

Prinzipien zur Erzeugung von Zufallszahlen in der Informatik

Vortragender: Dipl.-Inform. Thomas Hinze

1. **Motivation**
2. Grundlegende **Begriffe** und **Zusammenhänge**
3. **Klassifikation** der Prinzipien
4. Prinzipien zur Erzeugung **echter Zufallszahlen**
5. **Pseudozufallszahlengeneratoren**
6. **Statistische Tests** zur **Bewertung** der einzelnen Prinzipien
7. **Zusammenfassung**, Literatur

Motivation

Zufallszahlen

- besitzen mannigfaltige Anwendungen in der Informatik
- ermöglichen den effizienten computergestützten Einsatz und
- beschleunigte Bearbeitung zahlreicher Aufgabenstellungen

wichtige Anwendungsgebiete und -beispiele in der Informatik

- **probabilistische Algorithmen**
 - z.B. Monte-Carlo- und Las-Vegas-Methoden
- **Simulation**
 - Generierung zufälliger Ereignisse entsprechend statistischer Vorgaben
- **Kryptographie / Kryptoanalyse**
 - z.B. Schlüssel- und Parametererzeugung, Verschlüsselungsverfahren, Verfahren zur digitalen Signatur, Dummy Traffic, Angriffe auf kryptographische Verfahren
- **Test**
 - Generierung von Testsätzen

Grundlegende Begriffe und Zusammenhänge

zufälliges Ereignis

- **Ereignis**, dessen Eintrittszeitpunkt und Wirkung **nicht** mit absoluter Sicherheit **vorhergesagt** werden kann
 - setzt eine unvollständige Beschreibung des Systems, in dem das zufällige Ereignis stattfinden kann, voraus
 - Zufall \rightarrow Ausdruck von **Unwissenheit**

Zufallsgröße

- meßbare / analysierbare Repräsentation der Gesamtheit aller zufälligen Ereignisse der zugrundeliegenden Systemkomponente
- **Wertebereich, Wertevorrat**

diskret \rightarrow **endlicher** oder **abzählbar unendlicher** Wertevorrat

Zufallszahl

- **Wert**, den eine Zufallsgröße bei ihrer Bestimmung annimmt

Zufallszahlenfolge

- Folge voneinander möglichst **unabhängiger** Zufallszahlen, die einer gegebenen **statistischen Verteilung** genügen

Vereinbarungen und Forderungen in der Informatik

- **Verarbeitung** der Zufallszahlen (ZZ) in jedem Fall durch Computer
- **Erzeugung** der ZZ entweder durch Computer oder extern

Grundanforderungen an Zufallszahlengeneratoren

- **Uniformität** – Gleichvert. der ZZ innerhalb jeder erzeugten Folge
- **Unabhängigkeit** – keine Autokorrelation zwischen den ZZ innerhalb jeder erzeugten Folge

zusätzliche Wünsche/Erfordernisse für Anwendungen der Informatik

- **diskrete** Zufallsgrößen
- anwendungsabhängig: **Reproduzierbarkeit/Irreproduzierbarkeit** der Zufallszahlenfolgen
- Gleichvert. der Zufallszahlen oft im **Intervall** $[0, 1)$, $\{0, 1\}$, $\{0, \dots, 9\}$
- **Schnelligkeit, Effizienz, Unvorhersagbarkeit** des Generators

Bemerkungen

- Transformation Gleichverteilung → andere bekannte Verteilungen mathematisch herleitbar und berechenbar
- Intervall $[0, 1)$ gequantelt entspr. computerinterner Zahlendarst.

Definitionen aus der mathematischen Statistik

diskret gleichverteilte Zufallsgröße

Eine diskrete Zufallsgröße X heißt **gleichverteilt** auf den Ereignissen a_1, \dots, a_n , wenn für $i = 1, \dots, n$ gilt:

- Gleichwahrscheinlichkeit der Ereignisse: $P(X = a_i) = \frac{1}{n}$
- Erwartungswert: $EX = \frac{1}{n} \sum_{i=1}^n a_i$
- Streuung: $D^2 X = \frac{1}{n} \sum_{i=1}^n (a_i - EX)^2$

Korrelation

- Grad des Zusammenhangs zwischen Zufallsgrößen

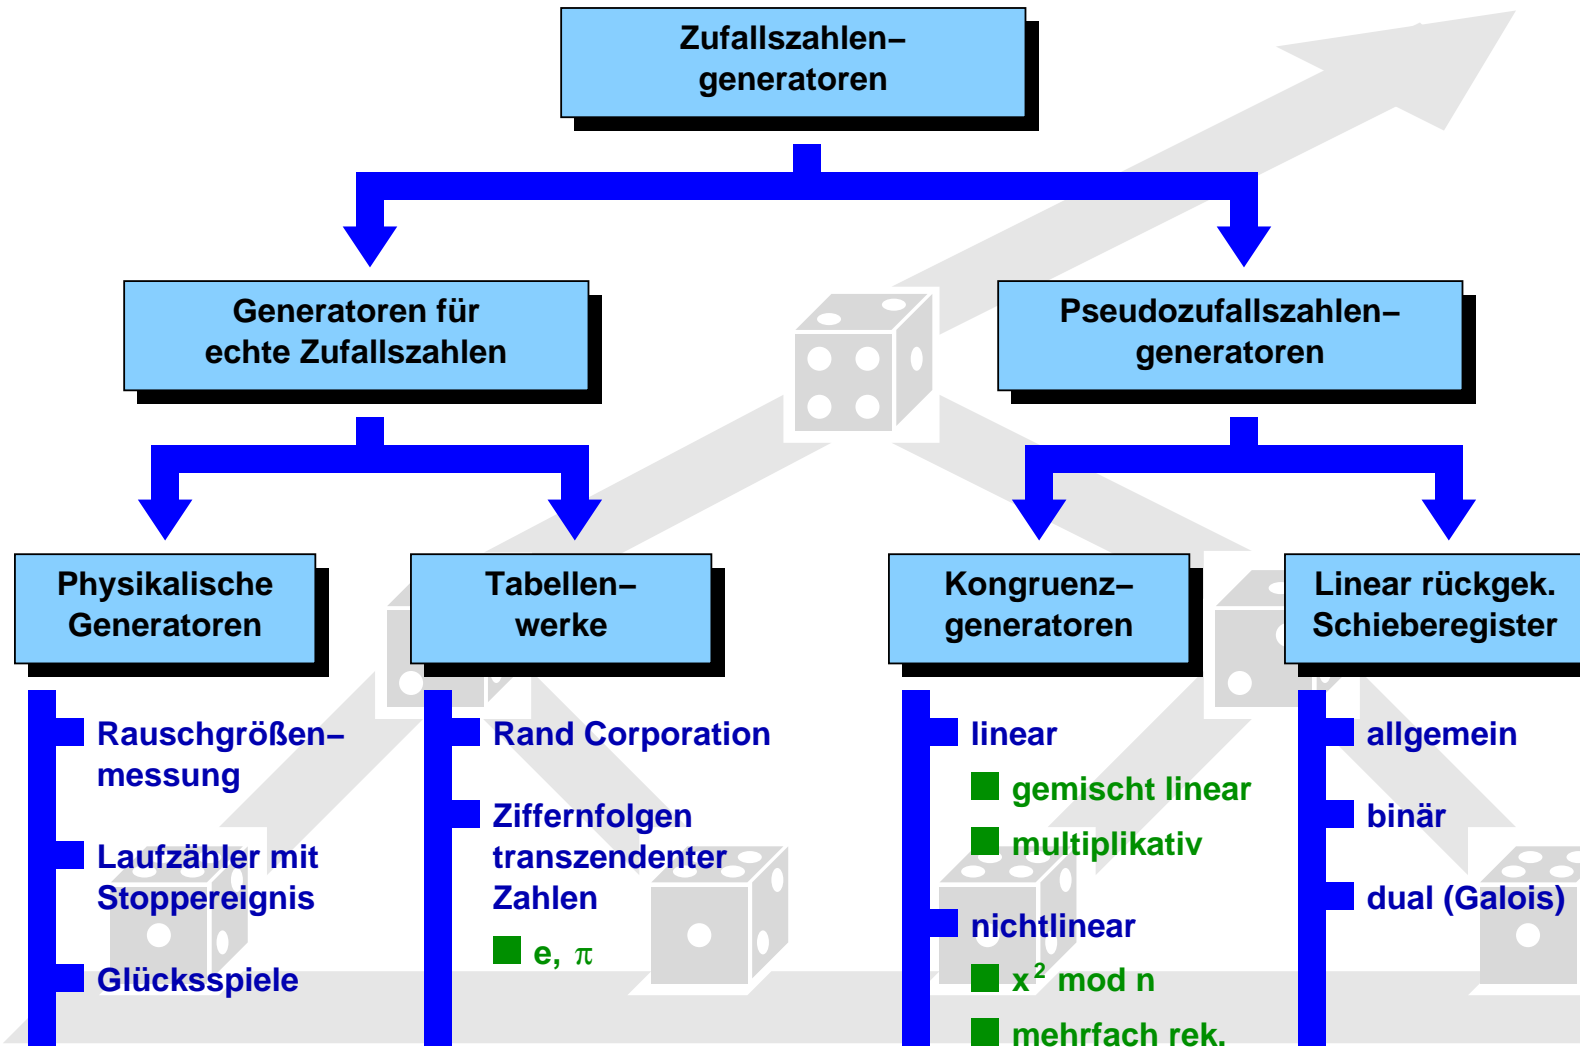
Korrelationskoeffizient

- zweier Zufallsgrößen X und Y : $\rho(X, Y) := \frac{E(X \cdot Y) - EX \cdot EY}{\sqrt{D^2 X \cdot D^2 Y}}$
- Es gilt: $\rho(X, Y) = \begin{cases} = 0 & \text{oder } \text{cov}(X, Y) = 0 \longrightarrow X, Y \text{ unkorreliert} \\ \neq 0 & \longrightarrow X, Y \text{ voneinander abhängig} \end{cases}$

Autokorrelation

- Korrelation einer Zufallsgröße X mit sich selbst ($\rho(X, X)$)

Klassifikation der Prinzipien



Rauschgrößenmessung

Prinzip

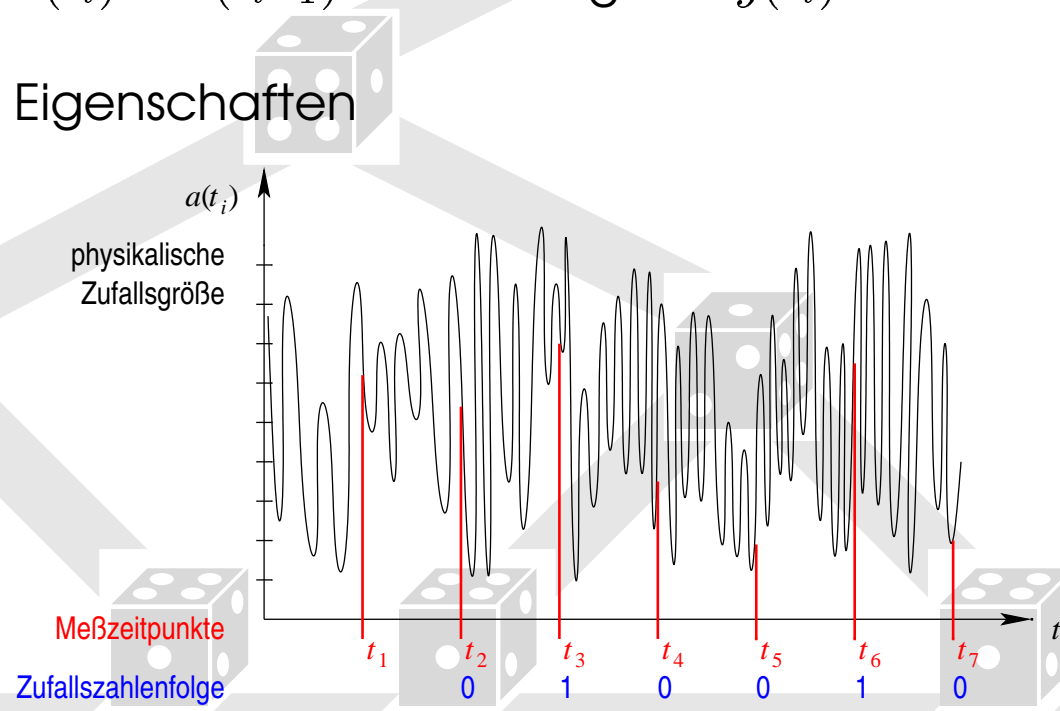
- zeitquantisierte Erfassung einer zugrundeliegenden physikalischen Zufallsgröße und Transformation in Zufallszahlenfolge
- Transformation z.B.: $a(t_i) \geq a(t_{i-1}) \rightarrow \text{Ausgabe } y(t_i) = 1$
 $a(t_i) < a(t_{i-1}) \rightarrow \text{Ausgabe } y(t_i) = 0$

Vorteile

- optimale statistische Eigenschaften
- ohne Speich. keine Reproduzierbarkeit

Nachteile

- Auswirkungen von Meßfehlern
- Verfügbarkeit und max. Abtastrate abhängig von phys. Zufallsgröße



Laufzähler mit Stoppereignis

Prinzip


- Zähler modulo n , der in schneller Folge fortlaufend von 0 bis $n - 1$ zählt und jeweils bei Eintreten des zufälligen zählerunabhängigen Stoppereignisses sofort den aktuellen Zählerwert als Zufallszahl bereitstellt

Vorteile

- optimale statistische Eigenschaften
- ohne Speich. keine Reproduzierbarkeit

Nachteile

- Organisation der Stoppereignisse
- Stoppereignisse nicht zeitlich äquidistant
- mehrfaches vollständiges Durchzählen zwischen aufeinanderfolgenden Stoppereignissen sicherzustellen



Rand Corporation

Prinzip

- Tabellenwerk (Buch) von Zufallszahlen, entstanden 1955
- enthält 1.000.000 Zufallszahlen
 - 400 Seiten zu 50 Zeilen mit je 50 Zufallszahlen (Dezimalziffern)
 - Buch zufällig aufschlagen, Folge wählen und
 - als genutzt kennzeichnen
- Zufallszahlen mittels physikalischem Generator erzeugt

Vorteile

- leichte Verfügbarkeit
- optimale statistische Eigenschaften
- Reproduzierbarkeit/Irreproduzierbarkeit
leicht vom Anwender steuerbar

Nachteile

- endlicher Vorrat an Zufallszahlen
- Übertragung Buch → Computer
- Bekanntheit des Buches

Ziffernfolgen transzendenter Zahlen

Definition transzendente Zahlen

Zahlen, die nicht algebraisch sind, d.h. die nicht als Nullstellen beliebiger Polynome $a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x + a_0$ mit $a_i \in \mathbb{Q}$ und $i \in \{0, \dots, n\}$, $n \in \mathbb{N} \setminus \{0\}$ vorkommen können. (z.B. e , π)

Prinzip

- Berechnung und Tabellierung der gewünschten transzendenten Zahl auf hinreichend viele zuverlässige Nachkommastellen (z.B. mittels Spigotalgorithmus)
- zufällige Auswahl einer Ziffernfolge, Nutzung als Zufallszahlenfolge und Kennzeichnung als bereits genutzt

Vorteile

- leichte rechnergestützte Realisierbarkeit
- leichte Vorabgen. für spätere Nutzung

Nachteile

- keine gesicherten statistischen Eigenschaften, nur Annahmen
- hoher Bekanntheitsgrad der Ziffernfolgen

A rectangular box with a thin red border containing three lines of digits. The first line is '3, 141 592 653' in green. The second line is '2, 718 281 828 ...' in brown. The third line is '589 793 238 ...' in green. The digits are grouped with spaces, and the first line starts with a comma. The background of the slide features a large, faint, light-gray arrow pointing from the top-left towards the bottom-right, with several dice scattered along its path.

3, 141 592 653
2, 718 281 828 ...
589 793 238 ...

Pseudozufallszahlengeneratoren

- Gewinnung der Zahlenfolgen durch **deterministische Berechnung**
- Zufall \rightarrow Pseudozufall: Wegfall der generellen Unvorhersagbarkeit

gemeinsames Prinzip

- ausgehend von einem zufällig gewählten **Startwert** und **geeigneten Parameterbelegungen** erfolgt Bestimmung der Pseudozufallszahlenfolge durch spezifische **rekursive Berechnungsvorschrift**

Forderung für perfekten Pseudozufallszahlengenerator

- Es soll **keinen effizienten** (polynomiellen) **Algorithmus** geben, der eine **Pseudozufallszahlenfolge** ohne Kenntnis der Berechnungsvorschrift, des Startwertes und der Parameterbelegungen signifikant von einer **echten Zufallszahlenfolge unterscheiden** kann.

gemeinsame Eigenschaft

- **Periodizität:** zyklische Wiederholung der Pseudozufallszahlenfolge (PZZ-Folge) nach endlicher Länge
- **Ziel:** Maximierung der Periodenlänge

Multiplikativer Kongruenzgenerator

Prinzip

Parameter: $a, m \in \mathbb{N}$ mit $a \geq 2, a < m, m > 1$

Startwert: $z_0 \in \{1, \dots, m-1\}$

Rekursion: $z_i = (a \cdot z_{i-1}) \bmod m$

PZZ-Folge: $r_i = z_i/m$ Es gilt: $r_i \in [0, 1)$

maximale Periodenlänge

- m unter folgenden Bedingungen (Kobayashi):
 - $m = p^l$ oder $m = 2p^l$ mit p ungerade Primzahl, $l \in \mathbb{N} \setminus \{0\}$
 - $a^{m-1} \equiv 1 \pmod{m}$
 - $\text{ggT}(z_0, m) = 1$
- Minimierung der Autokorrelation: $a \approx \sqrt{m}$

Vorteile

- Schnelligkeit des Verfahrens und leichte Implementierbarkeit

Nachteile

- keine optimalen statistischen Eigenschaften, kleine Periodenlänge
- leichte Vorhersagbarkeit der PZZ-Folge (nicht perfekt)

Gemischt linearer Kongruenzgenerator

Prinzip

Parameter: $a, c, m \in \mathbb{N}$ mit $a < m, a \geq 2, c < m, c > 0, m > 1$

Startwert: $z_0 \in \{1, \dots, m - 1\}$

Rekursion: $z_i = (a \cdot z_{i-1} + c) \bmod m$

PZZ-Folge: $r_i = z_i/m$ Es gilt: $r_i \in [0, 1)$

maximale Periodenlänge

- m unter folgenden Bedingungen (Lehmer):
 - $\text{ggT}(c, m) = 1$
 - $a \equiv 1 \pmod q$ für jeden Elementarteiler q von m
 - $a \equiv 1 \pmod 4$ falls 4 Teiler von m ist
- Minimierung der Autokorr. (Fishman/Greenb.): $a \approx \sqrt{m - \frac{6c}{m} \left(1 - \frac{c}{m}\right)}$

Vorteile

- Schnelligkeit des Verfahrens und leichte Implementierbarkeit

Nachteile

- keine optimalen statistischen Eigenschaften, kleine Periodenlänge
- leichte Vorhersagbarkeit der PZZ-Folge (nicht perfekt)

Mehrfach rekursiver Kongruenzgenerator

Prinzip

Parameter: $r, m, a_1, \dots, a_r \in \mathbb{N}$ mit $r \geq 1, a_i \in \{0, \dots, m-1\}, m > 1$

Startwerte: $z_1, \dots, z_r \in \{0, \dots, m-1\}$ mit $\exists j \in \{1, \dots, r\} \cdot z_j \neq 0$

Rekursion: $z_i = \left(\sum_{k=1}^r a_k \cdot z_{i-k} \right) \bmod m$

PZZ-Folge: $r_i = z_i/m$ Es gilt: $r_i \in [0, 1)$

- Spezialfall: Fibonacci-Generator

maximale Periodenlänge

- $m^r - 1$ Belegungsvorschrift der Parameter für max. Periodenlänge ändert sich mit jedem Vorgabewert für r , keine geschl. Darst.

Vorteile

- größere maximale Periodenlänge, schwierigere Vorhersagbarkeit
- Schnelligkeit des Verfahrens und leichte Implementierbarkeit

Nachteile

- keine optimalen statistischen Eigenschaften, nicht perfekt
- hoher Aufwand zum Finden geeigneter Parameterbelegungen

$x^2 \bmod n$ Generator

- Verfahren nach Blum, Shub

Prinzip

Parameter: $s, p, q \in \mathbb{N}$ mit p, q prim, $p \approx q$, $p, q \equiv 3 \pmod{4}$,
 $0 < s < pq$, $\text{ggT}(s, pq) = 1$

Startwert: $z_0 = s^2 \bmod (pq)$

Rekursion: $z_i = z_{i-1}^2 \bmod (pq)$

PZZ-Folge: $r_i = z_i \bmod 2$ Es gilt: $r_i \in \{0, 1\}$

maximale Periodenlänge

- pq

Vorteile

- perfekter Pseudozufallszahlengenerator
- leichte Implementierbarkeit
- leichte Wahl geeigneter Parameterbelegungen

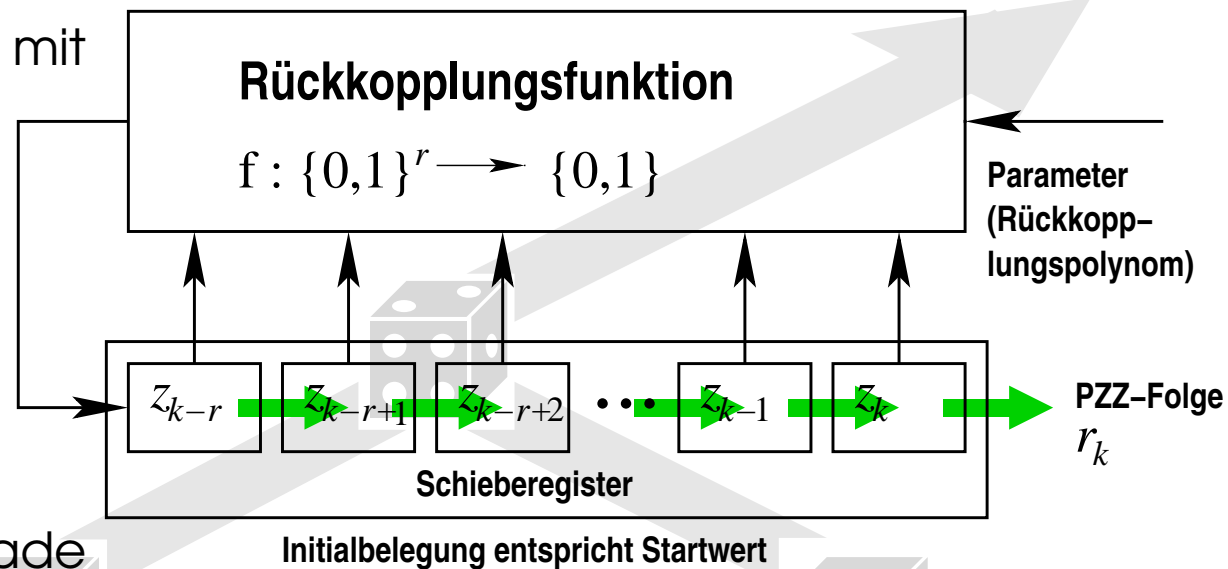
Nachteile

- nur ein Bit pro Rekursionsschritt \rightarrow langsam
- kleine Periodenlänge

Linear rückgekoppeltes Schieberegister

Prinzip

- Schieberegister mit Bitfolge $\neq 0^r$ initialisiert
 - jede Zelle speichert ein Bit für einen Takt (D1)
 - Bits schieben sich taktweise durch die Kaskade
 - Bit der letzten Zelle als Pseudozufallsbit taktweise ausgegeben
 - Bit der ersten Zelle mittels Rückkopplungsfunktion berechnet
 - Rückkopplungsfunktion und ihre Parameter bestimmen wesentlich die Qualität der statistischen Eigenschaften der PZZ-Folge
 - gleichwertige Notation auch als Rekursionschema möglich
- maximale Periodenlänge**
- $2^r - 1$ Bit, unabhängig von der gewählten zulässigen Initialisierung



Binäres linear rückgekoppeltes Schieberegister

Prinzip

- Rückkopplungsfunktion ist mit den Parametern $b_i \in \{0, 1\}$ mit $i \in \{1, \dots, r\}$ behaftet

- Parameter b_i bilden Koeffizienten des **charakt. Polynoms**

$$p : \{0, 1\} \rightarrow \{0, 1\}$$

$$p(x) = b_r x^{r-1} \oplus \dots \oplus b_3 x^2 \oplus b_2 x \oplus b_1$$

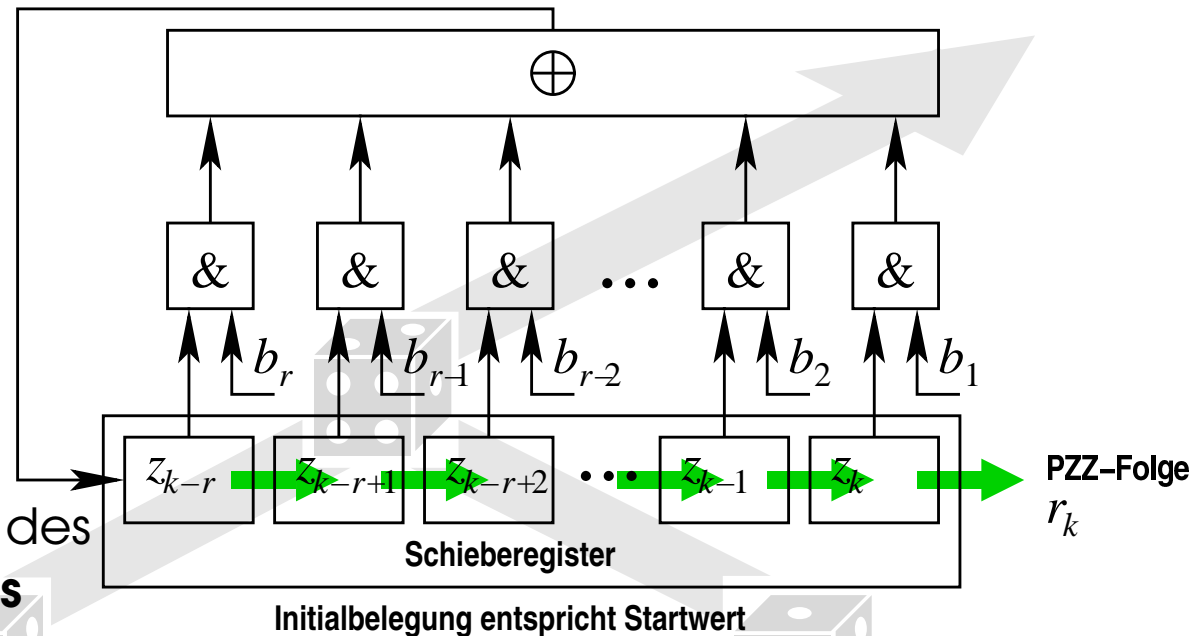
- zum Erreichen der maximalen Periodenlänge $2^r - 1$ muß charakteristisches Polynom **irreduzibel** sein

Vorteile

- leicht in Hardware implementierbar
- sehr schnell, einfache Parameterwahl

Nachteile

- nicht perfekt



Duales linear rückgekoppeltes Schieberegister

Galois-Schieberegister

Prinzip

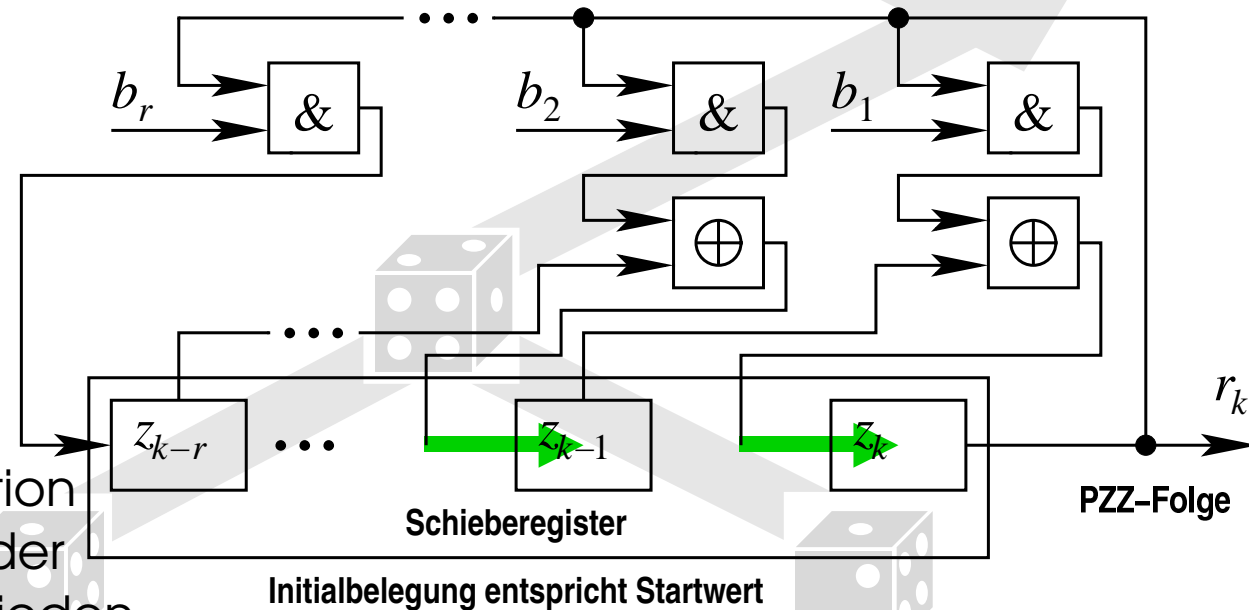
- entspricht dem binären linear rückgekoppelten Schieberegister (SR)
- Einsparung einer \oplus -Operation
- zum Erreichen der maximalen Periodenlänge $2^r - 1$ muß charakteristisches Polynom **irreduzibel** sein
- Transformation duales \leftrightarrow binäres linear rückgek. SR möglich

Vorteile

- leicht in Hardware implementierbar
- sehr schnell, einfache Parameterwahl

Nachteile

- nicht perfekt



Statistische Tests zur Bewertung der Prinzipien

- basieren auf konkreten erzeugten (Pseudo)Zufallszahlenfolgen
- Generatoren selbst nicht herangezogen
- Aufschluß darüber, „**wie gut**“ Unabhängigkeit und Uniformität eingehalten werden
- **Hypothese** (Vorliegen Gleichverteilung, keine Autokorrelation) auf definiertem **Signifikanzniveau** (z.B. 5%, 1% Fehlertoleranz) akzeptiert oder verworfen
- Tests als Algorithmen der mathematischen Statistik notiert und angewendet, z.B.:

χ^2 -Test (u.a. auf Gleichverteilung)

- Standardverfahren der mathematischen Statistik
- für lange (Pseudo)Zufallszahlenfolgen (≥ 50 Zahlen) empfohlen

Kolmogorov-Smirnov-Test (auf Gleichverteilung)

- Standardverfahren der mathematischen Statistik
- i.a. genauer als χ^2 -Test, aber aufwendiger, auch für kurze (Pseudo)Zufallszahlenfolgen

Gap-Test (auf Autokorrelation)

- Überprüfung der Intervallängen bis zum Wiedererscheinen der gleichen Zahl unter
- Anwendung des Kolmogorov-Smirnov-Tests

Poker-Test (auf Autokorrelation)

- analysiert die Häufigkeit, mit der sich die Ziffern in der (Pseudo)ZZ-Folge wiederholen

Mustersuche (auf Autokorrelation)

- graphische Darstellung und Auswertung der (Pseudo)Zufallszahlenfolge
- Gibt es wiederkehrende regelmäßige Muster oder zyklische Variationen?

Zusammenfassung

Resümee

- vorgestellte Prinzipien i.a. seit mehreren Jahrzehnten **bekannt** und
- im praktischen Einsatz **bewährt**
- Prinzipien decken ein **großes Spektrum** nutzbarer und eigenständiger **Strategien** ab
- Repertoire umfaßt Prinzipien, die bevorzugt **hardware-** oder **softwarebasiert** implementiert werden können
- Pseudozufallszahlengeneratoren, die üblicherweise in **Programmiersprachen** oder von **Computer-Algebra-Systemen** bereitgestellt werden, sind vorgestellt worden und spezialisieren sich durch ihre Parameterbelegungen

Ausblick

- weiterführende aufbauende Arbeiten beschäftigen sich u.a. mit der Untersuchung
 - von **Zufallsfunktionen** (Orakeln)
 - von **chaotischen Systemen**

Ausgewählte Literatur

- L. Blum, M. Blum, M. Shub.** *A Simple Unpredictable Pseudo-Random Number Generator.* SIAM J. on Computing **15(2)**:364–383, 1986
- W. Göhler.** *Höhere Mathematik.* Deutscher Verlag für Grundstoffindustrie Leipzig, 1986
- A. Grube.** *Moderne Erzeugung von Zufallszahlen.* S.-Toeche-Mittler-Verlag Darmstadt, 1975
- D. Knuth.** *The Art of Computer Programming.* Vol. 2: Seminumerical Algorithms. Addison-Wesley Ontario, 1998
- N. Schmitz, F. Lehmann.** *Monte-Carlo-Methoden I.* Verlag Anton Hain Meisenheim, 1976
- B. Schneier.** *Applied Cryptography.* John Wiley and Sons Inc. New York, 1994
- R. Zielinski.** *Erzeugung von Zufallszahlen.* Verlag Harri Deutsch Frankfurt/M., 1978