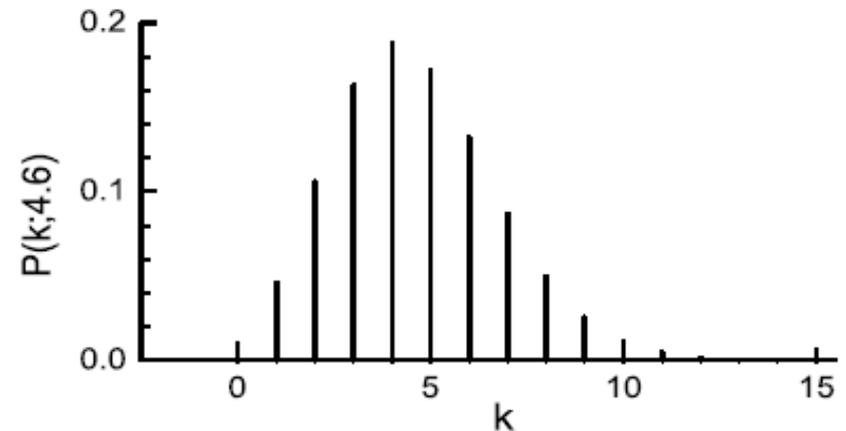
z.B. Bohm/Zech Abschnitt 4.2

Erzeugung diskreter Verteilungen

- Transformationsmethode funktioniert auch für diskrete Verteilungen (Beispiel: Poisson-Verteilung)

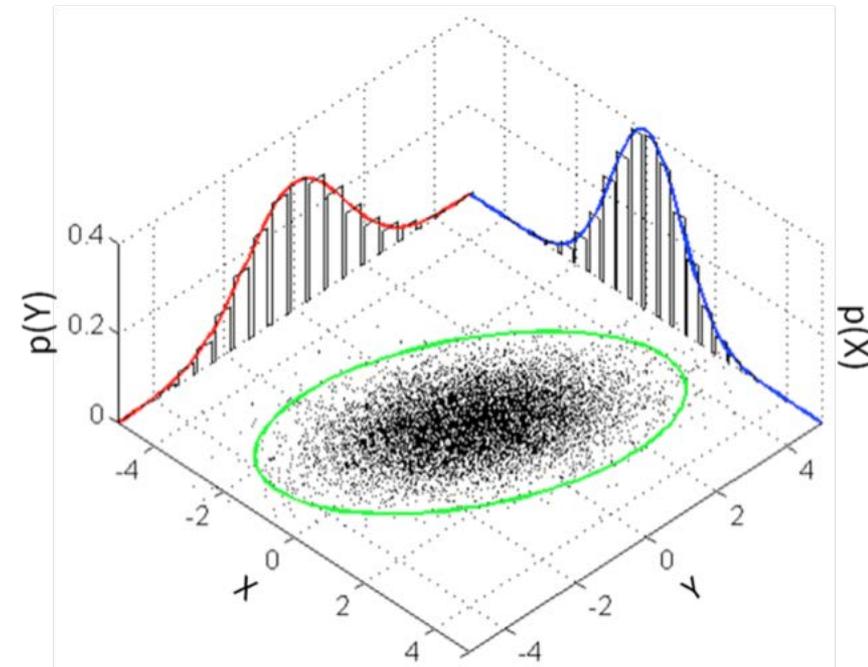
- Durch Summation aller Bins k der diskreten Verteilung erhält man die Verteilungsfunktion $S(k)$

- Eine Zufallszahlen r_i wird dem Bin k zugeordnet, das dem kleinsten $S(k)$ mit $r_i > S(k)$ entspricht



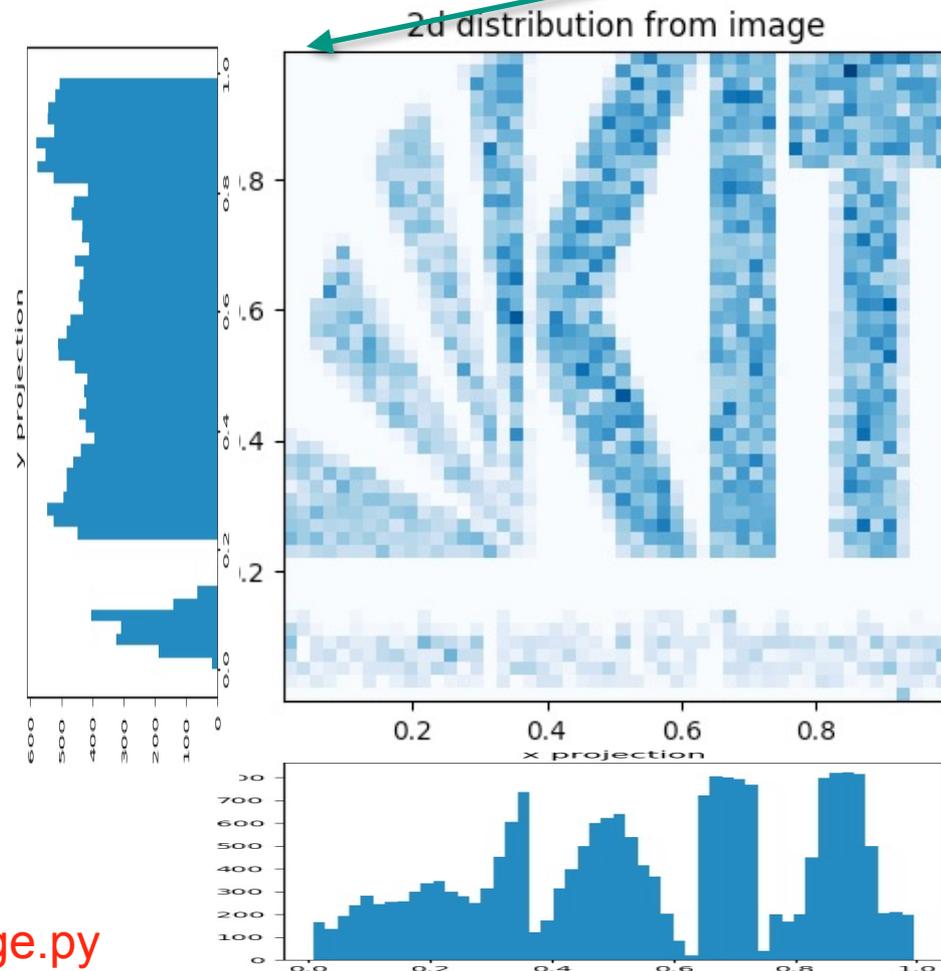
Verteilungen aus Histogrammen

- Allgemein kann die Transformationsmethode zur Erzeugung von Zufallszahlenverteilungen aus vorgegebenen Histogrammen verwendet werden
 - r_i bestimmt das Bin k
 - Der Rest $r_i - S(k-1)$ kann zur Interpolation innerhalb des Bins verwendet werden
- Auch für mehr-dimensionale Verteilungen:
 - bilde für jedes i :
Randverteilung $g_i = \sum h_{ij}$
(also Projektion von h_{ij} in j)
 - berechne Summenverteilungen über j
 - generiere i und dann für gegebenes i eine Bin-Nummer j



Quelle: Wikipedia

Beispiel: 2D Verteilung aus Bild

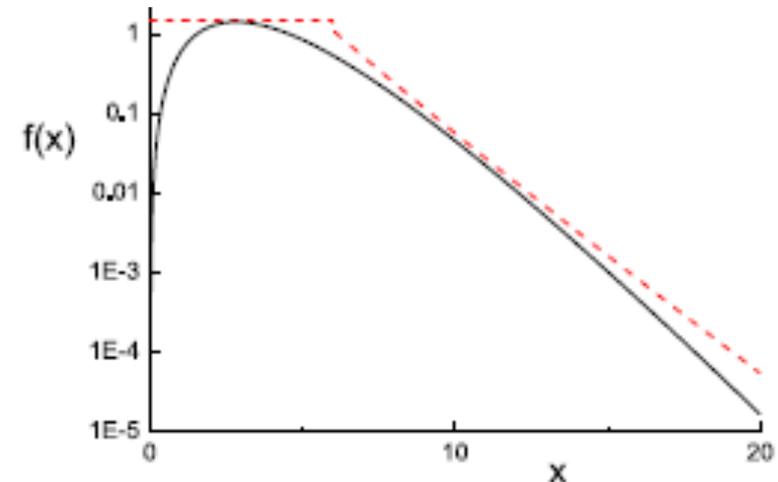
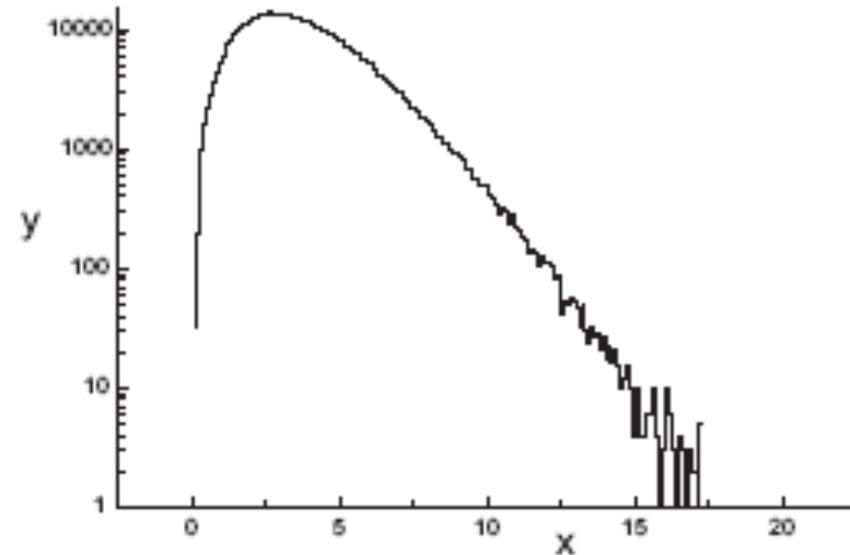


Beispiel: [Distribution-fromImage.py](#)

■ Helligkeit des Pixels wird als Wahrscheinlichkeitsdichte verwendet

Varianzreduzierende Verfahren

- Ziel: Verwende generierte Ereignisse möglichst effizient, z.B. bei steil abfallenden Verteilungen (d.h. strebe optimales Verhalten $\sigma \propto 1/\sqrt{N}$ an)
- Majorantenverfahren (Importance-Sampling):
Wenn eine Funktion $m(x)$ mit $m(x) > f(x)$ existiert und $x = M^{-1}(r)$ bestimmbar ist:
 - Generiere $x_i = M^{-1}(r_{2i})$ und eine weitere Zufallszahl $r_{2i+1} \in [0, 1]$
 - Akzeptiere x_i , wenn $r_{2i+1} \cdot m(x) < f(x)$
 - Die akzeptierten Werte von x sind gemäß $f(x)$ verteilt



Bohm, Zech Abb, 4.7

- Subtraktion eines analytisch lösbaren Funktionsanteils $f(x)$

$$\int_a^b g(x) dx = \int_a^b f(x) dx + \int_a^b |g(x) - f(x)| dx$$

- Stratified Sampling (geschichtete Stichprobe)

- Hohe (niedrige) Ereignisrate in Bereichen von hohem (niedrigem) Interesse (z.B. in der Nähe von Singularitäten und in Schwänzen)

- Integration für eine leicht modifizierte Funktion $g_m(x_i)$

- Verwende Gewichte $w_i = g_m(x_i) / g(x_i)$ zur Berechnung

$$I' = \int g_m(x) dx \approx \frac{b-a}{n} \sum g_m(x_i) = \frac{b-a}{n} \sum g(x_i) w_i$$

- Wird in der Teilchenphysik extrem häufig verwendet, z.B. Abschätzung der Auswirkung systematischer Unsicherheiten auf das Endergebnis

- Funktioniert auch mit negativen Gewichten

Bemerkung: Gewichtung von Ereignissen

- Betrachte Bin eines Histogramms mit gewichteter Ereigniszahl N_w

$$N_w = \sum_i w_i k_i \quad \text{und} \quad V[N_w] = \sum_i \left(\frac{\partial N_w}{\partial k_i} \right)^2 V[k_i] = \sum_i w_i^2 V[k_i]$$

- Ein einzelnes Ereignis k_i ist Poisson-verteilt mit $E[k_i] = V[k_i] = 1$

$$V[N_w] = \sum_i w_i^2$$

- Deshalb müssen bei gewichteten Einträgen auch die Quadrate der Gewichte mitgenommen werden (siehe auch Vorl.1, Folie 43).
- Stark unterschiedliche Gewichte führen zu großer Varianz:

$$\frac{\delta(\sum w_i)}{\sum w_i} = \frac{\sqrt{\sum w_i^2}}{\sum w_i}$$

Gauß-verteilte Zufallszahlen

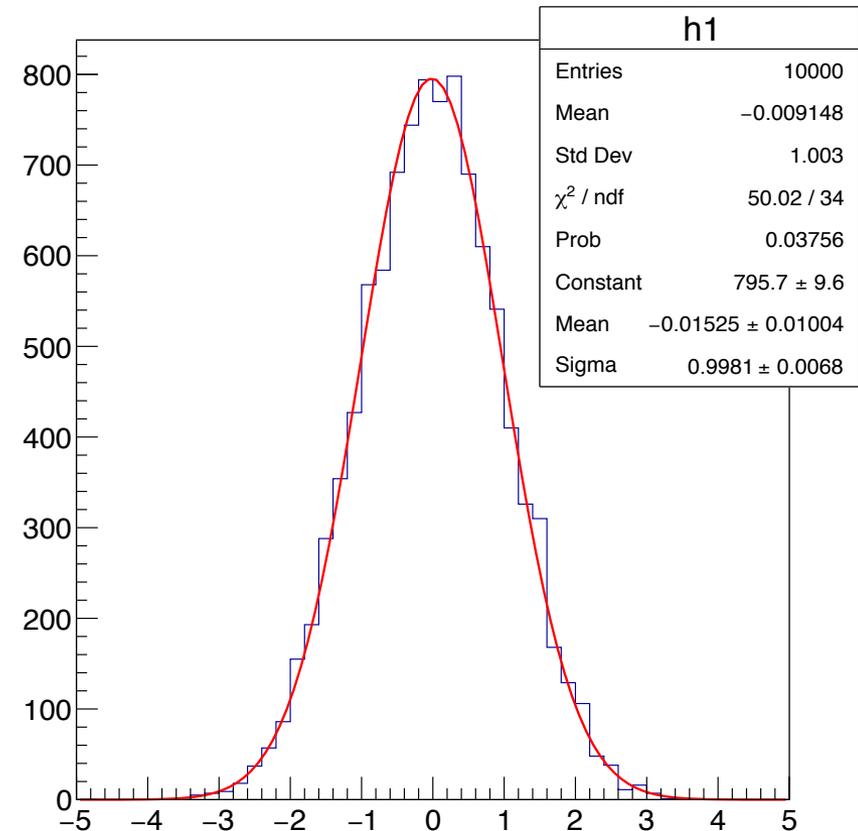
- Mit zentralem Grenzwertsatz:
Für große n geht

$$w = \sum_{i=1}^n x_i \text{ über in eine}$$

Gauß-Verteilung mit

$$\langle w \rangle = n \langle x \rangle \text{ und } V[w] = n \sigma^2$$

- Gute Gauß-Verteilung schon für relativ kleine n , z.B. $n = 12$



$$z_i = \sum_{j=1}^{12} u_j - 6$$

Blobel/Lohrmann Abschnitt 5.5.2

- Problem: Benötigen kumulierte Verteilungsfunktion der Gauß-Verteilung $\text{erf}(x) = \frac{2}{\sqrt{\pi}} \int_0^x e^{-t^2} dt$ - in 1D nur numerisch berechenbar.
- In zwei Dimensionen ist Gauß analytisch integrierbar (Polarkoordinaten)
$$\int \int \frac{1}{2\pi} \exp\left(-\frac{x^2 + y^2}{2}\right) dx dy \quad \rightarrow \quad \int_0^{2\pi} \frac{1}{2\pi} d\phi \int_0^r \exp\left(-\frac{r^2}{2}\right) r dr$$
- Gleichverteilung in φ , Radialverteilung integrierbar mit $r dr = 1/2 dr^2$
$$\int_0^r \exp\left(-\frac{r^2}{2}\right) \frac{1}{2} dr^2 = 1 - \exp\left(-\frac{r^2}{2}\right)$$
- Lässt sich nach r auflösen, d.h. Transformationsmethode ist anwendbar
- Erzeuge zwei gleichverteilte Zufallszahlen $u_1, u_2 \in]0, 1]$. Dann sind z_1, z_2 standard-normalverteilt:

$$z_1 = \sqrt{-2 \ln u_1} \cos(2\pi u_2)$$
$$z_2 = \sqrt{-2 \ln u_1} \sin(2\pi u_2)$$

Effizienteres Verfahren

- Trigonometrische Funktionen sind numerisch aufwändig.
- Kombination aus Transformations- und Rückweisungsverfahren:

1. Erzeuge zwei gleichverteilte Zufallszahlen $u_1, u_2 \in [0, 1[$ und setze $v_1 := 2u_1 - 1$ und $v_2 := 2u_2 - 1$
2. Berechne $v_2 = v_1^2 + v_2^2$
3. Falls $v^2 \geq 1 \rightarrow$ gehe zu 1.)
Akzeptierte Werte von v_1, v_2 sind gleichverteilt innerhalb des Einheitskreises

4. Berechne:

$$z_1 = v_1 \sqrt{-2 \ln(v^2) / v^2}$$
$$z_2 = v_2 \sqrt{-2 \ln(v^2) / v^2}$$

- z_1 und z_2 sind dann unabhängig voneinander standard-normalverteilt.
- Gauß-Verteilung mit Erwartungswert μ und Standardabweichung σ erhält man durch die Transformation $x = \sigma z + \mu$

- Gauß-Verteilung in n Dimensionen:

$$P(\vec{x}, \vec{\mu}, V) = \frac{1}{(2\pi)^{n/2} \sqrt{|V|}} \exp \left(-\frac{1}{2} (\vec{x} - \vec{\mu})^T V^{-1} (\vec{x} - \vec{\mu}) \right)$$

- $\vec{\mu}$: n Erwartungswerte,
- V : Kovarianzmatrix mit $(n^2+n)/2$ unabhängigen Parametern.
- $|V| = \det V$ ist die Determinante von V

Cholesky-Zerlegung

- Schreibe V^{-1} als Produkt von Dreiecksmatrizen $V^{-1} = D^T D$

- Mit $\vec{u} = D(\vec{x} - \vec{\mu})$ folgt: $G(\vec{x}, \vec{\mu}, V) = \frac{1}{(2\pi)^{n/2} \sqrt{|V|}} \exp \left(-\frac{1}{2} \vec{u}^T \vec{u} \right)$

- Vorgehensweise also:

- Würfle n unabhängige Gauß-verteilte Zufallszahlen u
- Transformiere Vektor u : $\vec{x} = D^{-1} \vec{u} + \mu$

Blobel/Lohrmann Abschnitt 5.4

Korrelierte Gauß-verteilte Zufallszahlen

$$V = \begin{pmatrix} \sigma_1^2 & \rho \sigma_1 \sigma_2 \\ \rho \sigma_1 \sigma_2 & \sigma_2^2 \end{pmatrix}$$

$$D^{-1} = \begin{pmatrix} \sigma_1 & 0 \\ \rho \sigma_2 & \sigma_2 \sqrt{1 - \rho^2} \end{pmatrix}$$

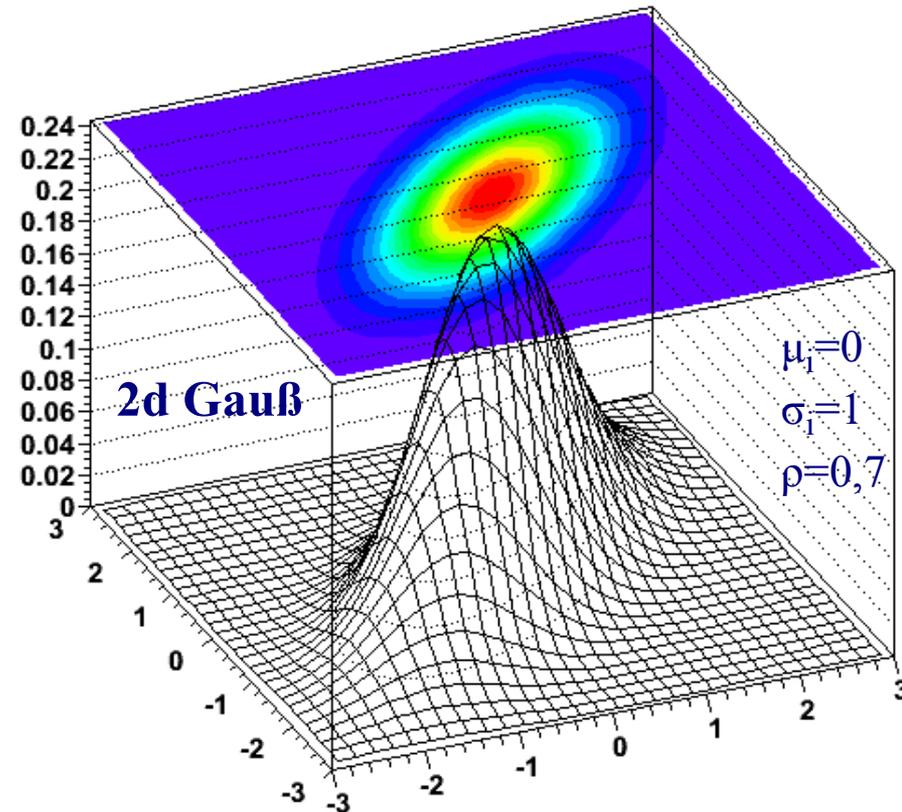
$$\vec{x} = D^{-1} \vec{u} + \mu$$

- Verwende standard-normalverteilte unkorrelierte u_1 und u_2
- Dann sind x_1 und x_2 standard-normalverteilt und korreliert mit Korrelationskoeffizient ρ :

$$x_1 = \mu_1 + \sigma_1 u_1$$

$$x_2 = \mu_2 + \sigma_2 \left(\rho u_1 + \sqrt{1 - \rho^2} u_2 \right)$$

- **Bemerke:** u_1 trägt zu x_1 und x_2 bei
→ Korrelation



Beispiel: [rangauss2d.C](#) oder [rangauss2d-pyroot.py](#)

Globel/Lohrmann Abschnitt 5.4

Zwischenrechnung

■ Berechne aus V:

$$V^{-1}V = 1$$

$$V^{-1} = D^T D \quad \text{mit } D_{21}=0$$

$$D^{-1}D = 1$$

$$V = \begin{pmatrix} \sigma_1^2 & \rho \sigma_1 \sigma_2 \\ \rho \sigma_1 \sigma_2 & \sigma_2^2 \end{pmatrix}$$

$$D = \begin{pmatrix} 1/\sigma_1 & 0 \\ \frac{-\rho}{\sigma_1 \sqrt{1-\rho^2}} & \frac{1}{\sigma_2 \sqrt{1-\rho^2}} \end{pmatrix}$$

$$D^T = \begin{pmatrix} 1/\sigma_1 & \frac{-\rho}{\sigma_1 \sqrt{1-\rho^2}} \\ 0 & \frac{1}{\sigma_2 \sqrt{1-\rho^2}} \end{pmatrix}$$

$$V^{-1} = \frac{1}{\sigma_1^2 \sigma_2^2 (1 - \rho^2)} \times \begin{pmatrix} \sigma_2^2 & -\rho \sigma_1 \sigma_2 \\ -\rho \sigma_1 \sigma_2 & \sigma_1^2 \end{pmatrix}$$

$$D^{-1} = \begin{pmatrix} \sigma_1 & 0 \\ \rho \sigma_2 & \sigma_2 \sqrt{1 - \rho^2} \end{pmatrix}$$

Blobel/Lohrmann Abschnitte 5.4 und 3.6

- Monte Carlo Methode (auch “MC-Simulation”)
 - Integration in hochdimensionalen Räumen
 - Nachbildung von komplexen Prozessen (z.B. experimentelle Apparaturen)
 - Bestimmung der Eigenschaften von Verteilungen von Zufallszahlen

- Vorgehensweise
 - Erzeuge Folge von Zufallszahlen r_1, r_2, \dots, r_m gleichverteilt in $]0, 1]$.
 - Transformiere diese zur Erzeugung einer anderen Sequenz x_1, \dots, x_n , die einer Verteilungsdichte $f(x)$ folgen
 - Aus den x_i werden dann Eigenschaften von $f(x)$ bestimmt.

- Einfache Operationen mit den x_i ersetzen sehr viel komplexere Operationen auf den Verteilungsdichten.

- Paket `numpy.random`:
 - `binomial(n, p[, size])`
 - `chisquare(df[, size])`
 - `exponential([scale, size])`
 - `lognormal([mean, sigma, size])`
 - `multinomial(n, pvals[, size])`
 - `multivariate_normal(mean, cov[, size])`
 - `normal([loc, scale, size])`
 - `poisson([lam, size])`
 - `power(a[, size])`
 - `standard_cauchy([size])`
 - `standard_exponential([size])`
 - `standard_normal([size])`
 - `standard_t(df[, size])`
 - `triangular(left, mode, right[, size])`
 - `uniform([low, high, size])`

<https://docs.scipy.org/doc/numpy/reference/routines.random.html>

- TRandom: LCG
 - schnell, kurze Periode: 10^9
 - niedrigste Bits nicht unkorreliert, nicht verwenden!
- TRandom1: RANLUX (Lüscher, James '94)
 - langsam, lange Periode: 10^{171}
 - übersteht TestU01 Suite (auf höchstem Level)
 - <http://arxiv.org/abs/hep-lat/9309020>
- TRandom2: Tausworthe (P.L'Ecuyer '96)
 - schnell, Periodenlänge ok 10^{26}
- TRandom3: Mersenne-Twister ('98)
 - hinreichend schnell, Periodenlänge 10^{6000}
 - Default: gRandom points to TRandom3
- Methoden: Exp(tau), Integer(imax), Gaus(mean,sigma), Rndm(), Uniform(x1), Landau(mpv, sigma), Poisson(mean), Binomial(ntot, prob) u.v.m.

- Methode `SetSeed(UInt_t seed=0)` zur Initialisierung
 - `seed=0`: Systemuhr zur Initialisierung (jede Zahlenfolge anders)
 - `seed !=0`: feste Zahlenfolge, abhängig vom Wert von `seed`
- Globaler Zeiger `TRandom *gRandom` in Root initialisiert
Sehr nützlich, um immer die gleiche Folge von Zufallszahlen innerhalb eines Root-Programms zu verwenden.
- `TRandom` durch `TRandom3` ersetzen
`delete gRandom;`
`gRandom = new TRandom3(seed);`
- Man kann auch auch einen eigenen (lokalen) Generator initialisieren:
`TRandom3 *myrandom=new TRandom3(seed);`