

# Stochastik-Praktikum

## Simulation stochastischer Prozesse

Peter Frentrup

Humboldt-Universität zu Berlin

27. November 2017



# Übersicht

- 1 Random Walk
- 2 Brownsche Bewegung
- 3 Diffusionen und Stochastische DGL

# Vorbemerkungen

Ein stochastischer Prozess  $X = (X_t)_{t \in \mathcal{T}}$  ist eine **indizierte Kollektion von Zufallsgrößen**.

Genauer:  $X : \Omega \times \mathcal{T} \rightarrow (\mathcal{X}, \mathcal{F})$ ,  
 $X(\omega, t) := X_t(\omega)$  messbar  $\forall t \in \mathcal{T}$ .

Sei  $\mathcal{T}$  **geordnet** (Zeit, z.B.  $\mathcal{N}$ ,  $[0, T]$ ).

Für fixiertes  $\omega^* \in \Omega$  heißt  $X(\omega^*, \cdot)$  ein **Pfad** des stochastischen Prozesses  $X$ .

**Filtration**  $(\mathcal{F}_t)_{t \in \mathcal{T}}$ : wachsende Familie von Sub- $\sigma$ -Algebren von  $\mathcal{F}$  auf  $\mathcal{X}$

$(\mathcal{X}, \mathcal{F}, (\mathcal{F}_t)_{t \in \mathcal{T}}, \mathbb{P})$  heißt **filtrierter Wahrscheinlichkeitsraum**.

# Random Walk

## Definition

Es seien  $Z_i$ ,  $i \in \{1, \dots, n\}$ , i.i.d. Zufallsvariablen mit

$$\mathbb{P}[Z_i = 1] = p = 1 - \mathbb{P}[Z_i = -1].$$

Die Zufallsvariable  $S_n := \sum_{i=1}^n Z_i$  beschreibt eine (eindimensionale) Irrfahrt (random walk) in  $\mathbb{Z}$ .

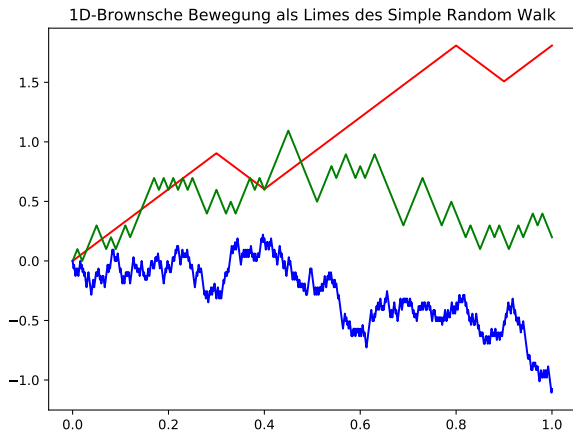
Für  $p = 1/2$  ist dies die so genannte symmetrische Irrfahrt.

$S_n$  nimmt Werte in  $[-n, n]$  an.  $\forall n: \mathbb{E}[S_n] = 0$  und  $\mathbb{V}\text{ar}(S_n) = n$ .

Reskaliert konvergiert die Irrfahrt in Verteilung gegen die Brownsche Bewegung (ZGWS bzw. Donsker):

$$\frac{S_{\lfloor nt \rfloor}}{\sqrt{n}} \xrightarrow{\mathcal{D}} B_t \quad \text{bzw. allgemeiner} \quad \frac{S_{\lfloor n \cdot \rfloor}}{\sqrt{n}} \xrightarrow{\mathcal{D}} B.$$

# Reskalierter symmetrischer Random Walk



# Python: Random Walk

```
def simpleScaledRandomWalk(n, T):  
    """  
    Perform a random walk of 'n' steps on [0, 'T'] with spacial  
    scaling factor 'sqrt(T/n)'.  
    """  
    ts = np.linspace(0, T, n+1)  
    coins = np.random.uniform(size=n+1)  
    dxs = (2.0 * (coins > 0.5) - 1) * np.sqrt(float(T) / n)  
    dxs[0] = 0.0  
    xs = np.cumsum(dxs)  
    return ts, xs  
  
ts, xs = simpleScaledRandomWalk(10, 1)  
plt.plot(ts, xs, 'r-')
```

# Übersicht

1 Random Walk

2 Brownsche Bewegung

3 Diffusionen und Stochastische DGL

# Brownsche Bewegung

## Definition

Sei  $(\mathcal{F}_t)$  eine Filtration. Ein  $(\mathcal{F}_t)$ -adaptierter stochastischer Prozess  $(B_t)_{t \geq 0}$  auf  $(\Omega, \mathcal{F}, (\mathcal{F}_t), \mathbb{P})$  heißt (Standard-)brownsche Bewegung (oder Wiener-Prozess) bzgl.  $(\mathcal{F}_t)$ , falls gilt:

(BB1)  $B_0 = 0$   $\mathbb{P}$ -f.s.,

(BB2) Für alle  $t \geq s$  ist  $(B_t - B_s)$  unabhängig von  $\mathcal{F}_s$ ,

(BB3) Zuwächse  $(B_t - B_s)$ ,  $0 \leq s \leq t$ , sind  $\mathcal{N}(0, t - s)$ -verteilt,

(BB4)  $(B_t)_{t \geq 0}$  hat  $\mathbb{P}$ -f.s. stetige Pfade.

Oft ist z.B.  $\mathcal{F}_t := \sigma(B_u : u \leq t)$ .



## Satz

Ist  $B = (B_t)_{t \geq 0}$  eine brownische Bewegung, so auch jeder der folgenden Prozesse:

- (i)  $B^1 := -B$  (Spiegelungsprinzip)
- (ii) Für festes  $s \geq 0$ :  $B_t^2 := B_{s+t} - B_s, \quad t \geq 0$  (Zeithomogenität)
- (iii) Für festes  $c > 0$ :  $B_t^3 := c^{-1} B_{c^2 t}, \quad t \geq 0$  (Skalierung)
- (iv) Für festes  $T > 0$ :  $B_t^4 := B_T - B_{T-t}, \quad 0 \leq t \leq T$  (Zeitinversion)
- (v)  $B_t^5 := \begin{cases} tB_{1/t}, & t > 0, \\ 0, & t = 0. \end{cases}$  (Inversion)

## Satz

Ist  $B = (B_t)_{t \geq 0}$  eine brownische Bewegung, so auch jeder der folgenden Prozesse:

- (i)  $B^1 := -B$  (Spiegelungsprinzip)
- (ii) Für festes  $s \geq 0$ :  $B_t^2 := B_{s+t} - B_s, \quad t \geq 0$  (Zeithomogenität)
- (iii) Für festes  $c > 0$ :  $B_t^3 := c^{-1} B_{c^2 t}, \quad t \geq 0$  (Skalierung)
- (iv) Für festes  $T > 0$ :  $B_t^4 := B_T - B_{T-t}, \quad 0 \leq t \leq T$  (Zeitinversion)
- (v)  $B_t^5 := \begin{cases} tB_{1/t}, & t > 0, \\ 0, & t = 0. \end{cases}$  (Inversion)

## Satz

Ist  $B = (B_t)_{t \geq 0}$  eine brownische Bewegung, so auch jeder der folgenden Prozesse:

- (i)  $B^1 := -B$  (Spiegelungsprinzip)
- (ii) Für festes  $s \geq 0$ :  $B_t^2 := B_{s+t} - B_s, \quad t \geq 0$  (Zeithomogenität)
- (iii) Für festes  $c > 0$ :  $B_t^3 := c^{-1} B_{c^2 t}, \quad t \geq 0$  (Skalierung)
- (iv) Für festes  $T > 0$ :  $B_t^4 := B_T - B_{T-t}, \quad 0 \leq t \leq T$  (Zeitinversion)
- (v)  $B_t^5 := \begin{cases} tB_{1/t}, & t > 0, \\ 0, & t = 0. \end{cases}$  (Inversion)

## Satz

Ist  $B = (B_t)_{t \geq 0}$  eine brownische Bewegung, so auch jeder der folgenden Prozesse:

- (i)  $B^1 := -B$  (Spiegelungsprinzip)
- (ii) Für festes  $s \geq 0$ :  $B_t^2 := B_{s+t} - B_s, \quad t \geq 0$  (Zeithomogenität)
- (iii) Für festes  $c > 0$ :  $B_t^3 := c^{-1} B_{c^2 t}, \quad t \geq 0$  (Skalierung)
- (iv) Für festes  $T > 0$ :  $B_t^4 := B_T - B_{T-t}, \quad 0 \leq t \leq T$  (Zeitinversion)
- (v)  $B_t^5 := \begin{cases} tB_{1/t}, & t > 0, \\ 0, & t = 0. \end{cases}$  (Inversion)

## Satz

Ist  $B = (B_t)_{t \geq 0}$  eine brownische Bewegung, so auch jeder der folgenden Prozesse:

- (i)  $B^1 := -B$  (Spiegelungsprinzip)
- (ii) Für festes  $s \geq 0$ :  $B_t^2 := B_{s+t} - B_s, \quad t \geq 0$  (Zeithomogenität)
- (iii) Für festes  $c > 0$ :  $B_t^3 := c^{-1} B_{c^2 t}, \quad t \geq 0$  (Skalierung)
- (iv) Für festes  $T > 0$ :  $B_t^4 := B_T - B_{T-t}, \quad 0 \leq t \leq T$  (Zeitinversion)
- (v)  $B_t^5 := \begin{cases} tB_{1/t}, & t > 0, \\ 0, & t = 0. \end{cases}$  (Inversion)

# Markov-Eigenschaft und Simulation

## Korollar

*Aus den Eigenschaften der brownischen Bewegung und dem vorangehenden Satz folgt die Markov-Eigenschaft:*

$$\tilde{B}_t := B_{t+s} - B_s, \quad t \geq 0$$


*ist eine brownische Bewegung und unabhängig von  $\mathcal{F}_s$ . Die bedingte (reguläre) Verteilung von  $B_{t+s}$  gegeben  $\mathcal{F}_s$  ist also die Normalverteilung  $\mathcal{N}(B_s, t)$  und hängt nur von  $B_s$  und  $t$  ab.*

Exakte zeitdiskrete Simulation als gaußscher Random Walk!

# Python: Brownsche Bewegung auf Zeitgitter

```
def standardBrownianMotion(n, T):  
    """  
    Simulate a 1D standard Brownian motion on [0, 'T'] with 'n'  
    Brownian increments.  
    """  
    ts = np.linspace(0, T, n+1)  
    dxs = np.random.normal(  
        loc=0, scale=np.sqrt(float(T) / n), size=(n+1))  
    dxs[0] = 0.0  
    xs = np.cumsum(dxs)  
    return ts, xs  
  
ts = np.linspace(0, 1, 100)  
xs = np.sqrt(ts)  
plt.plot(ts, xs, 'r-', ts, -xs, 'r-')  
for i in range(0, 100):  
    ts, Bs = standardBrownianMotion(1000, 1)  
    plt.plot(ts, Bs, linewidth=0.1)
```

## 100 brownsche Bewegungen





# Weitere Eigenschaften der brownischen Bewegung

## Satz

Es sei  $B = (B_t)_{t \geq 0}$  eine brownische Bewegung. Dann gilt:

- 1 Die Pfade von  $B$  sind fast sicher nirgends differenzierbar.
- 2 Die Pfade von  $B$  sind auf jedem Intervall fast sicher von unbeschränkter Variation.
- 3 Das Wachstumsverhalten lässt sich durch das Gesetz vom iterierten Logarithmus beschreiben:

$$\limsup_{t \rightarrow \infty} \frac{B_t(\omega)}{\sqrt{2t \log(\log(t))}} = 1 \quad \text{für } \mathbb{P} - \text{fast alle } \omega \in \Omega.$$

- 4 Eine brownische Bewegung ist stetiger zentrierter Gauß-Prozess mit  $\text{Cov}(B_s, B_t) = s \wedge t \quad \forall s, t \geq 0$  (g.d.w.).

# Fast-sichere-Konvergenz: Lévy-Konstruktion der B.B.

Konstruktion mit pfadweise f.s.-Konvergenz (statt Verteilungskonvergenz wie bei Donsker):

Sei  $n \in \mathbb{N}_0$ ,  $D_n := \{k/2^n : k \in \mathbb{N}, 0 \leq k \leq 2^n\}$  und  $D := \bigcup_{n=1}^{\infty} D_n$ .

$(Z_t)_{t \in D}$  seien unabh. standardnormalverteilte Zufallsvariablen.

Funktionenfolge  $F_n : [0, 1] \rightarrow \mathbb{R}$  definiert durch  $F_0(t) := tZ_1$  und

$$F_n(t) := \begin{cases} \frac{Z_t}{\sqrt{2^{n+1}}}, & t \in D_n \setminus D_{n-1}, \\ 0, & t \in D_{n-1}, \\ \text{linear interpoliert,} & \text{sonst.} \end{cases}$$

Dann ist  $B_t := \text{f.s.-}\lim_N \sum_0^N F_n(t)$  eine brownische Bewegung auf  $[0, 1]$ .

## Fast-sichere-Konvergenz: Lévy-Konstruktion der B.B.

Dann ist  $B_t := \text{f.s.-}\lim_N \sum_0^N F_n(t)$  eine brownische Bewegung auf  $[0, 1]$ .

Dabei ist  $B_0 = 0$ ,  $B_1 = Z_1$  und  $B_t = \frac{B_t^- + B_t^+}{2} + \frac{Z_t}{\sqrt{2^{n+1}}}$ , wobei  $B_t^+$  den rechten und  $B_t^-$  den linken Nachbarpunkt nach einer Intervallhalbierung bezeichnen.

Konkret gilt z.B. für die ersten Schritte

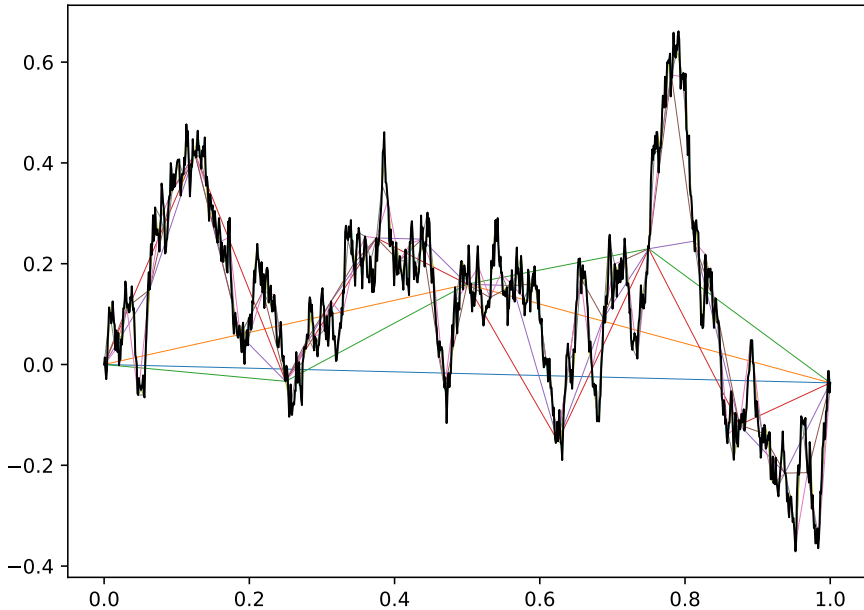
$$B_{1/2} = \frac{B_0 + B_1}{2} + \frac{Z_{1/2}}{2},$$

$$B_{1/4} = \frac{B_0 + B_{1/2}}{2} + \frac{Z_{1/4}}{\sqrt{8}} \quad \text{und} \quad B_{3/4} = \frac{B_{1/2} + B_1}{2} + \frac{Z_{3/4}}{\sqrt{8}}$$

...

Der entstehende Prozess hat zu jeder Zeit  $t$  die Varianz  $t$ .

# Lévy-Konstruktion der brownischen Bewegung



# Zweidimensionale Brownschen Bewegung


## Definition

Ein stochastischer Prozess  $(\mathbf{B}_t)_{t \geq 0}$  mit Werten im  $\mathbb{R}^d$  heißt  $d$ -dimensionale brownische Bewegung, falls die Koordinaten  $(B_i)_t$ ,  $i \in \{1, \dots, d\}$ , stochastisch unabhängige eindimensionale brownische Bewegungen sind.

```
def standardBrownianMotion2D(n, T):  
    dBxy = np.random.normal(  
        loc=0, scale=np.sqrt(float(T) / n), size=(n+1, 2))  
    dBxy[0, :] = 0.0  
    return dBxy.cumsum(axis=0)
```

```
Bxy = standardBrownianMotion2D(1000, T=1.0)  
plt.plot(Bxy[:, 0], Bxy[:, 1])
```

## 2D brownsche Bewegung



# Übersicht

- 1 Random Walk
- 2 Brownsche Bewegung
- 3 Diffusionen und Stochastische DGL**

# Diffusionen

Unter einem Diffusionsprozess versteht man z.B. einen Prozess der Form

$$X_t = X_0 + \mu t + \sigma B_t, \quad t \geq 0,$$

mit einer brownischen Bewegung  $B$ .

Ein  $X_t$  wie oben wird teils als „allgemeine Brownsche Bewegung“ mit Drift  $\mu$  und Volatilität  $\sigma$  bezeichnet.

Allgemeiner erfüllt ein Diffusion eine **stochastische DGL**

$$dX_t = \mu dt + \sigma dB_t$$


mit Koeffizienten  $\mu, \sigma$ , die Funktionen von  $(t, X_t)$  sein dürfen (oben: Konstanten).




# Python: Diffusion

```
def diffusion(x0, n, T, mu, sigma):  
    """  
    Simulate  $dX_t = \mu dt + \sigma dB_t$  on  $[0, T]$  with  $X_0 = x0$ ,  
    using  $n$  increments.  
    Return  $(ts, Xs)$ , time and space coordinates.  
    """  
    dt = T/n  
    ts = np.linspace(0, T, n+1)  
    dXs = mu * dt + sigma * np.random.normal(  
        loc=0, scale=np.sqrt(dt), size=n+1)  
    dXs[0] = x0  
    Xs = np.cumsum(dXs)  
    return ts, Xs  
  
ts, Xs = diffusion(0, 10000, 5, -1, 0.5)  
plt.plot(ts, Xs)
```

# Diffusion



## Diffusionen mit Konfidenzbändern bei $\pm 1\text{STD}$



# SDGL Approximation: Das Eulerschema

Was eine Lösung  $(X_t)$  einer **stochastischen DGL** der Form

$$X_0 = x_0, \quad dX_t = \mu(t, X_t) dt + \sigma(t, X_t) dB_t$$

genau ist, wird erst durch die VL Stochastische Analysis geklärt!

# SDGL Approximation: Das Eulerschema

## stochastischen DGL

$$X_0 = x_0, \quad dX_t = \mu(t, X_t) dt + \sigma(t, X_t) dB_t$$

Das **Eulerschema** ist intuitiv plausibel als numerische SDGL-Approximation  $\tilde{X}_t$  entlang eines diskreten Zeitgitters  $t_k = k/n$  mit  $\Delta t := 1/n$  und  $\Delta B_{t_k} := B_{t_k} - B_{t_{k-1}}$ :

$$\tilde{X}_0 := x_0, \quad \tilde{X}_{t_k} = \tilde{X}_{t_{k-1}} + \mu(t, \tilde{X}_{t_{k-1}}) \Delta t + \sigma(t, \tilde{X}_{t_{k-1}}) \Delta B_{t_k},$$

wobei die  $\Delta B_{t_k} = B_{t_k} - B_{t_{k-1}}$  als i.i.d.  $\mathcal{N}(0, \Delta t)$ -verteilte Zufallsvariablen simuliert werden.

## Beispiel zum Eulerschema

Die Stochastische Analysis wird zeigen, dass die SDGL

$$X_0 = 1, \quad dX_t = X_t a dB_t$$

mit  $a \in \mathbb{R}$  als Lösung die geometrische brownische Bewegung

$$X_t = \exp(aB_t - a^2 t/2)$$

hat, das sogenannte „Stochastische Exponential von  $aB_t$ “.

Das Eulerschema liefert als zeitdiskrete Approximation hierfür

$$\tilde{X}_0 = 1, \quad \tilde{X}_{t_k} := \tilde{X}_{t_{k-1}} + \tilde{X}_{t_{k-1}} a \Delta B_{t_k}$$