

Vorlesung 8a

Der zentrale Grenzwertsatz

und

Mittelwerte

1. Auftakt

1. Auftakt

Letztesmal hatten wir gesehen:

Die Summe von
unabhängigen, normalverteilten Zufallsvariablen
ist wieder normalverteilt.

Insbesondere ergibt sich:

Die standardisierte Summe von unabhängigen,
identisch normalverteilten Zufallsvariablen
ist standard-normalverteilt

Mit anderen Worten: Sind N_1, N_2, \dots, N_n
unabhängig und $N(\mu, \sigma^2)$ -verteilt, dann ist

$$\frac{N_1 + \dots + N_n - n\mu}{\sqrt{n\sigma^2}} \quad \text{standard-normalverteilt.}$$

2. Der Zentrale Grenzwertsatz: Die Botschaft

Der Zentrale Grenzwertsatz liefert
eine gewaltige Weiterung der vorigen Aussage
(asymptotisch für große n):

Zentraler Grenzwertsatz:

“Die standardisierte Summe von **VIELEN**
unabhängigen, identisch verteilten
nicht notwendig normalverteilten
 \mathbb{R} -wertigen Zufallsvariablen
mit endlicher Varianz
ist annähernd standard-normalverteilt”

Formal:

Seien X_1, X_2, \dots unabhängige und identisch verteilte Zufallsvariable mit endlichem Erwartungswert μ und endlicher Varianz $\sigma^2 > 0$. Dann gilt für alle $c < d \in \mathbb{R}$

$$\mathbf{P}\left(\frac{X_1 + \dots + X_n - n\mu}{\sqrt{n\sigma^2}} \in [c, d]\right) \xrightarrow{n \rightarrow \infty} \mathbf{P}(Z \in [c, d]).$$

Dabei ist Z standard-normalverteilt.

In Worten:

Die standardisierte Summe von n unabhängigen,
identisch verteilten \mathbb{R} -wertigen Zufallsvariablen
mit endlicher Varianz
konvergiert für $n \rightarrow \infty$ in Verteilung
gegen eine standard-normalverteilte Zufallsvariable.

3. Zentraler Grenzwertsatz: Meilensteine in seiner Geschichte

Abraham de Moivre:

Der faire Münzwurf (1733)

Pierre-Simon Laplace:

Allgemeine binomiale Zufallsgrößen (1812)

Pafnuty Lvovich Chebyshev:

Skizze eines Beweises für den allgemeinen Fall (1887)

Aleksandr Mikhailovich Lyapunov:

Noch allgemeiner (1906)

Allgemeiner zentraler Grenzwertsatz (1901)

Andrei Andreyevich Markov:

weitere Verallgemeinerungen (~ 1910)

Nehmen wir an,
diese Herren hätten sich
auf ihre vielen anderen Interessen
beschränkt.

ZENTRALER GRENZWERTSATZ

Nehmen wir an,
diese Herren hätten sich
auf ihre vielen anderen Interessen
beschränkt.

ZENTRALER GRENZWERTSATZ

Unbekannt.

Könnten wir ihn entdecken?

Wie kämen wir auf φ ?

Warum gerade $e^{-x^2/2}$?

4. Ein Beispiel: Summen von unabhängigen uniform verteilten Zufallsvariablen

Wir denken an

Rundungsfehler bei Addition

In Wirklichkeit

$$\pi =$$

3.141592653589793238462643383279502884197169399375105...

Im Rechner

$$\pi \leftarrow 3.14159265358979$$

MODELL

Zahl = Rechnerdarstellung + Rundungsfehler.

$$A = a^{[R]} + \varepsilon X \quad \varepsilon = 10^{-15}$$

Annahme: X uniform verteilt auf $[-0.5, 0.5]$.

$$\sum_{i=1}^n A_i = ?$$

$$\sum_{i=1}^n A_i = \sum_{i=1}^n a_i^{[R]} + \varepsilon \sum_{i=1}^n X_i$$

Wie groß ist der Fehler?

$$\sum_{i=1}^n X_i \approx ?$$

Ein Beispiel:

X_1, X_2, \dots unabhängig
und uniform auf $[-0.5, 0.5]$ verteilt

Empirische Verteilung von

$$S_n := X_1 + \dots + X_n$$

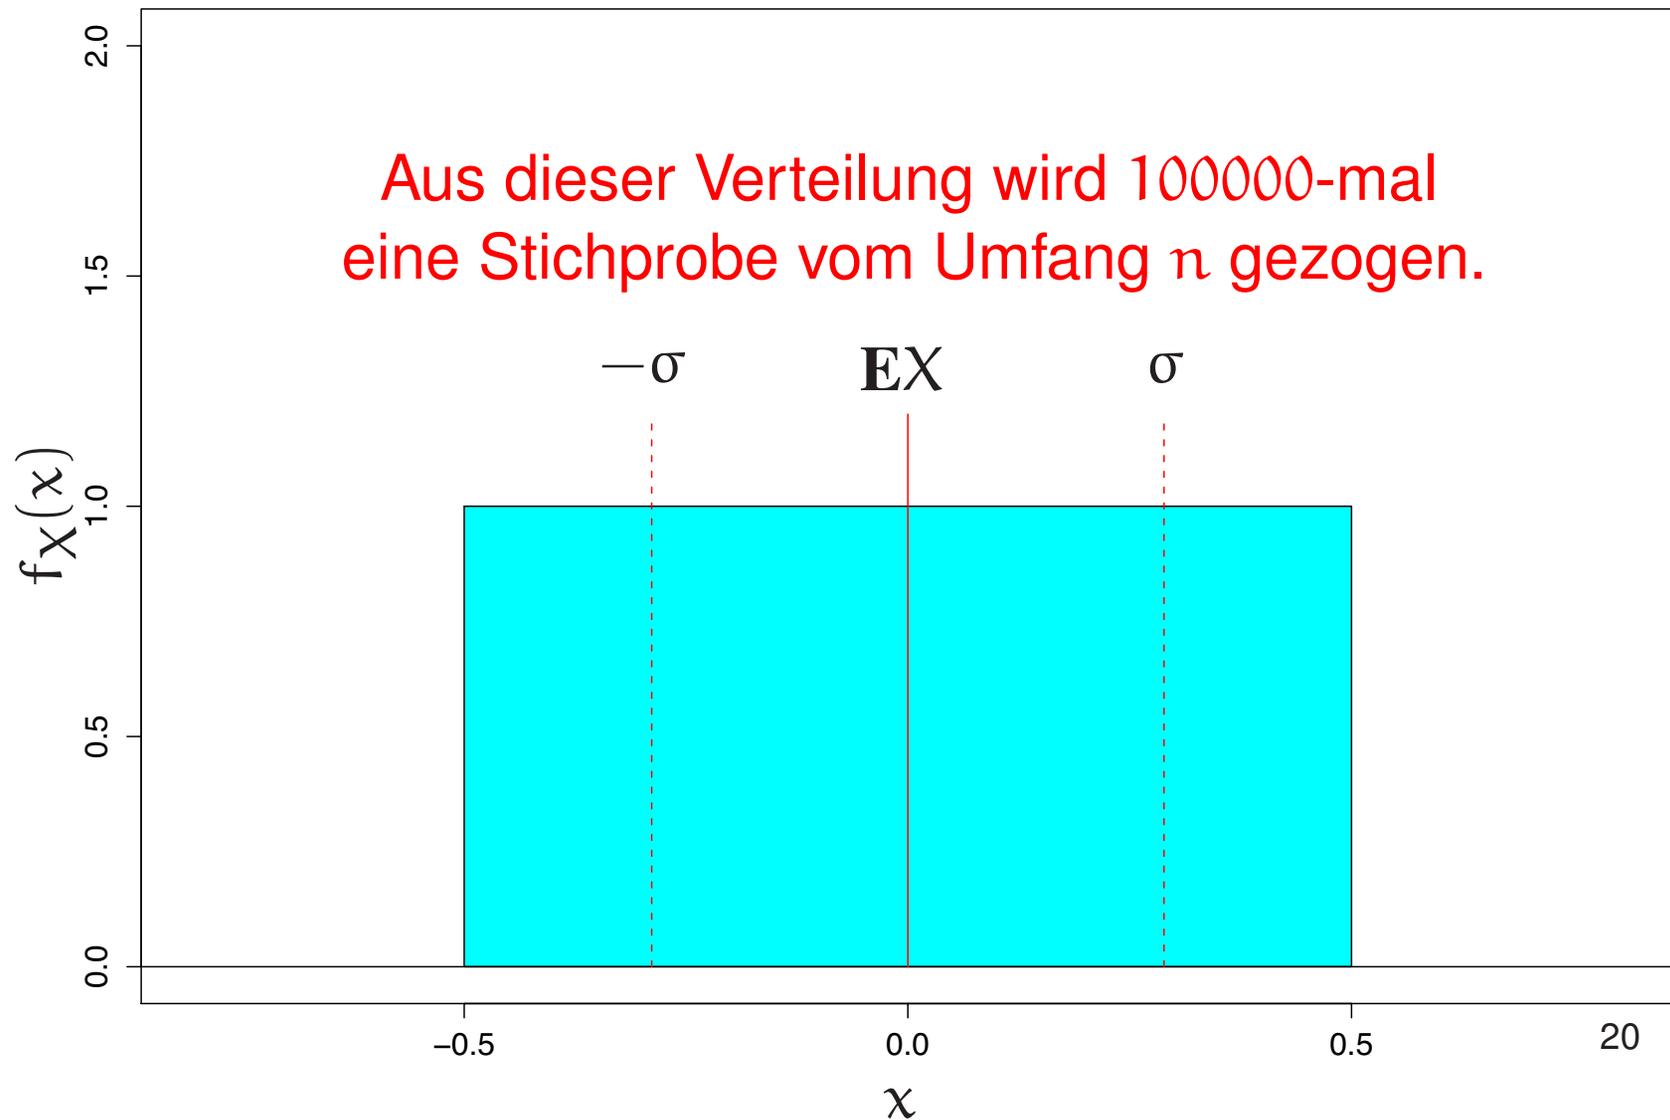
100000 Simulationen

jeweils für

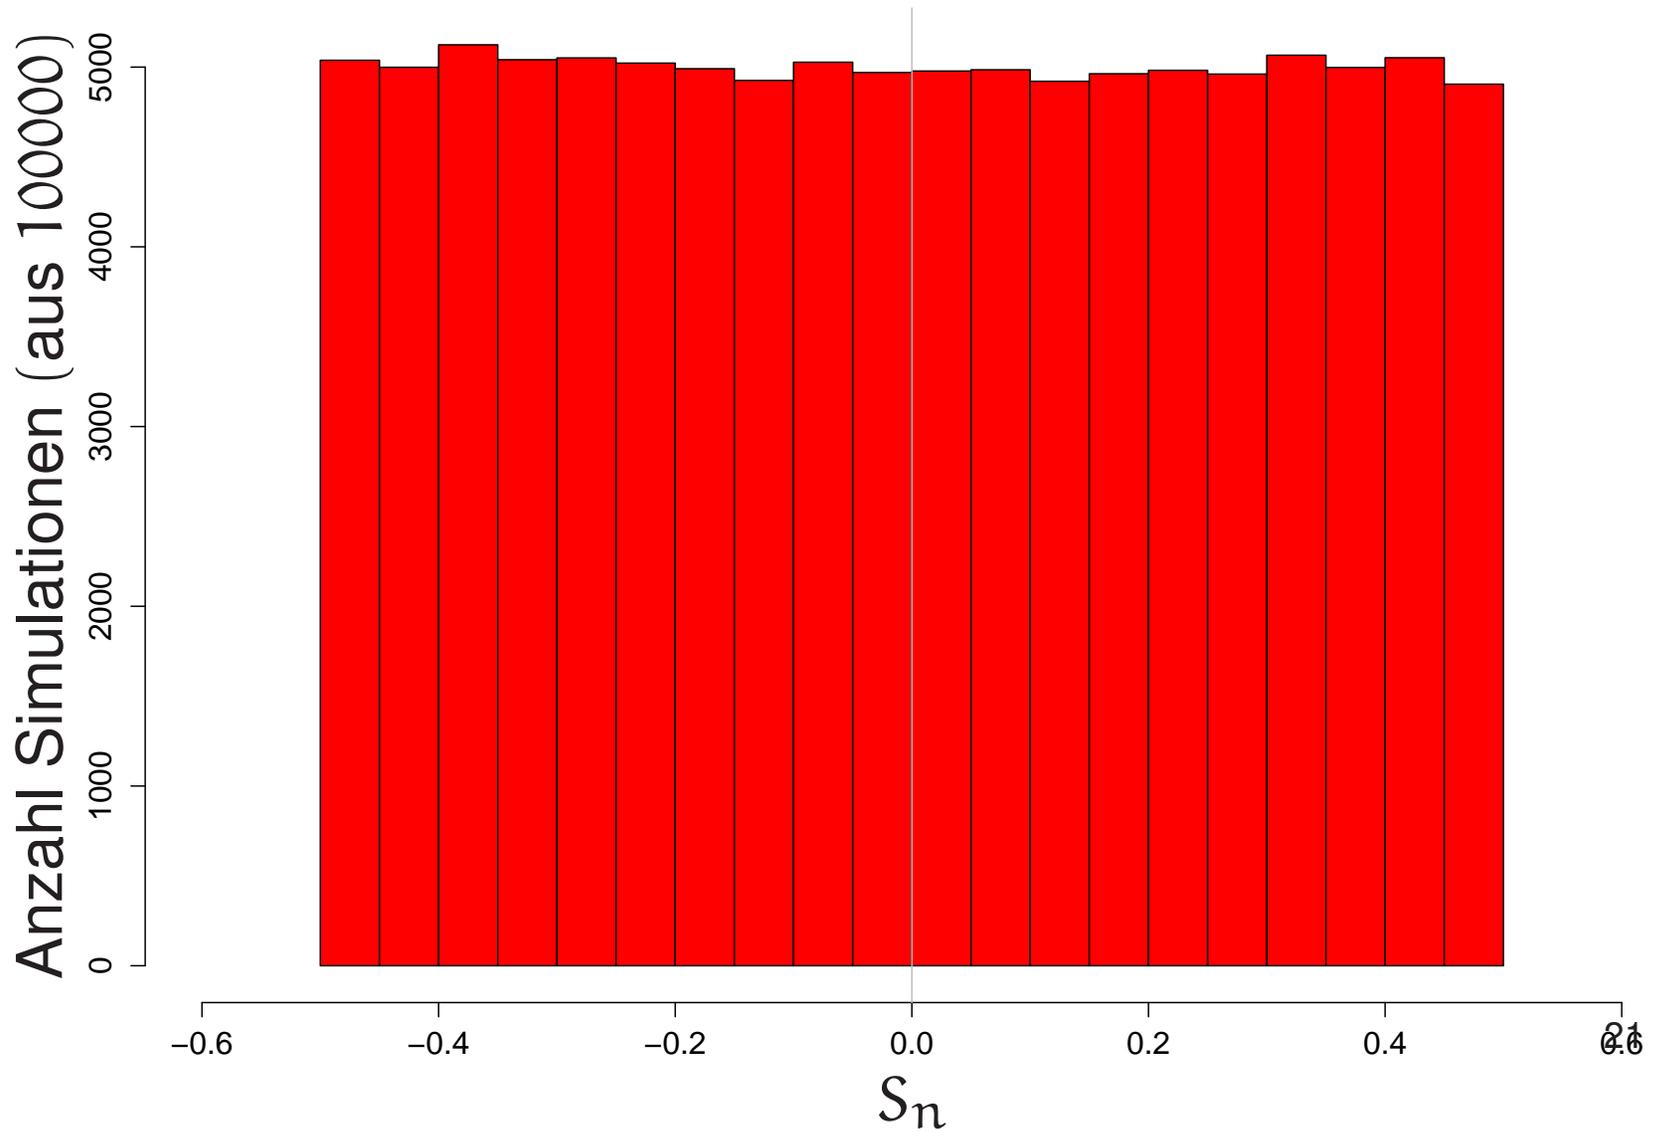
$$n = 1, 2, \dots, 10$$

$$n = 15, 20, \dots, 100$$

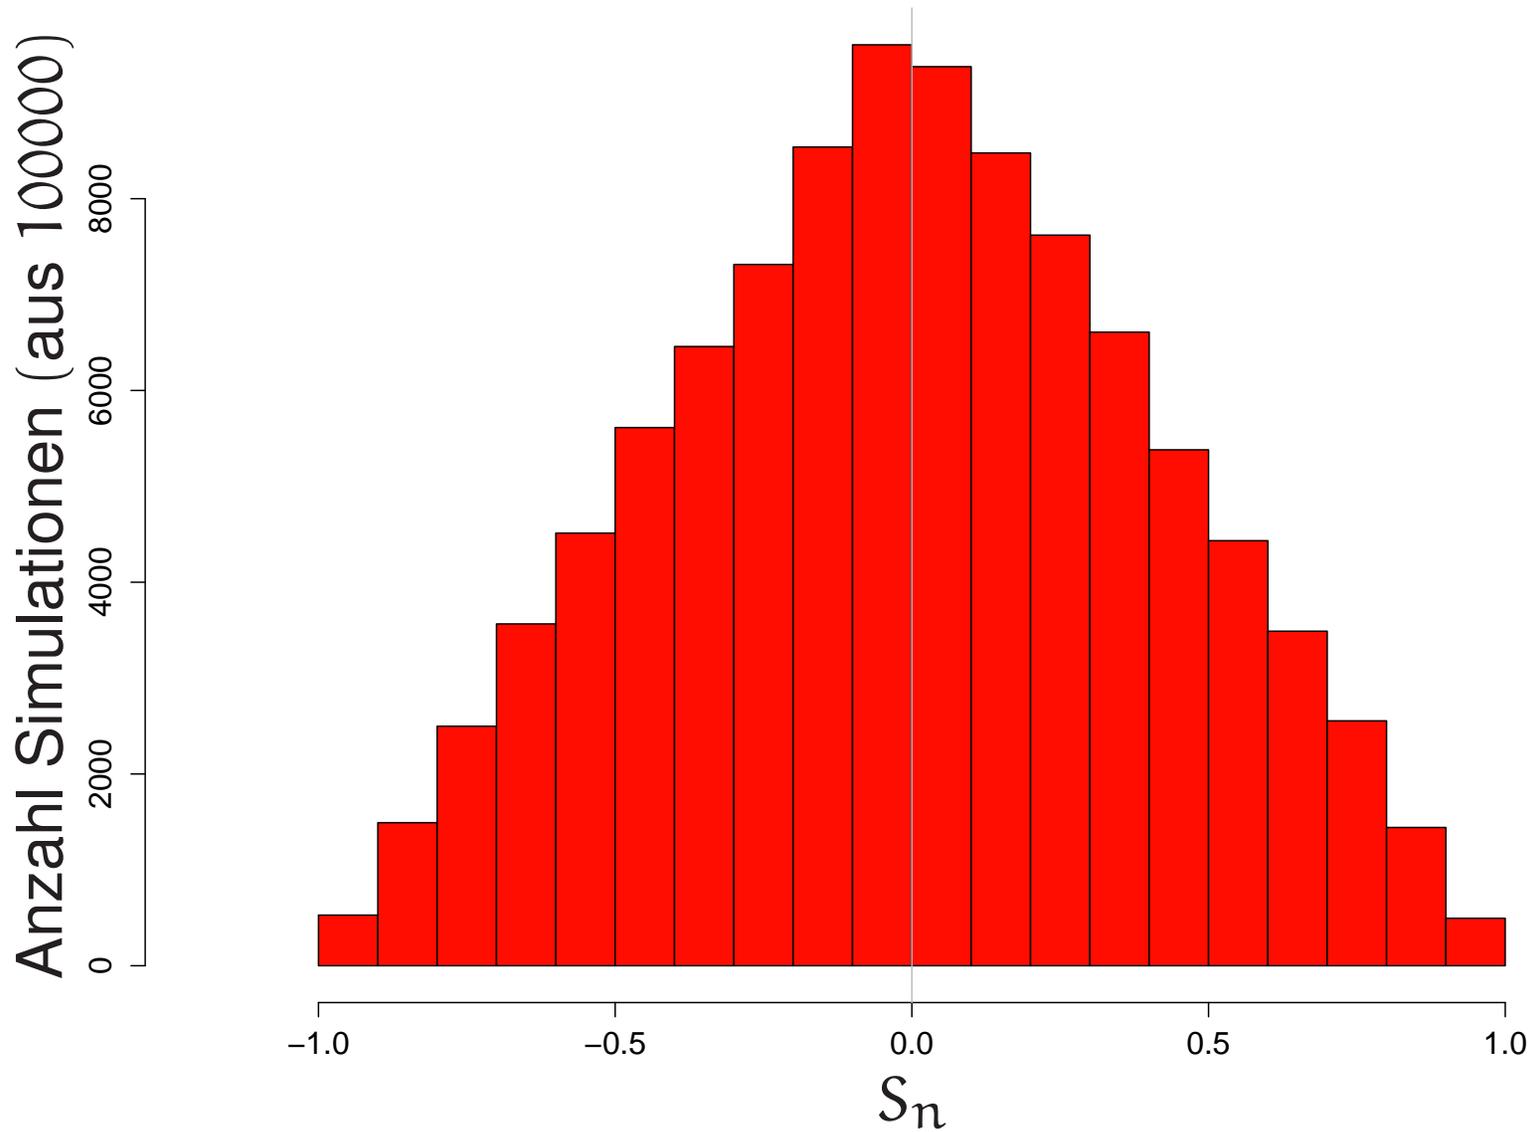
Dichtefunktion f_X der Verteilung von X



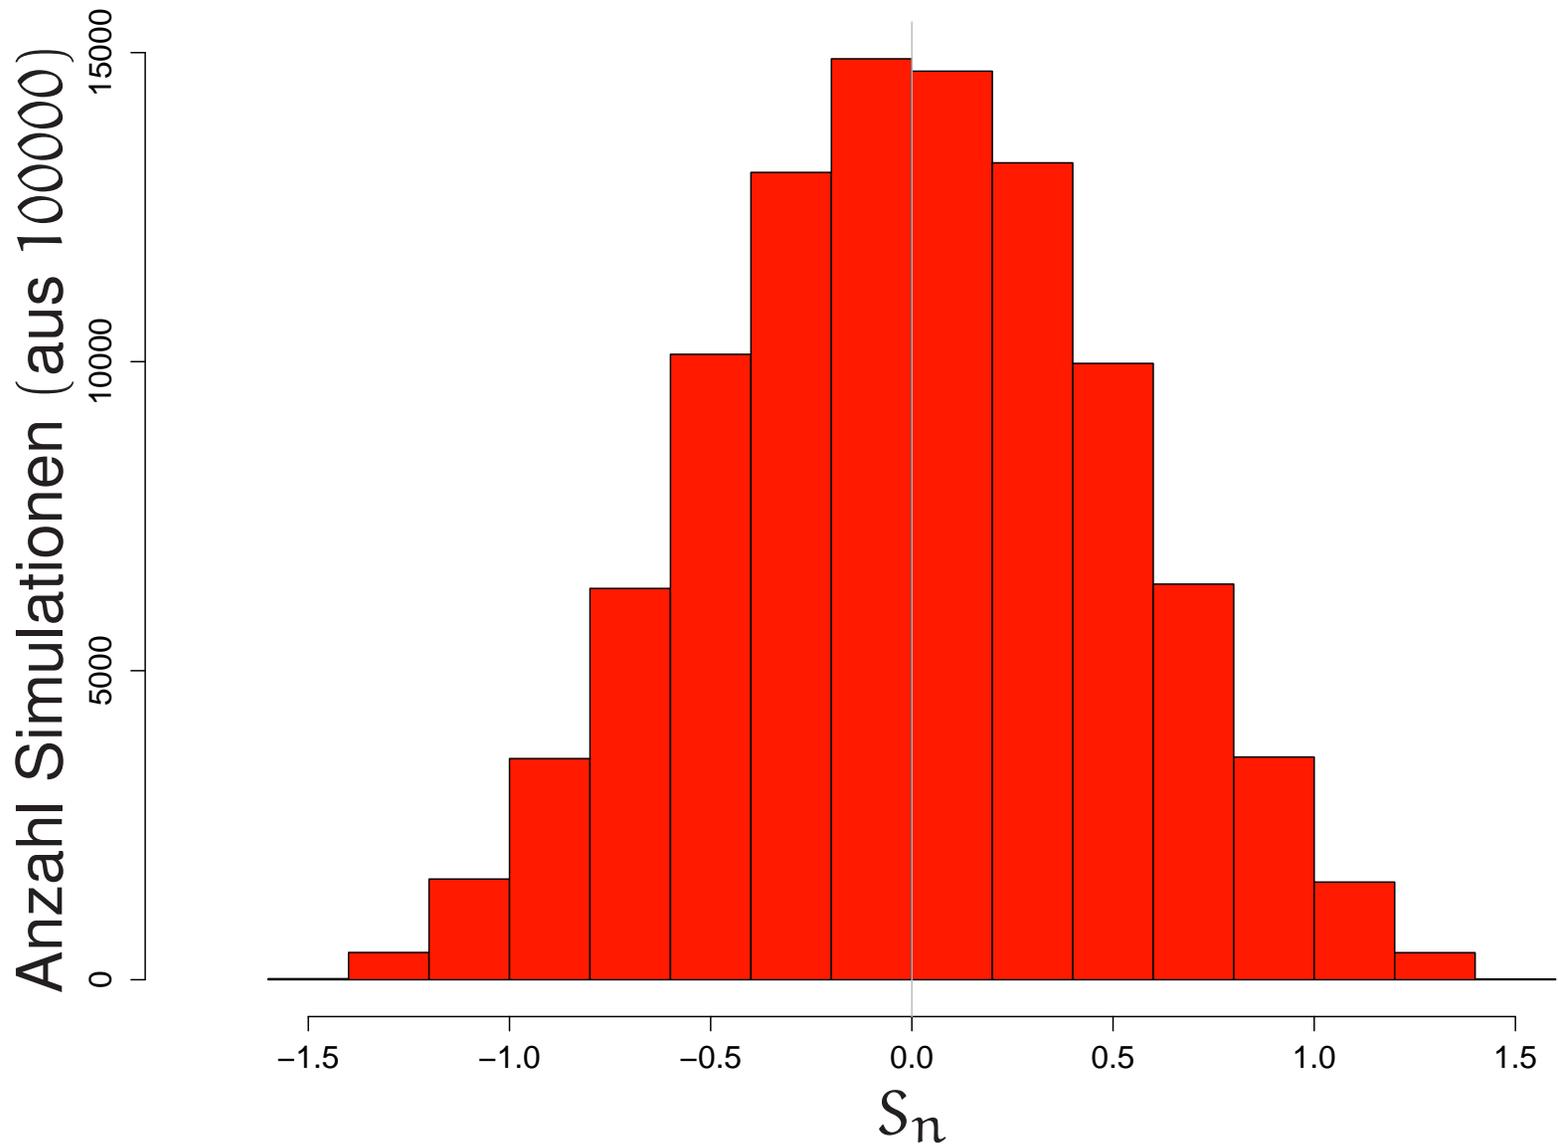
Verteilung von $S_1 = X_1$ ($n = 1$)



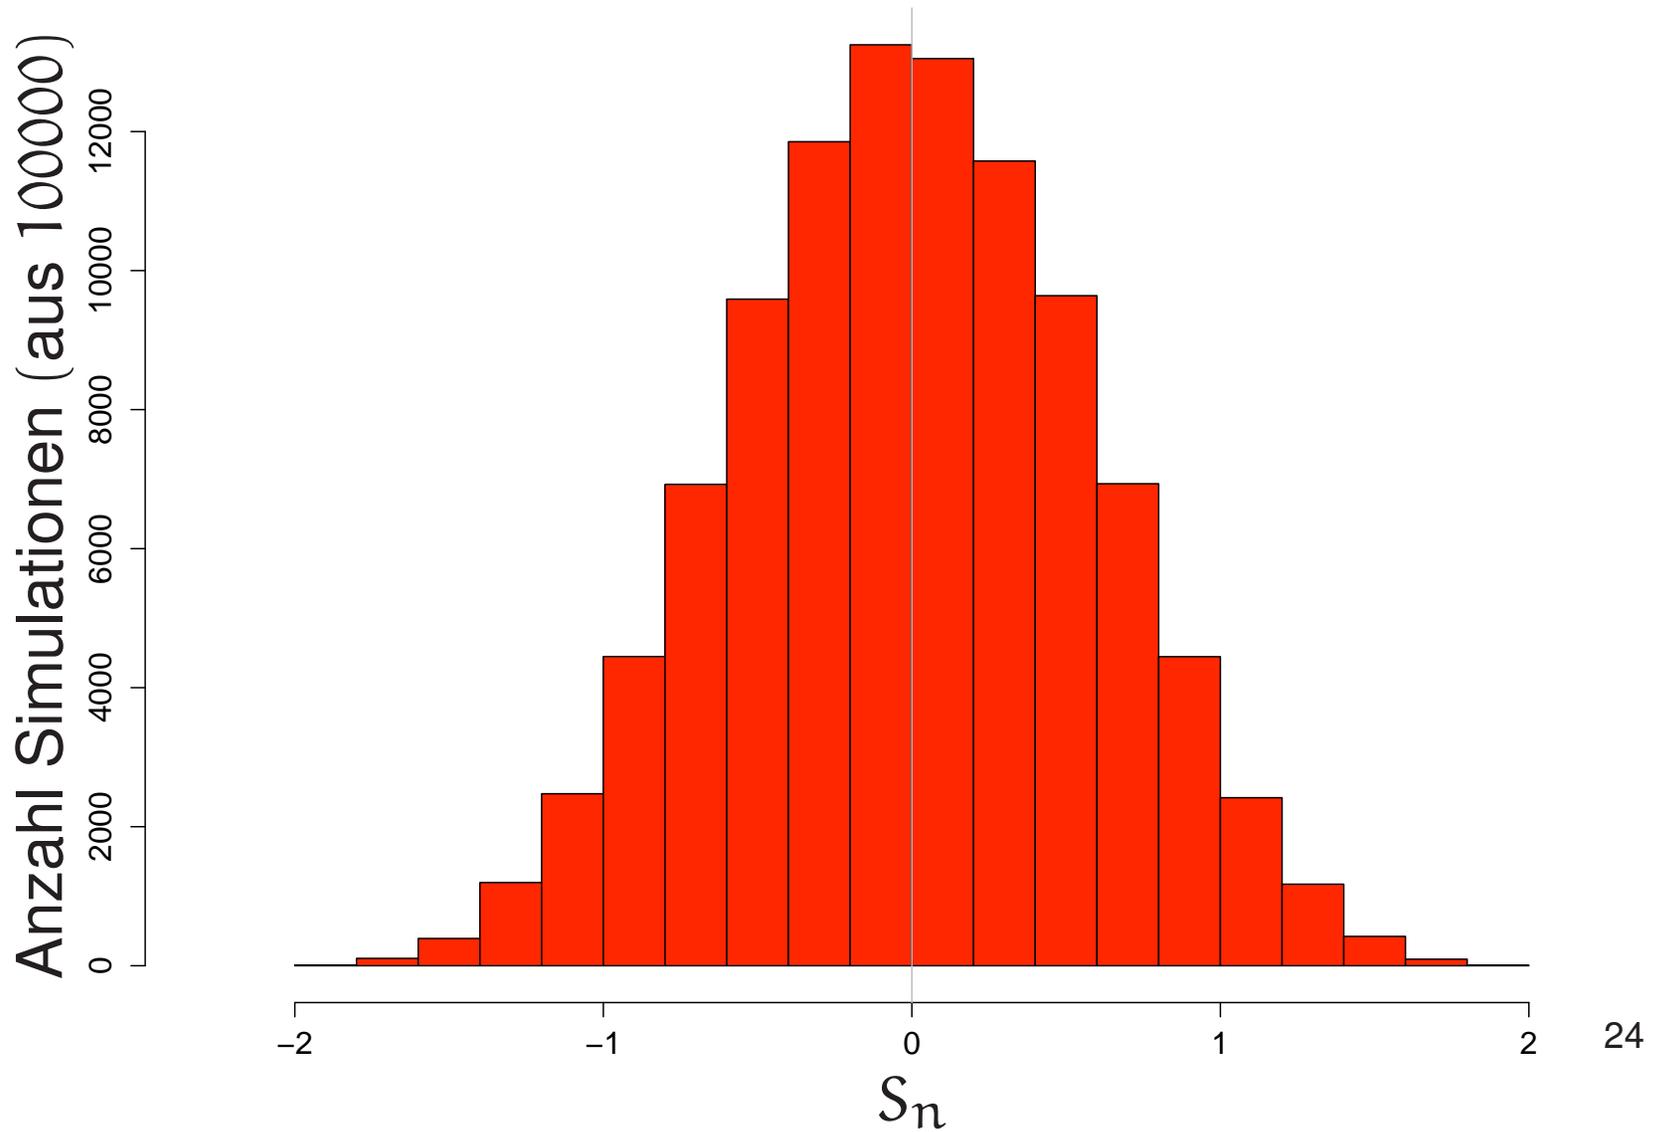
Verteilung von $S_n = X_1 + \dots + X_n$ ($n = 2$)



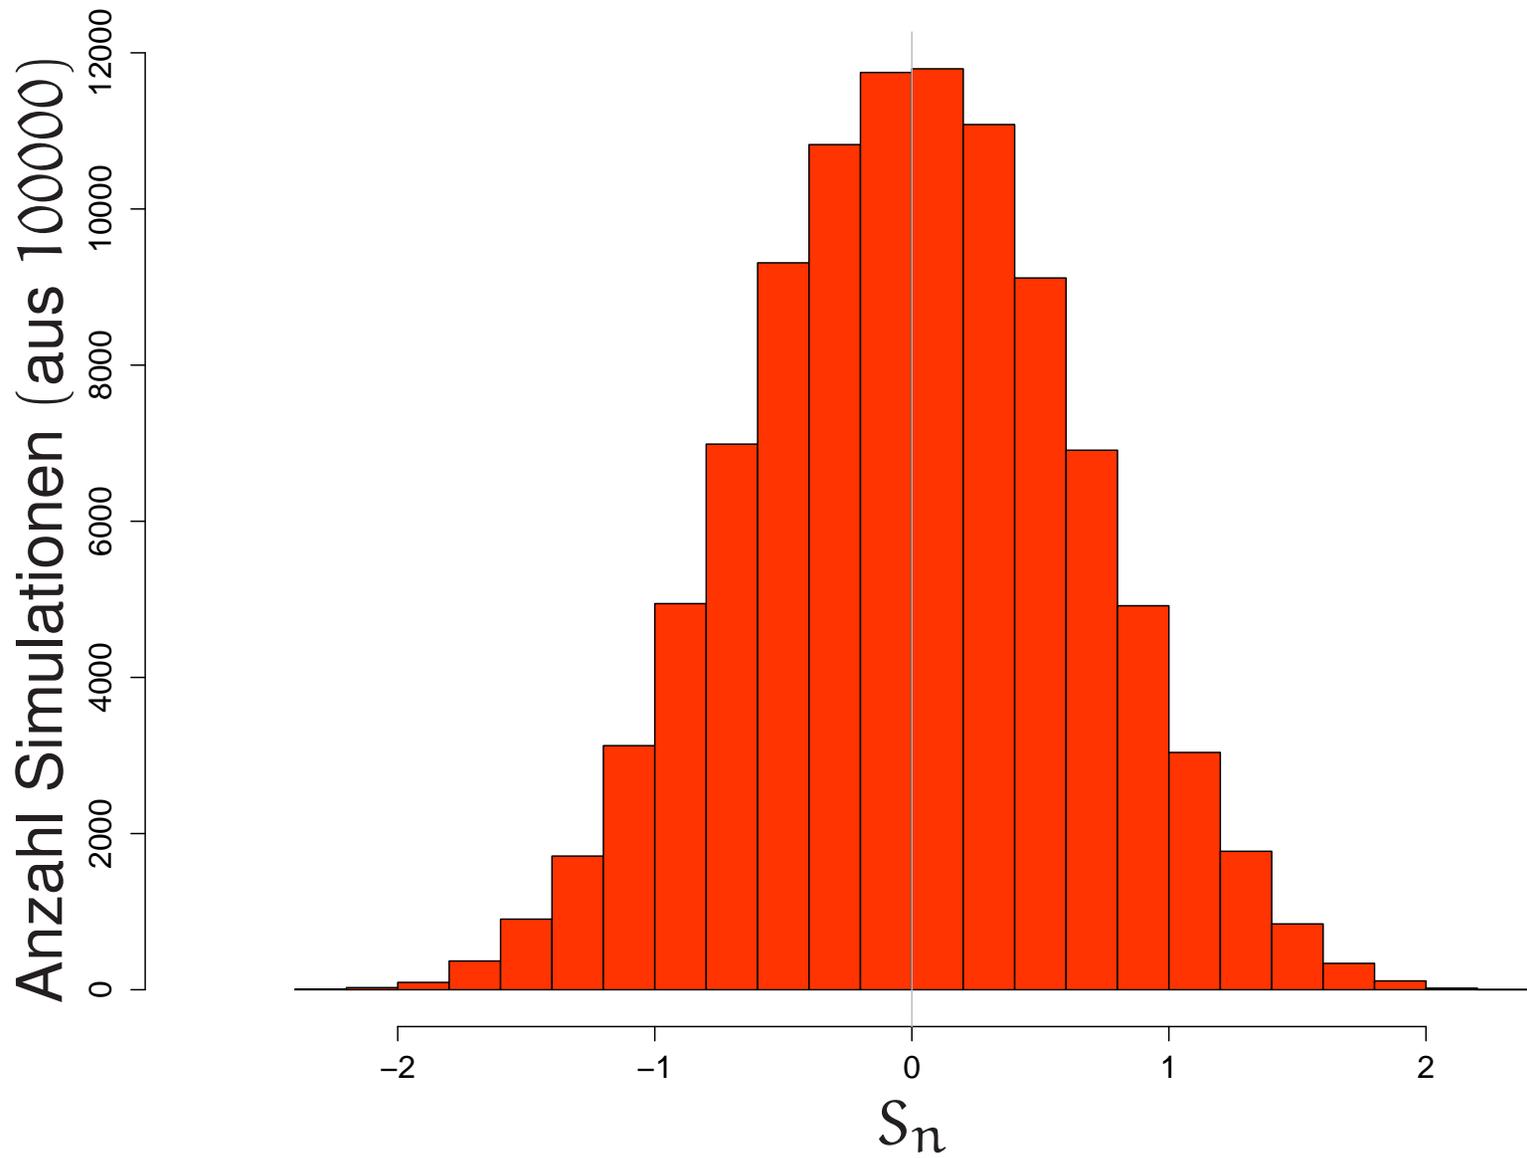
Verteilung von S_n ($n = 3$)



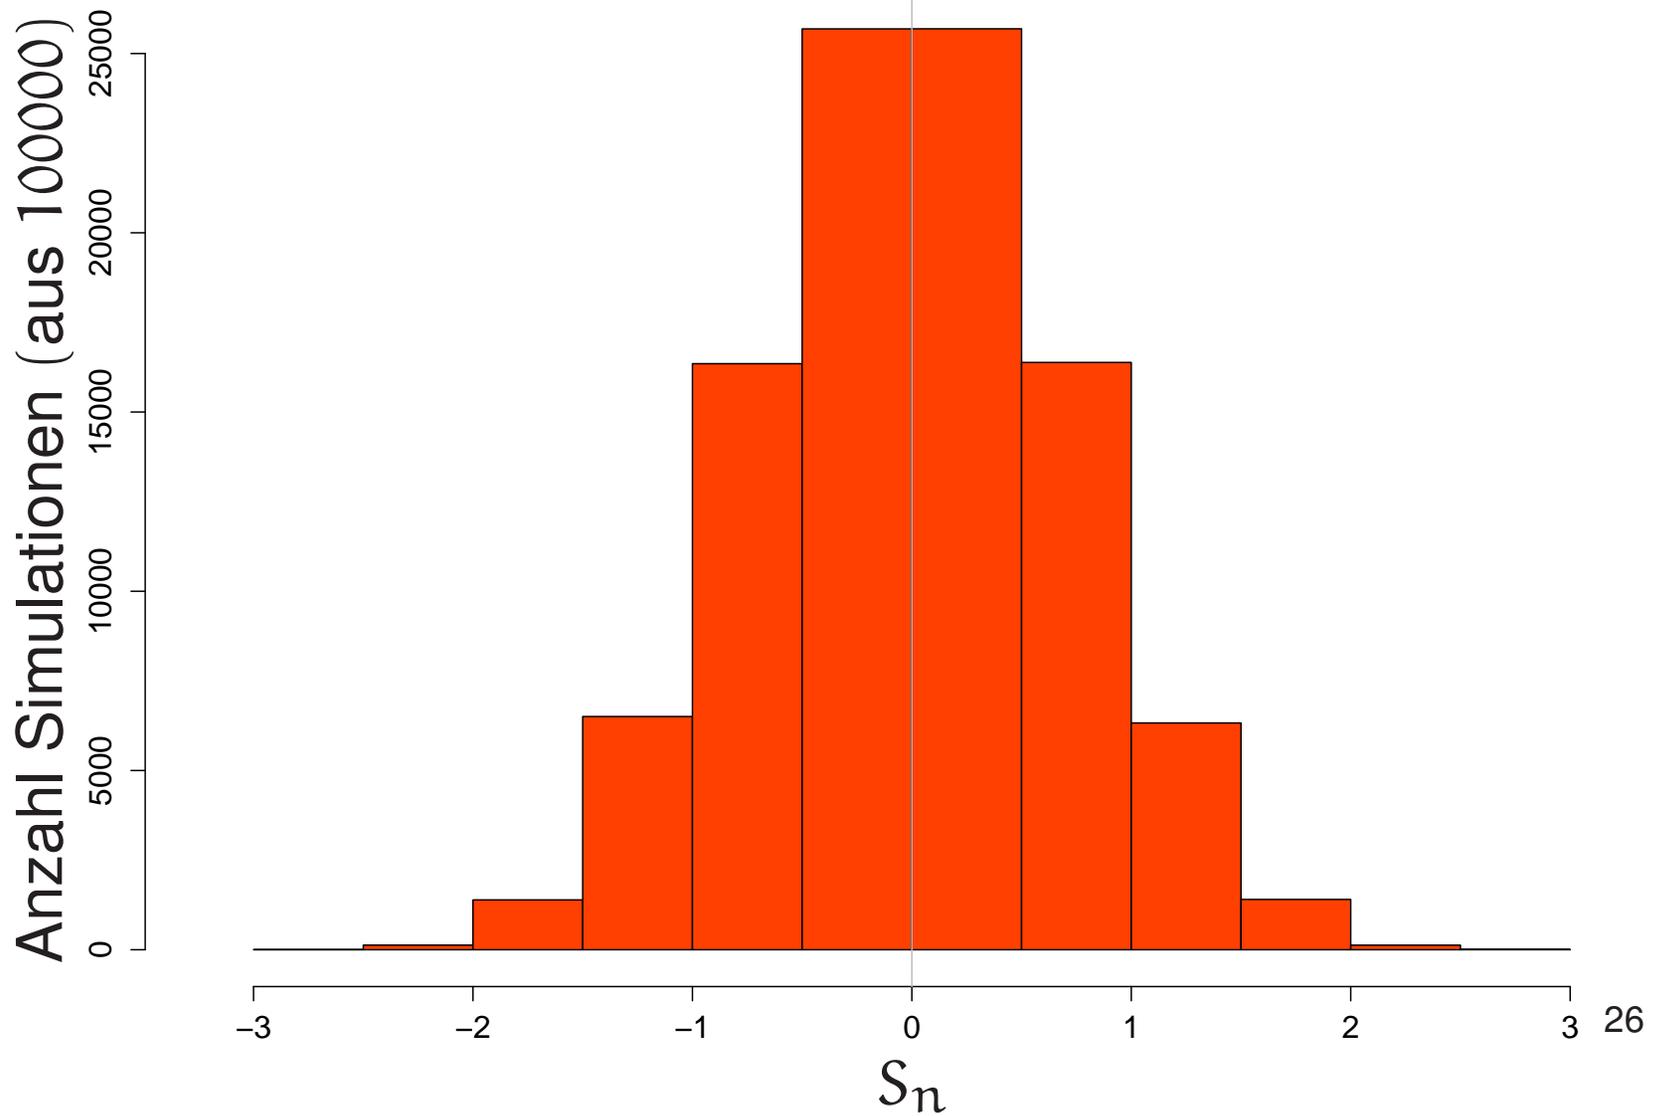
Verteilung von S_n ($n = 4$)



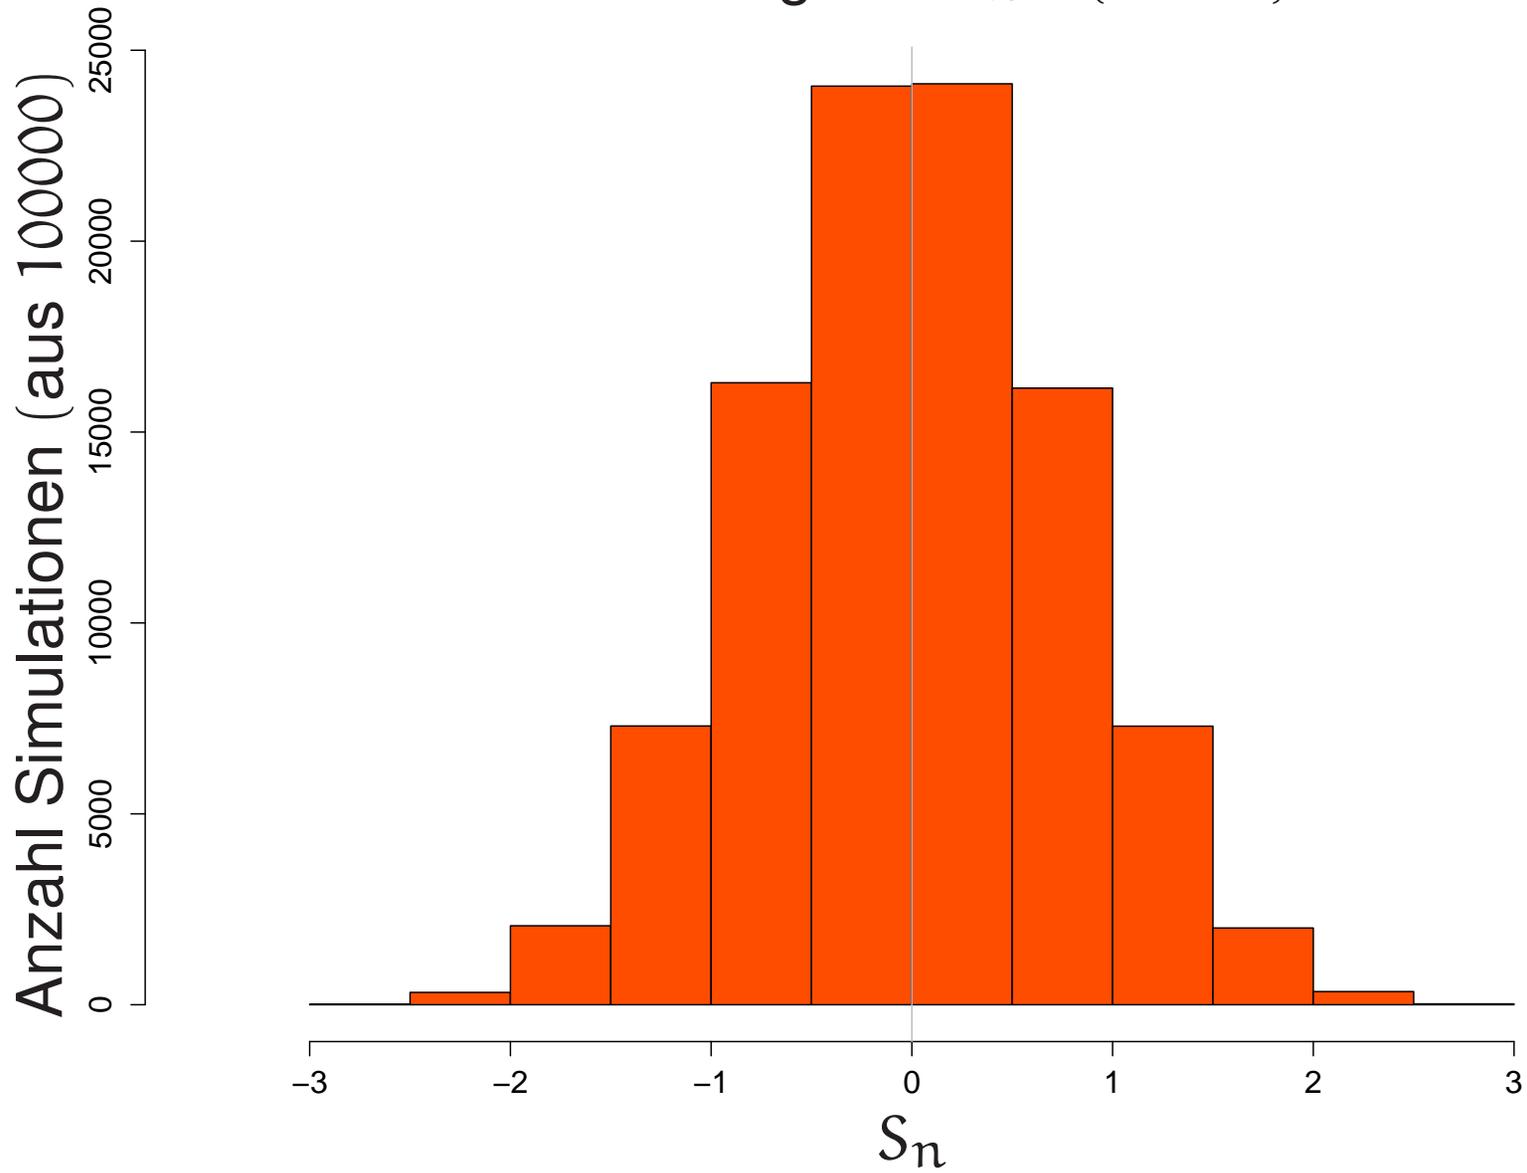
Verteilung von S_n ($n = 5$)



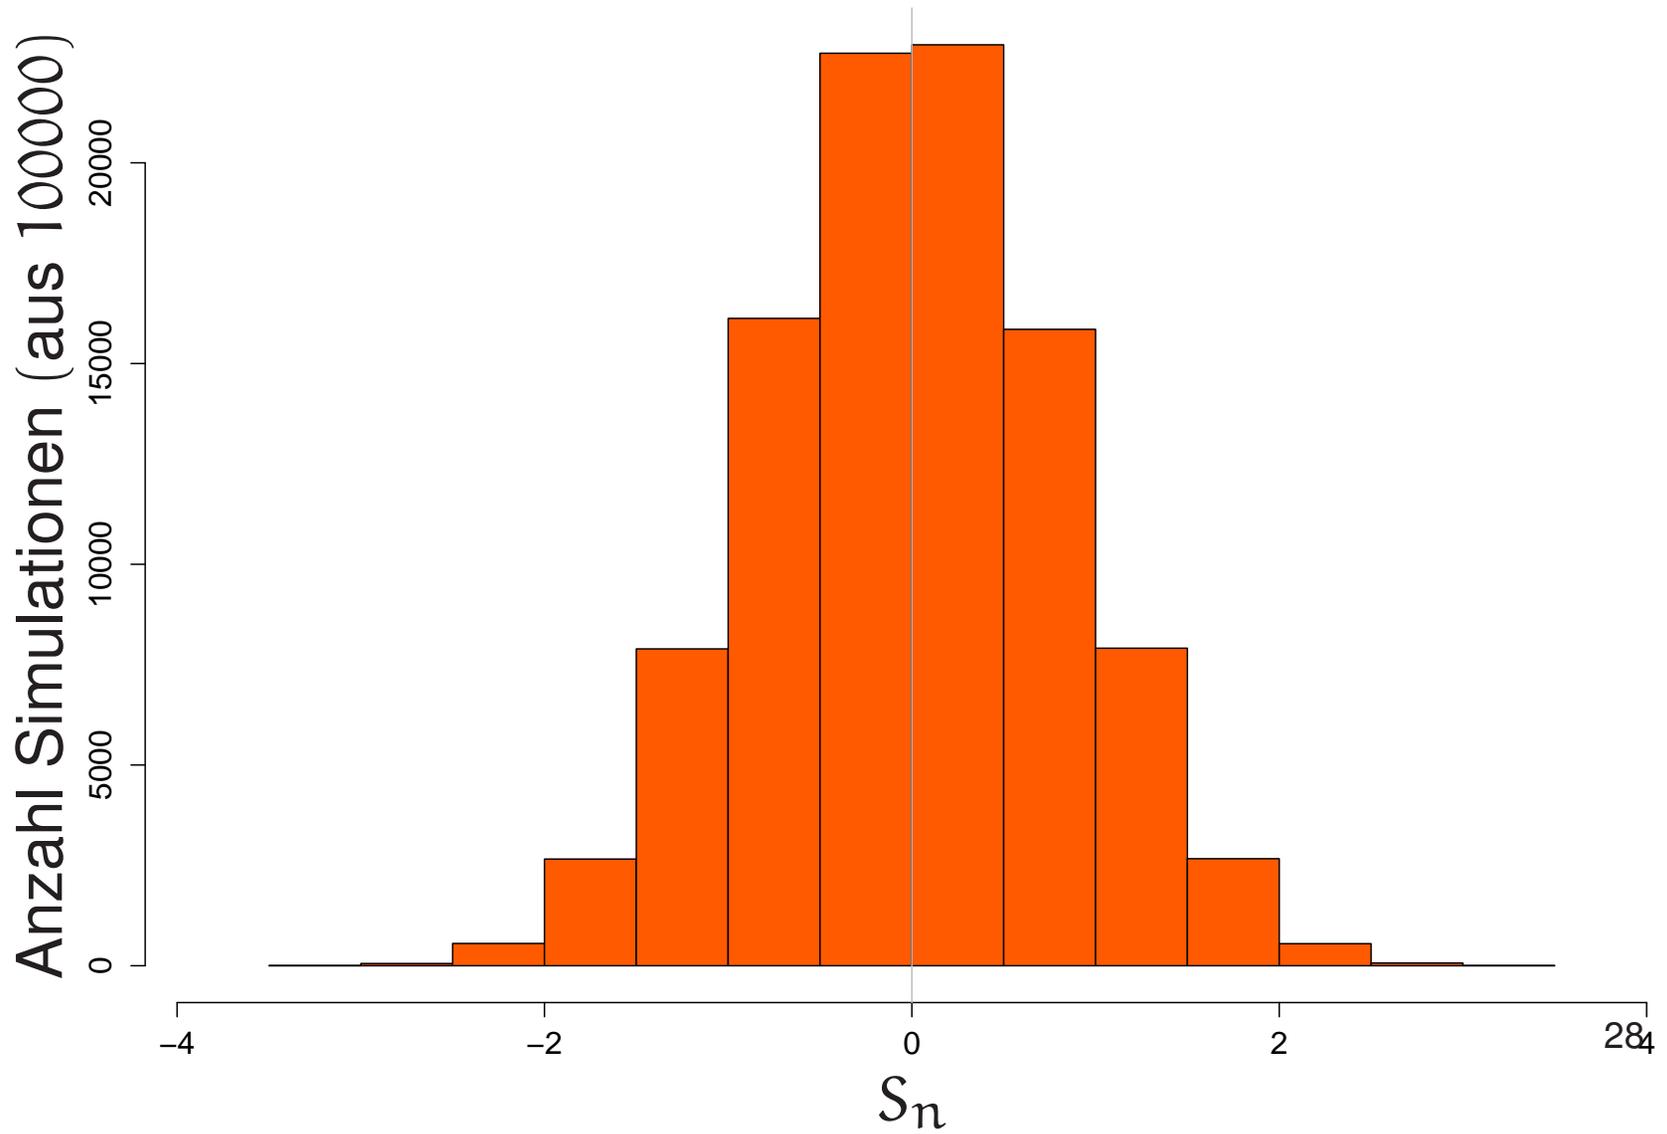
Verteilung von S_n ($n = 6$)



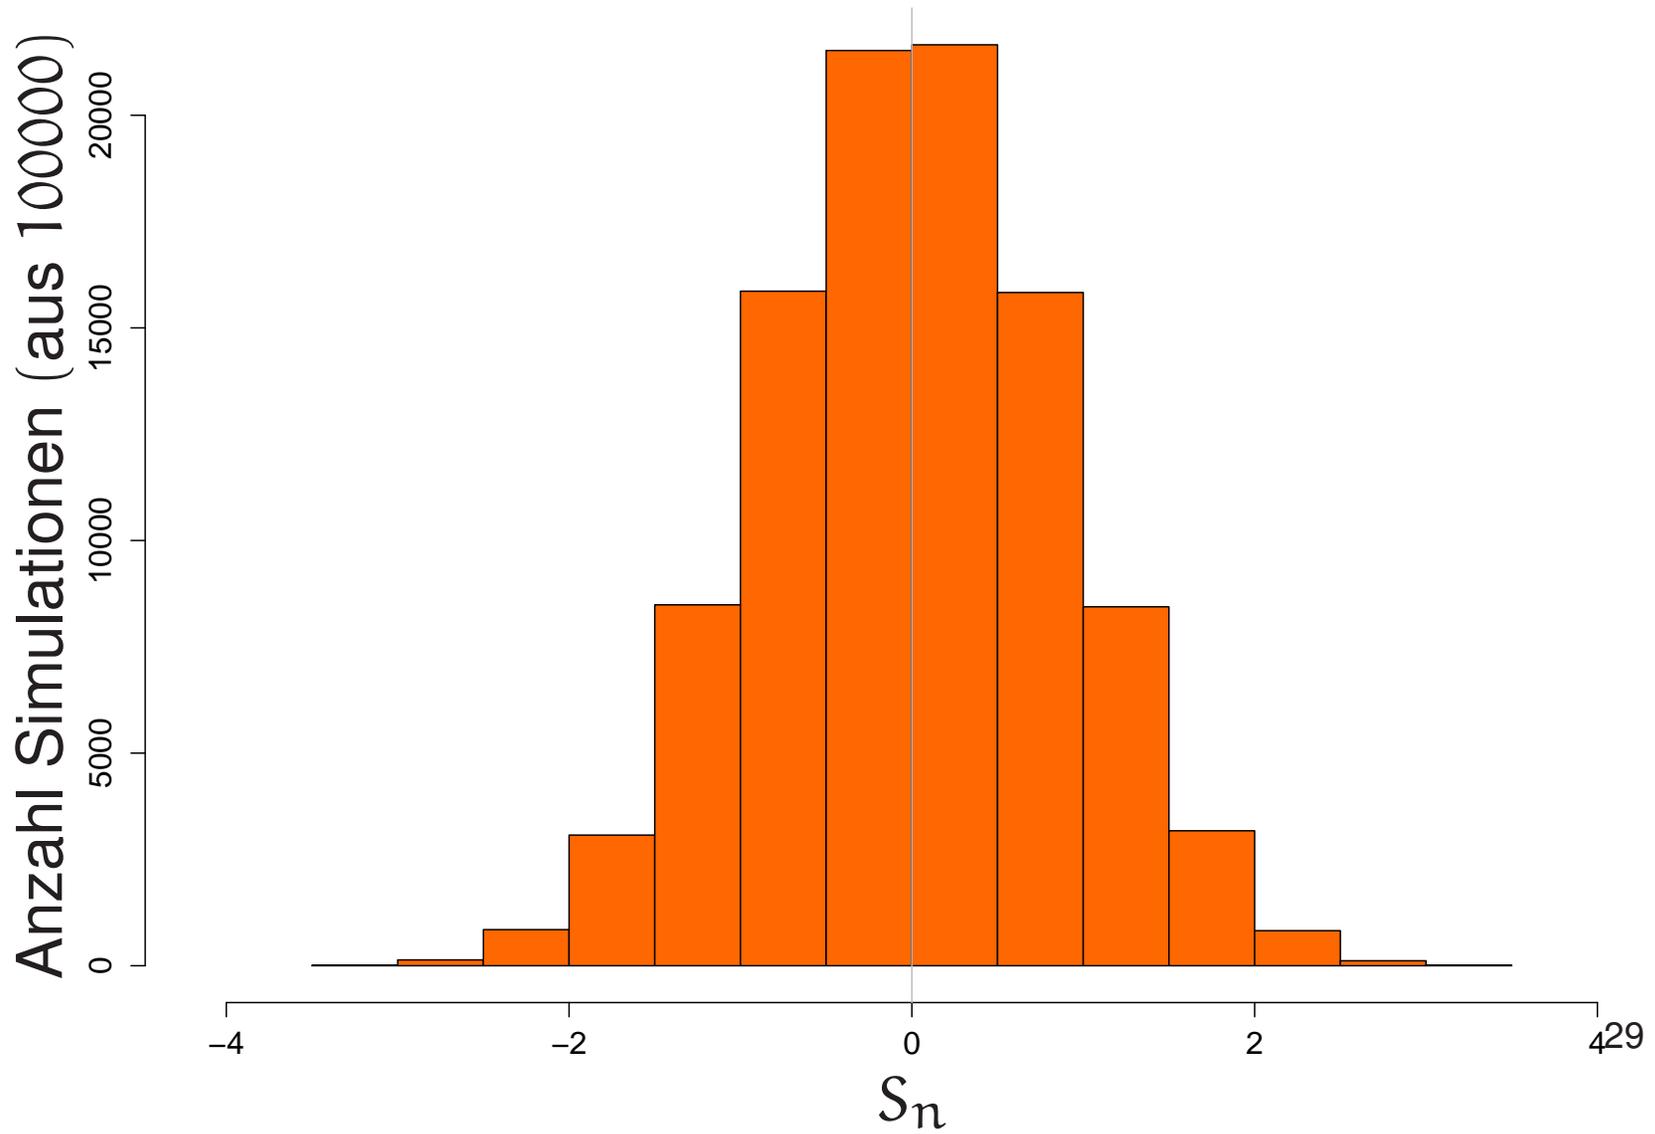
Verteilung von S_n ($n = 7$)



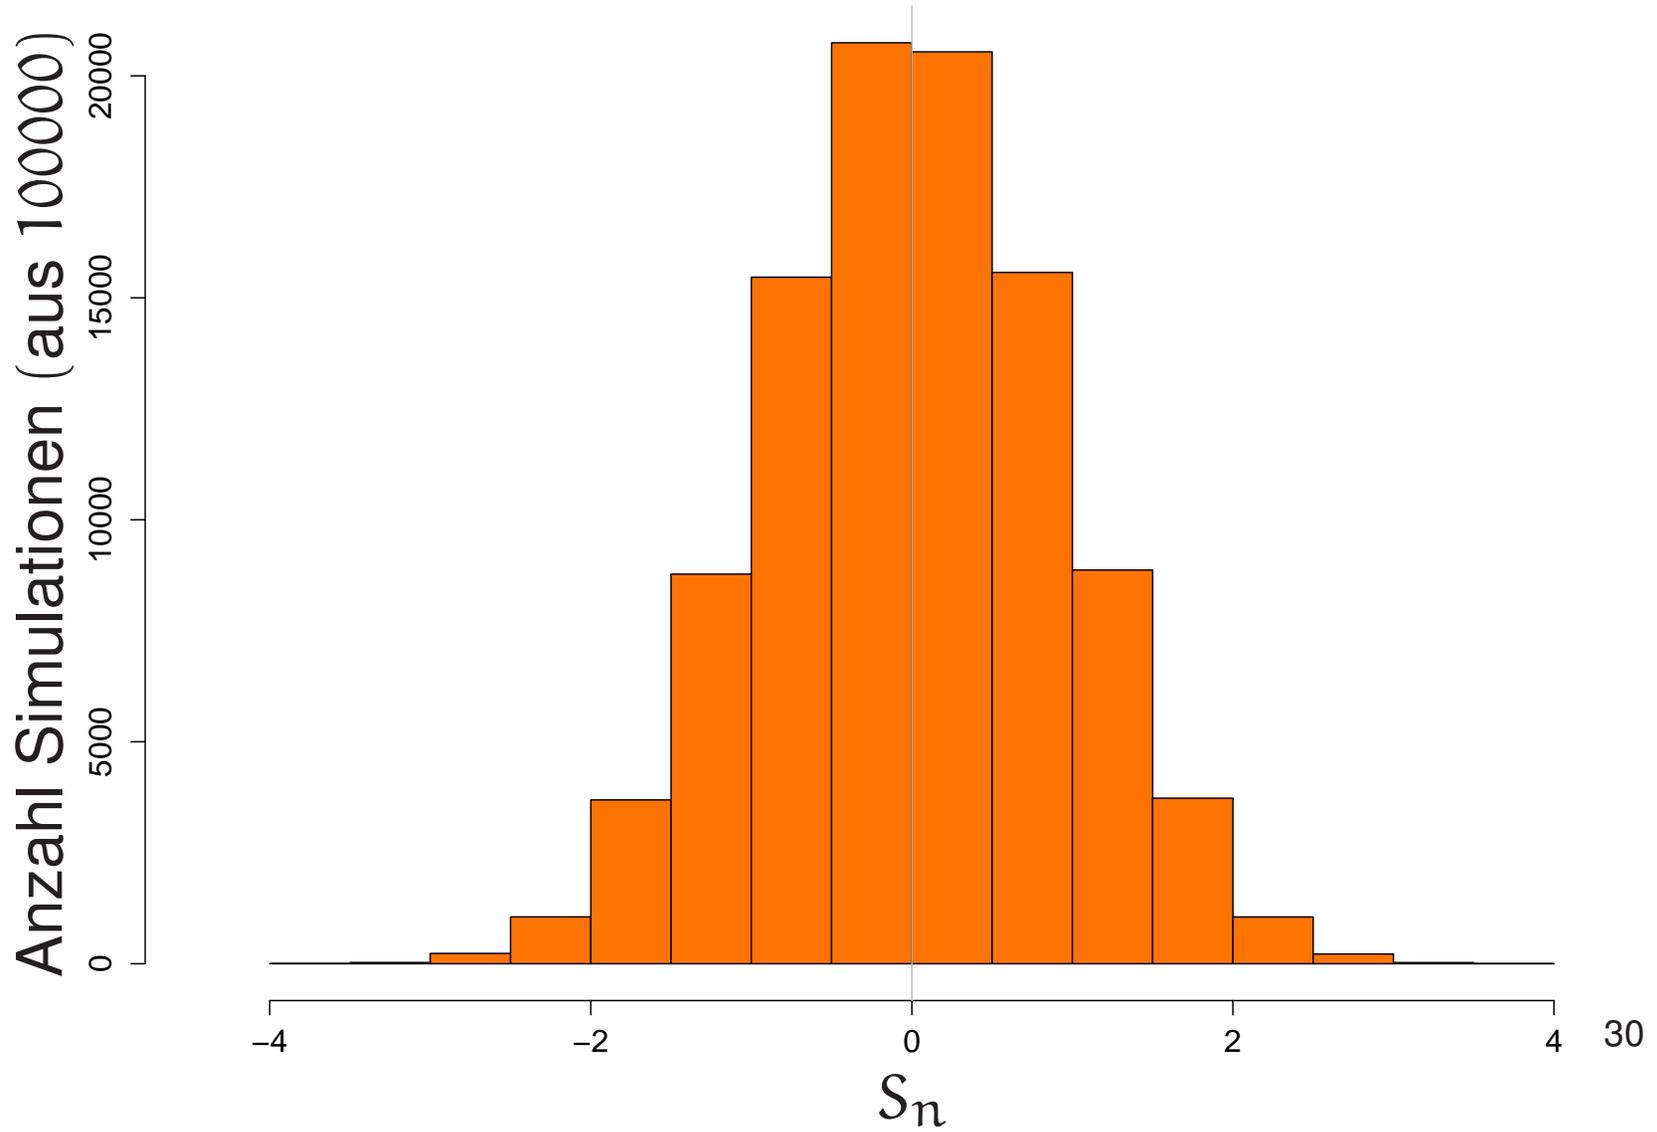
Verteilung von S_n ($n = 8$)



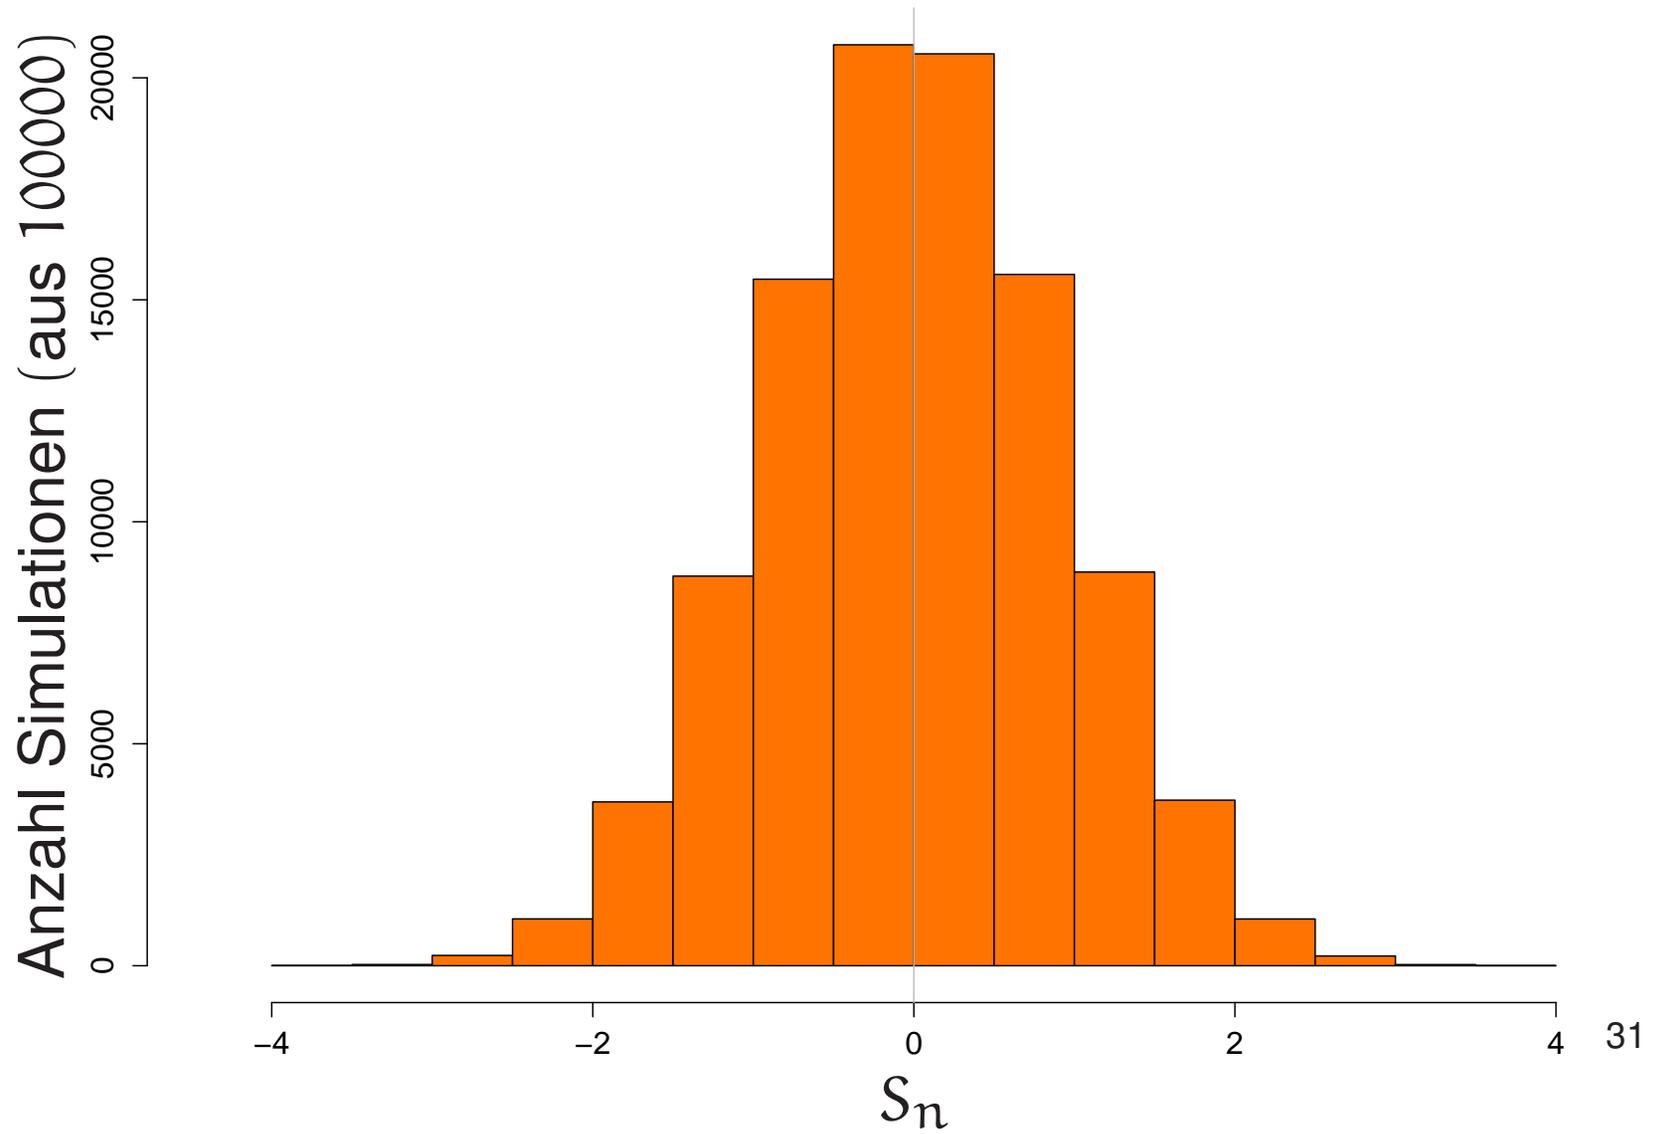
Verteilung von S_n ($n = 9$)



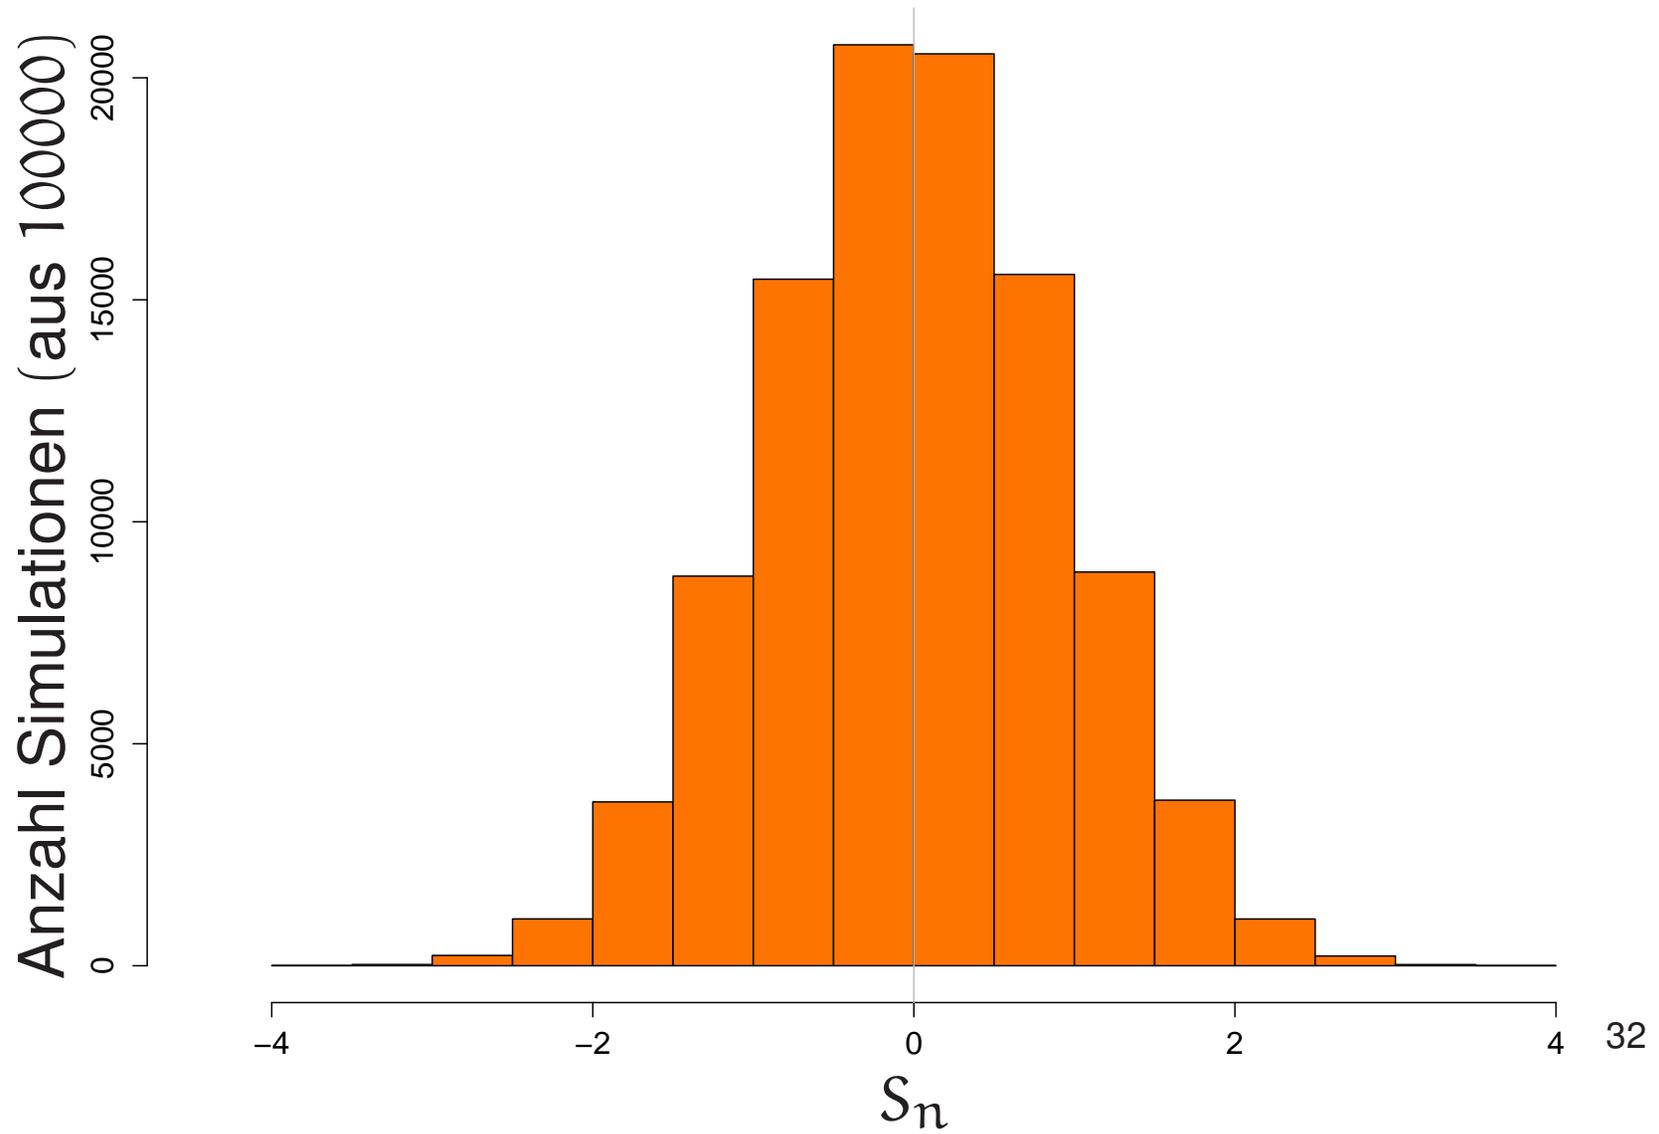
Verteilung von S_n ($n = 10$)



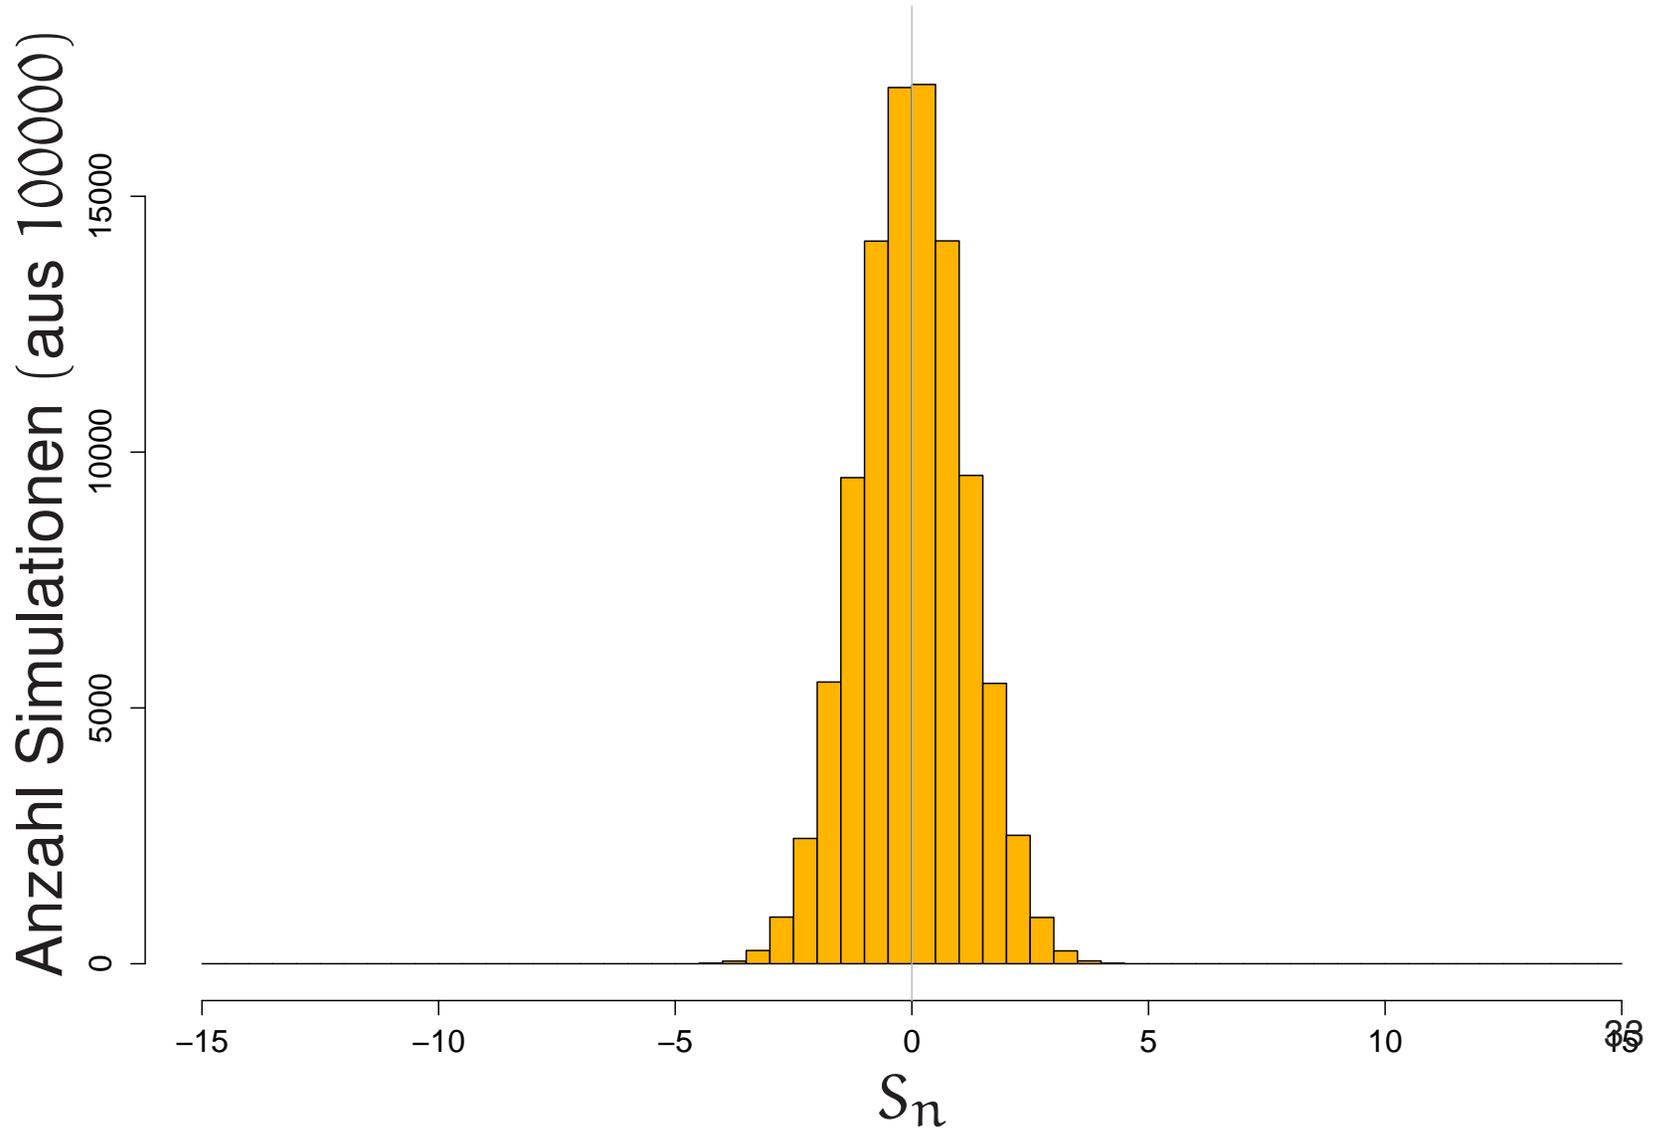
Bisher: dynamische Skalierung



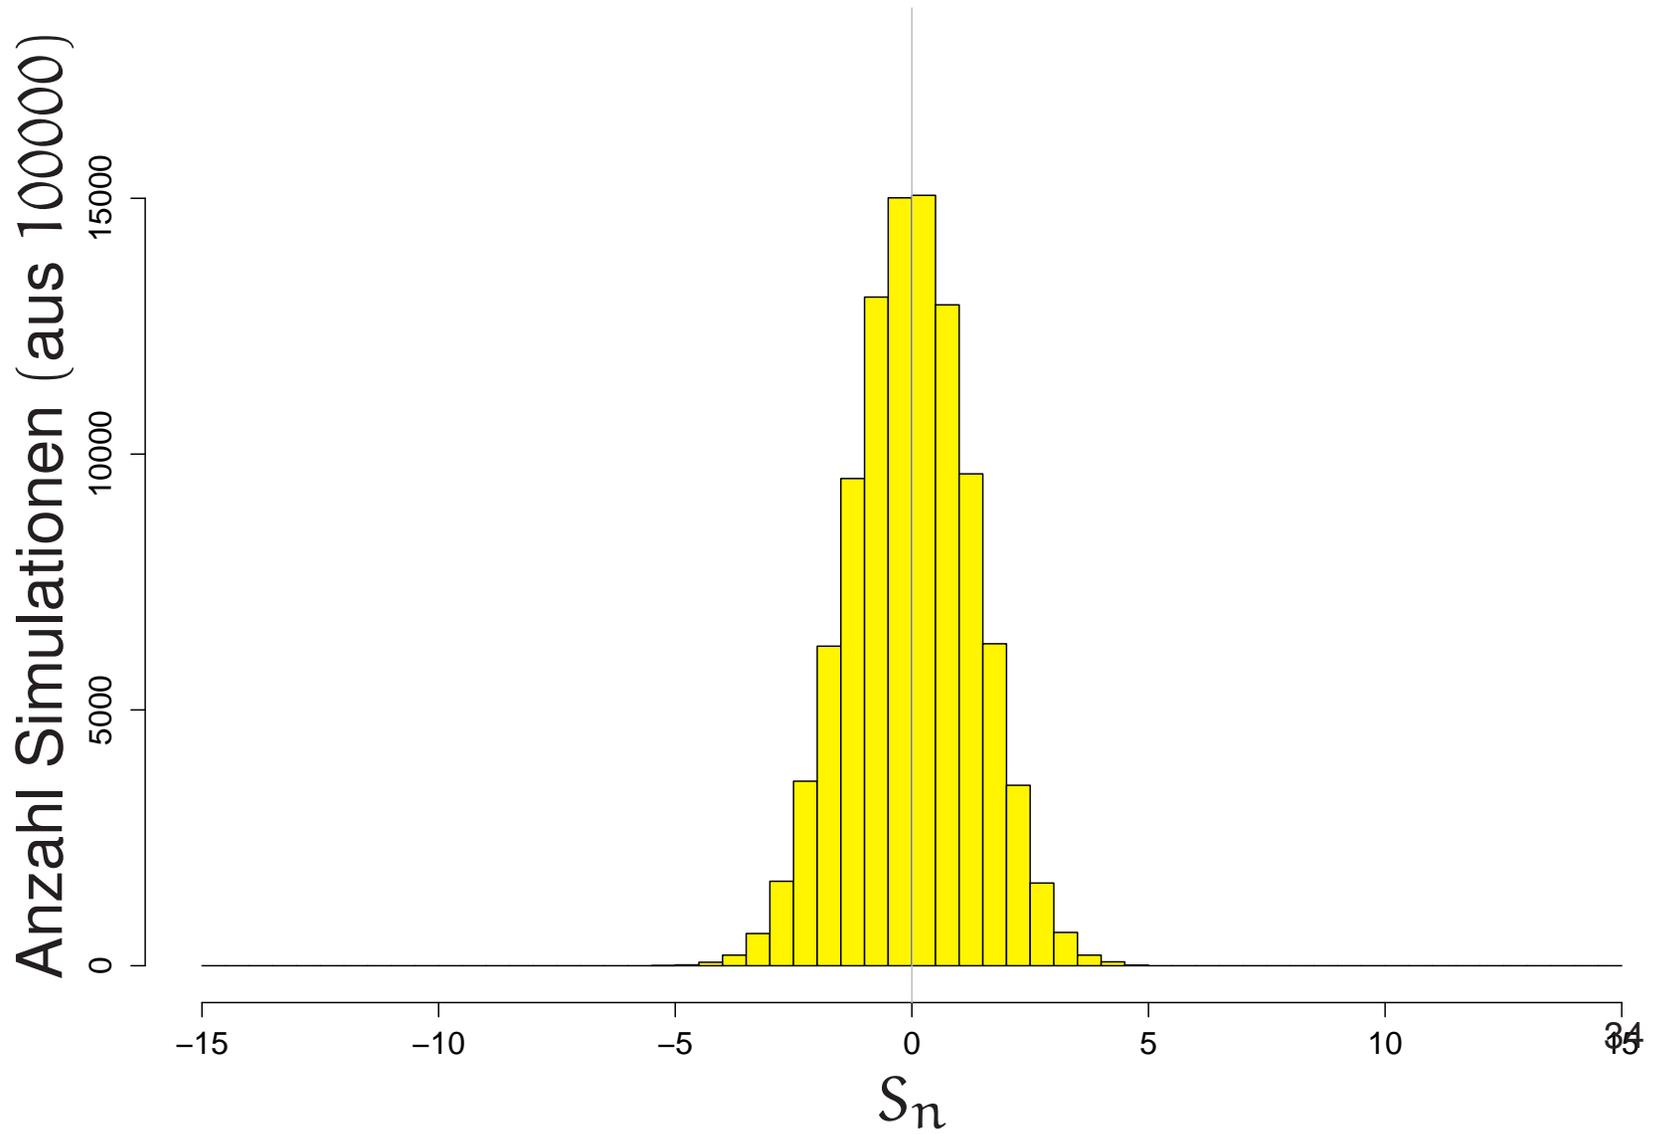
Jetzt: feste Skalierung



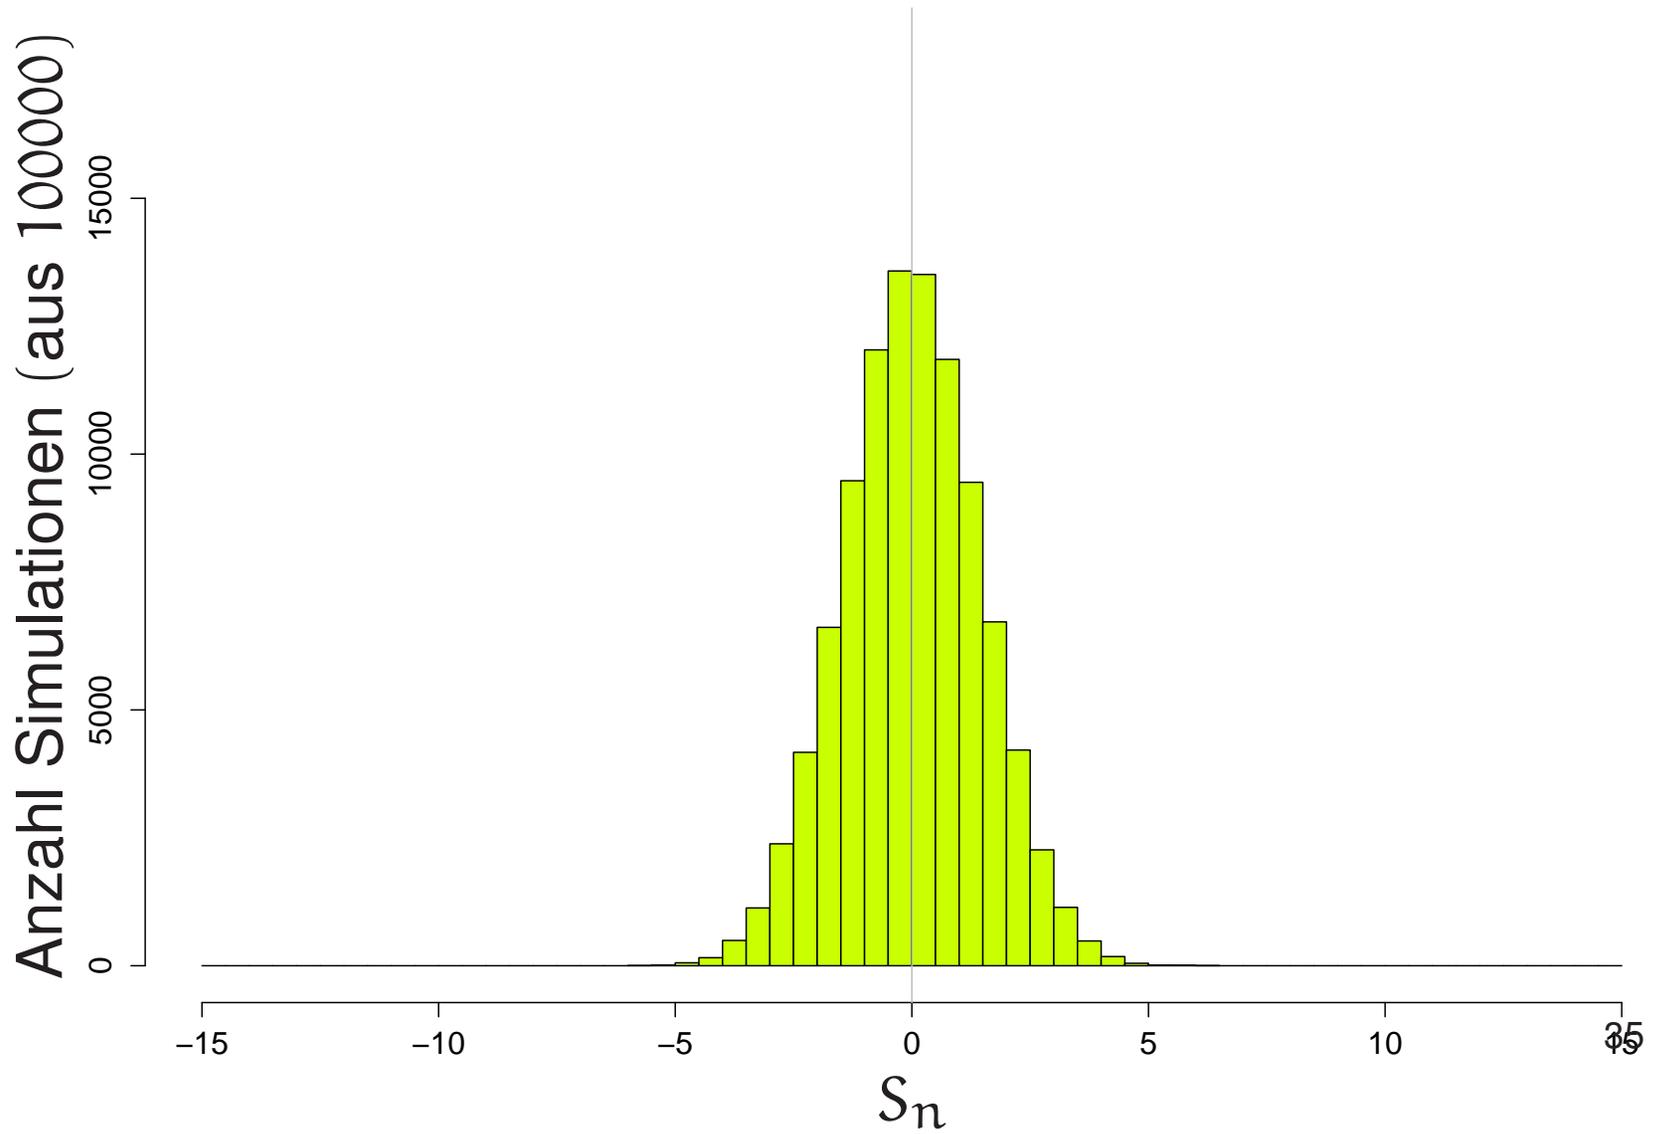
Verteilung von S_n ($n = 15$)



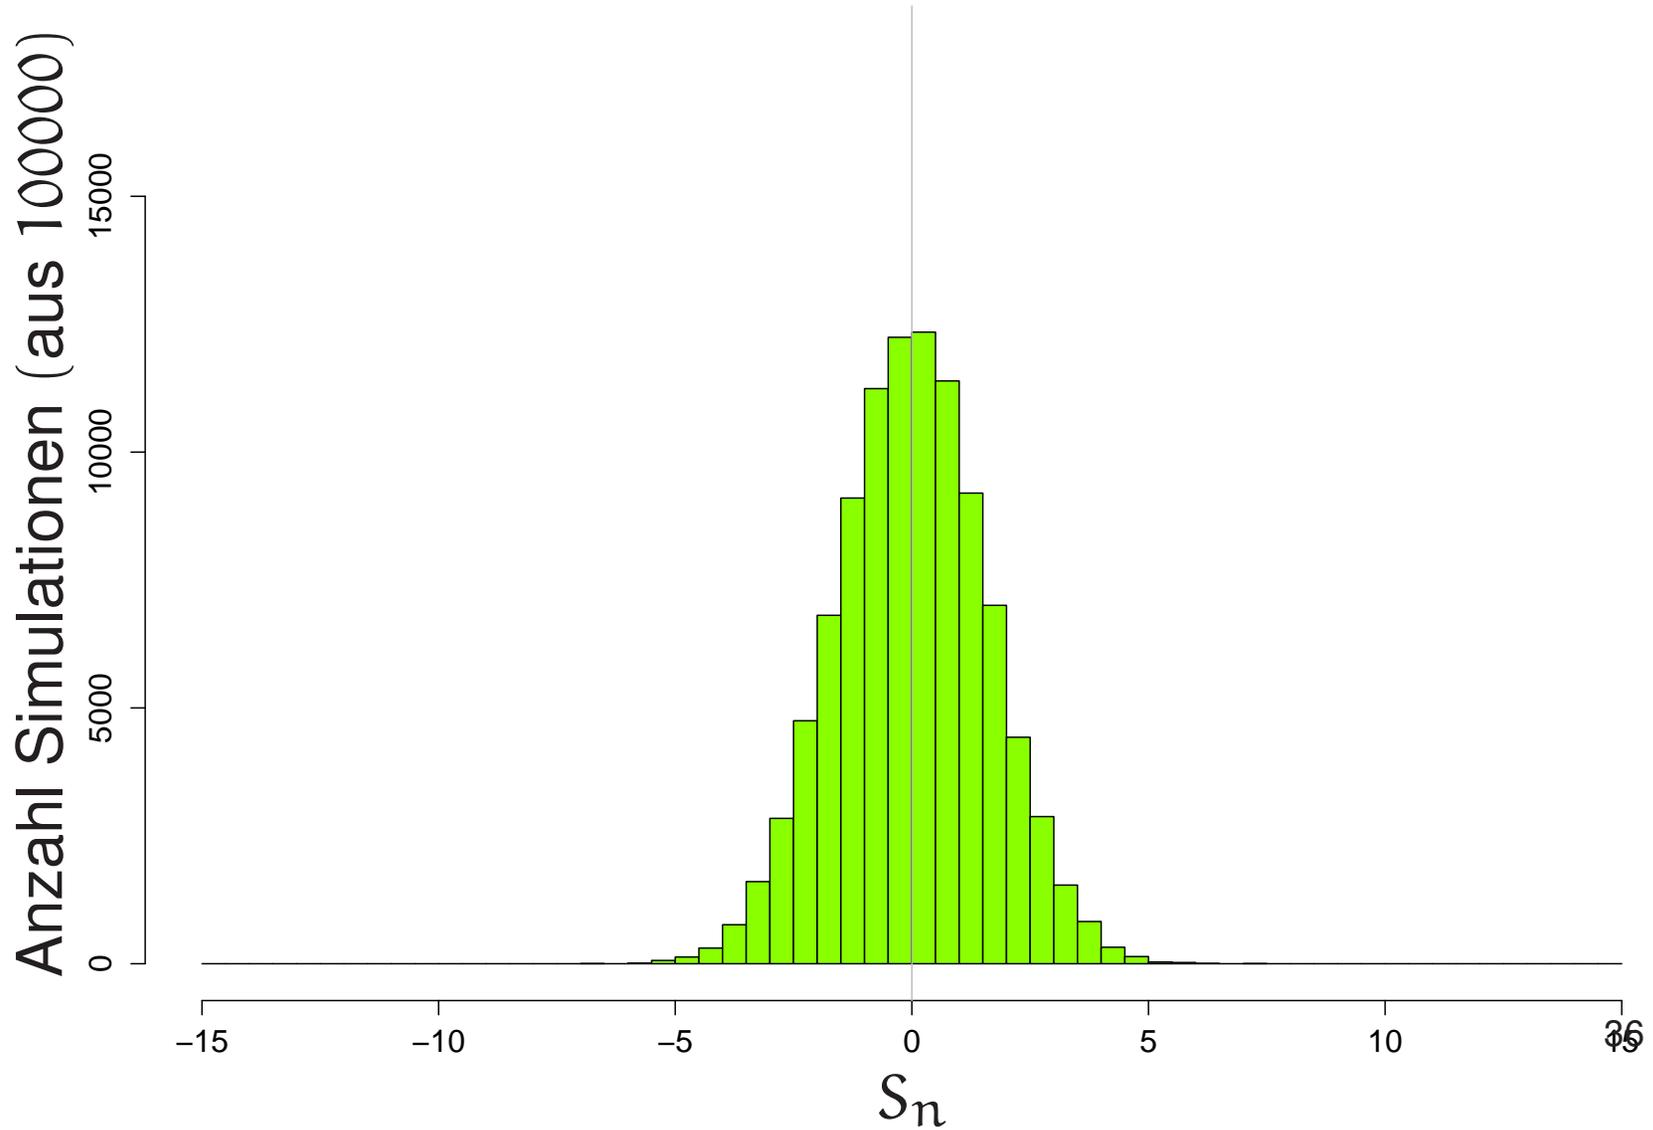
Verteilung von S_n ($n = 20$)



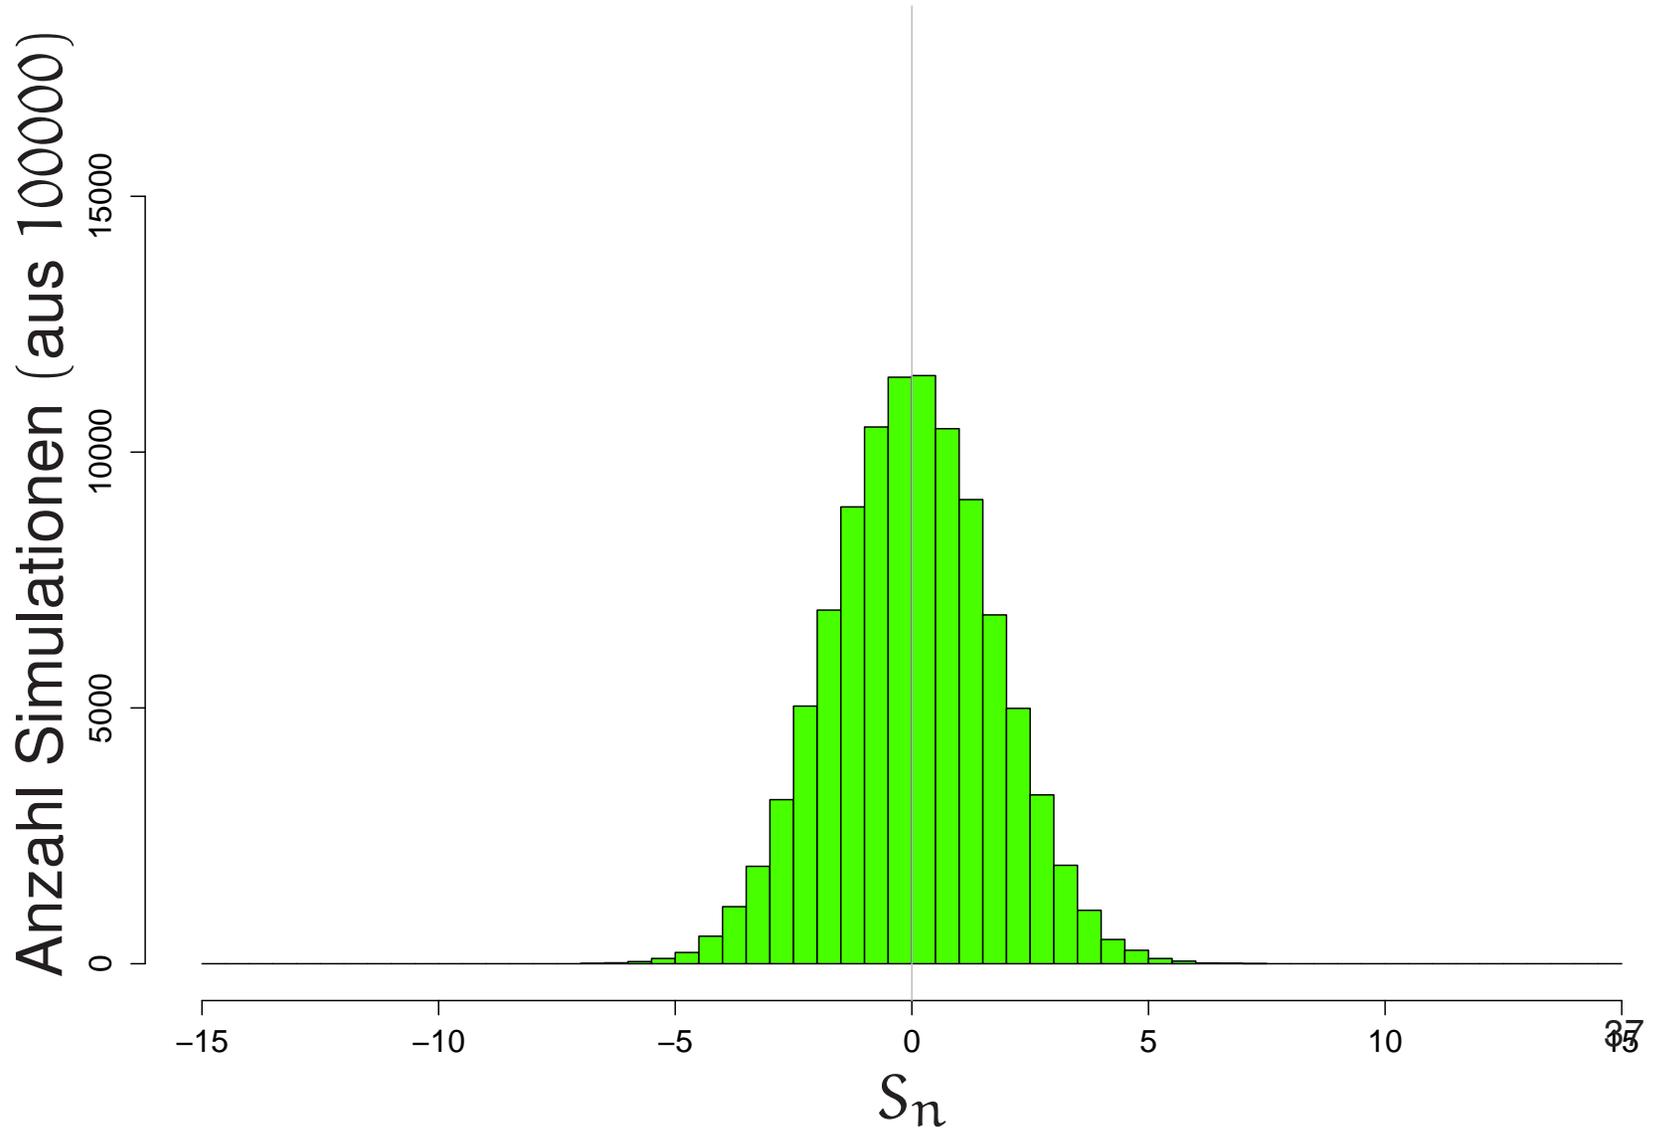
Verteilung von S_n ($n = 25$)



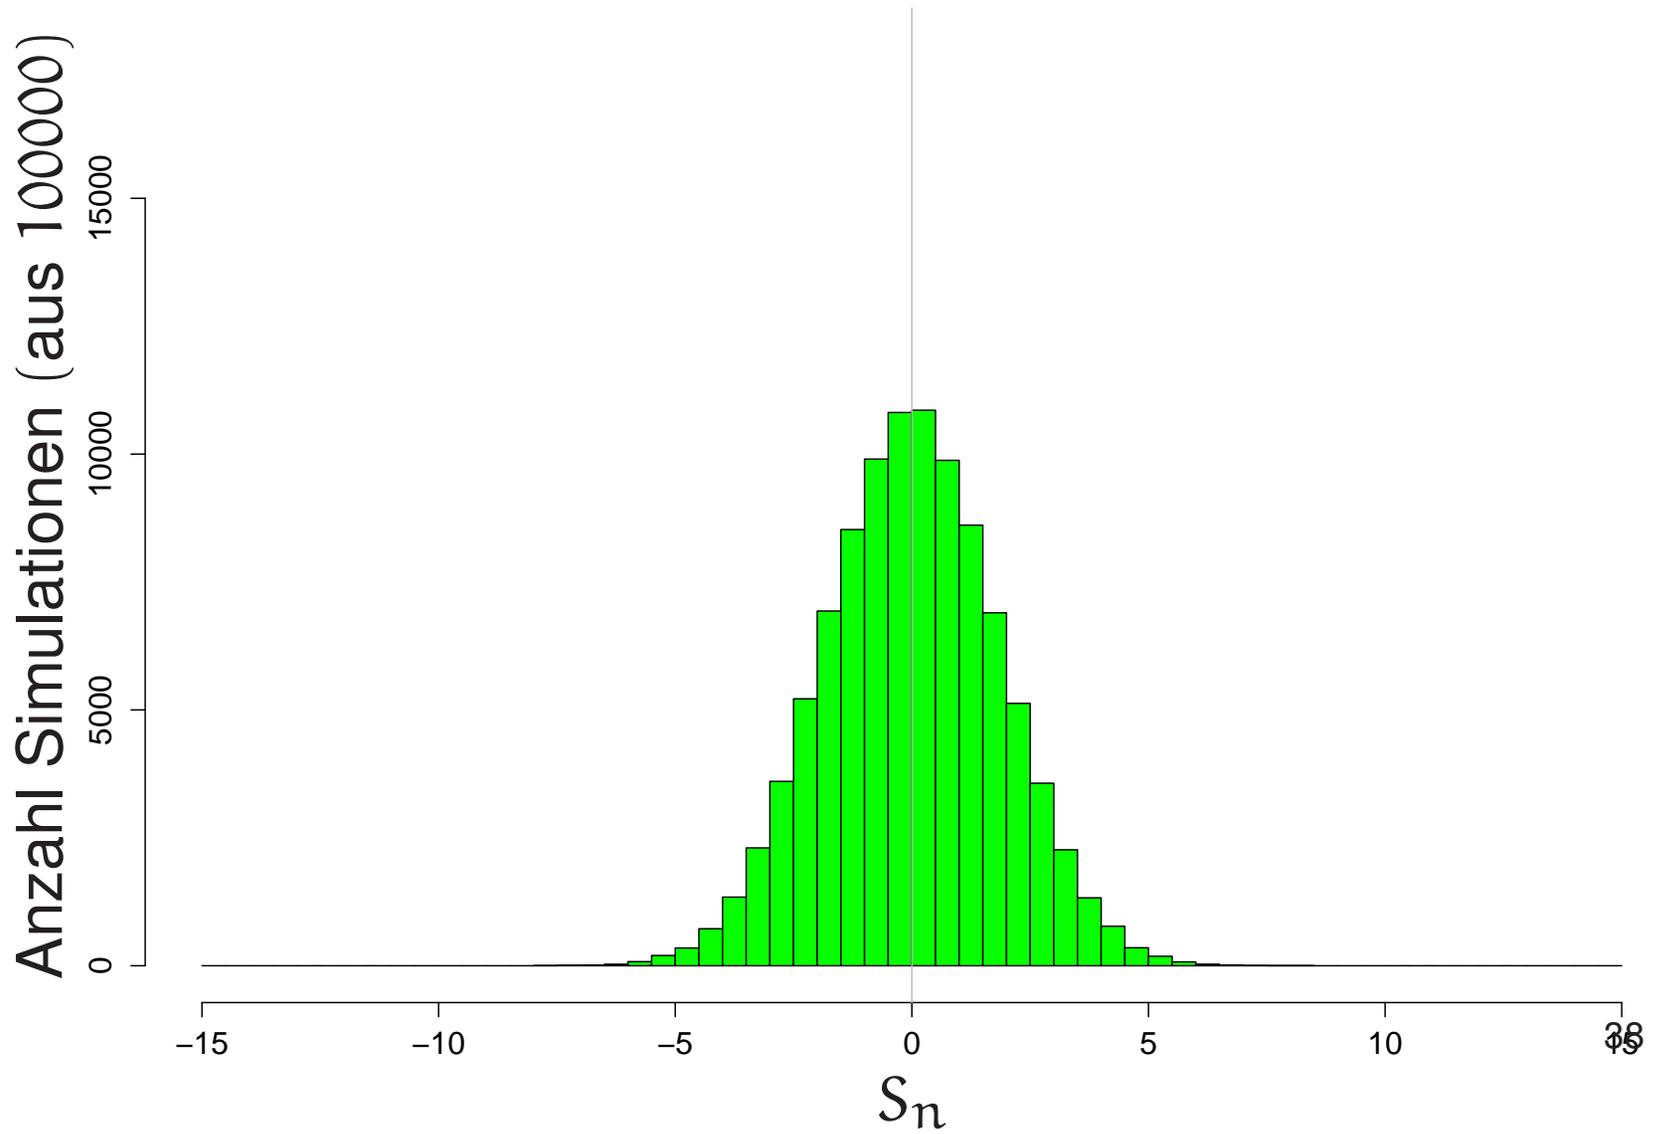
Verteilung von S_n ($n = 30$)



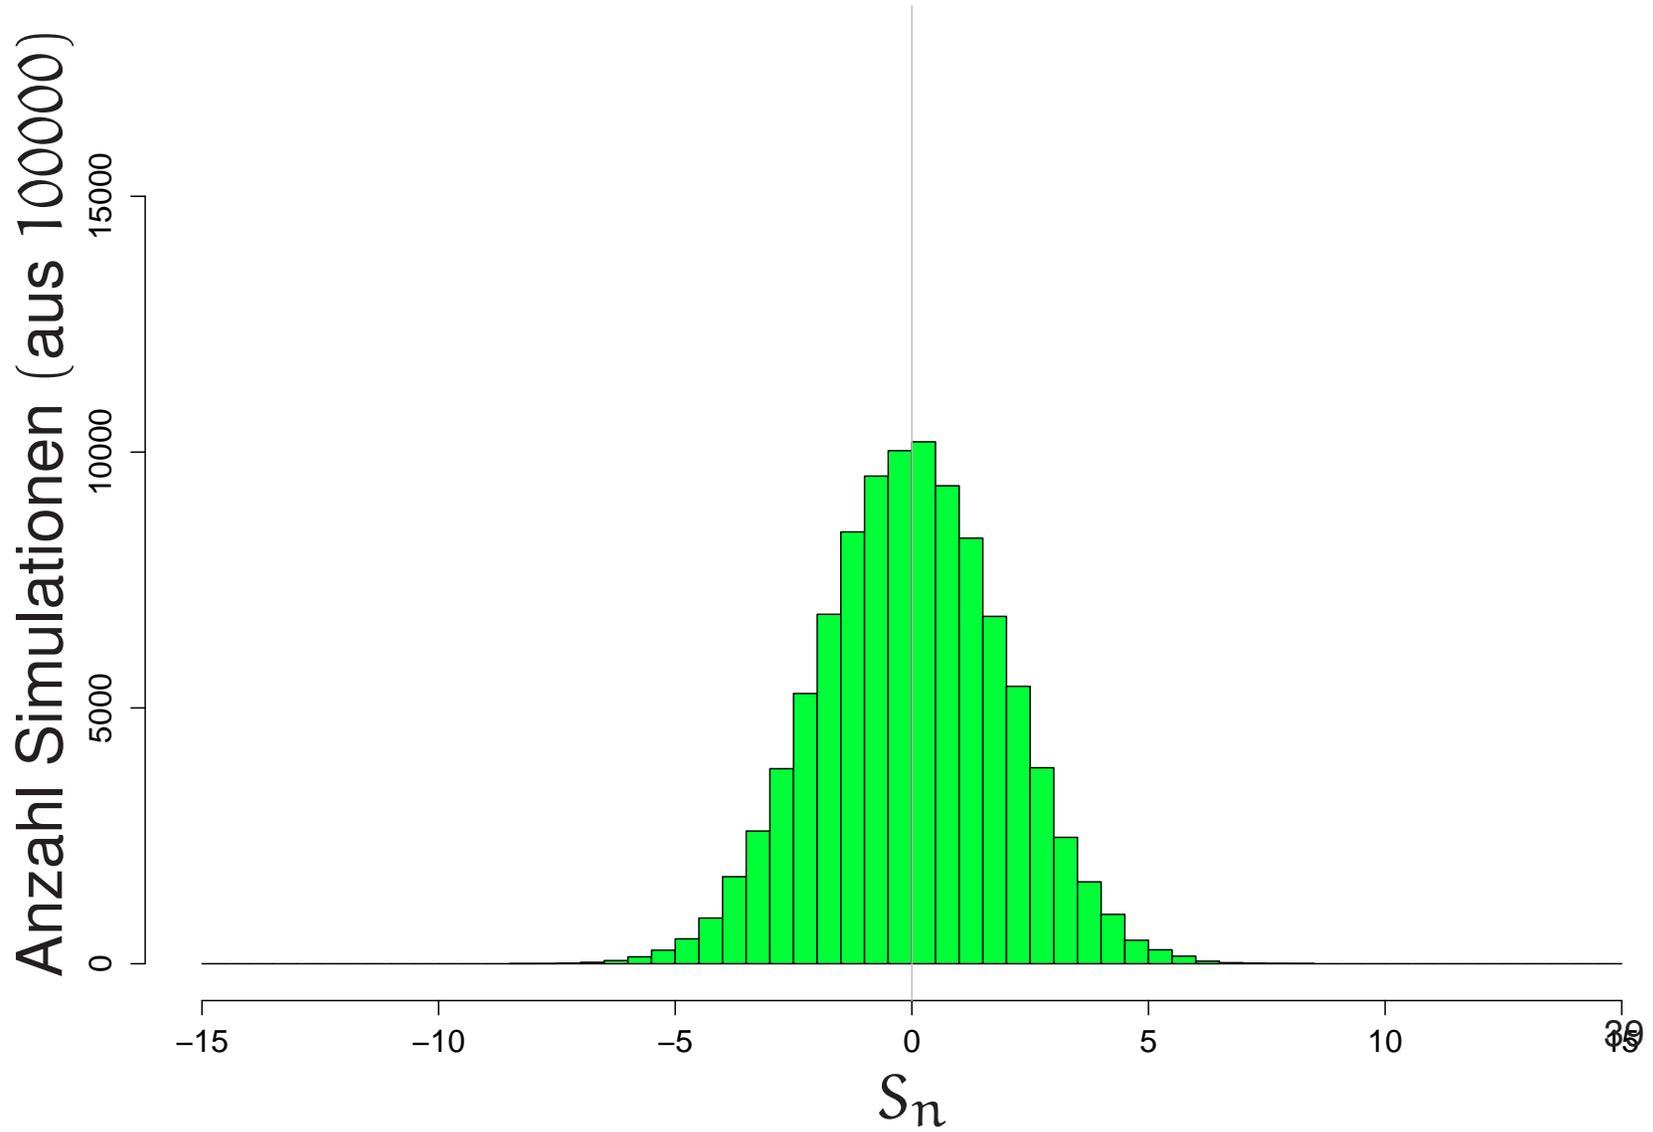
Verteilung von S_n ($n = 35$)



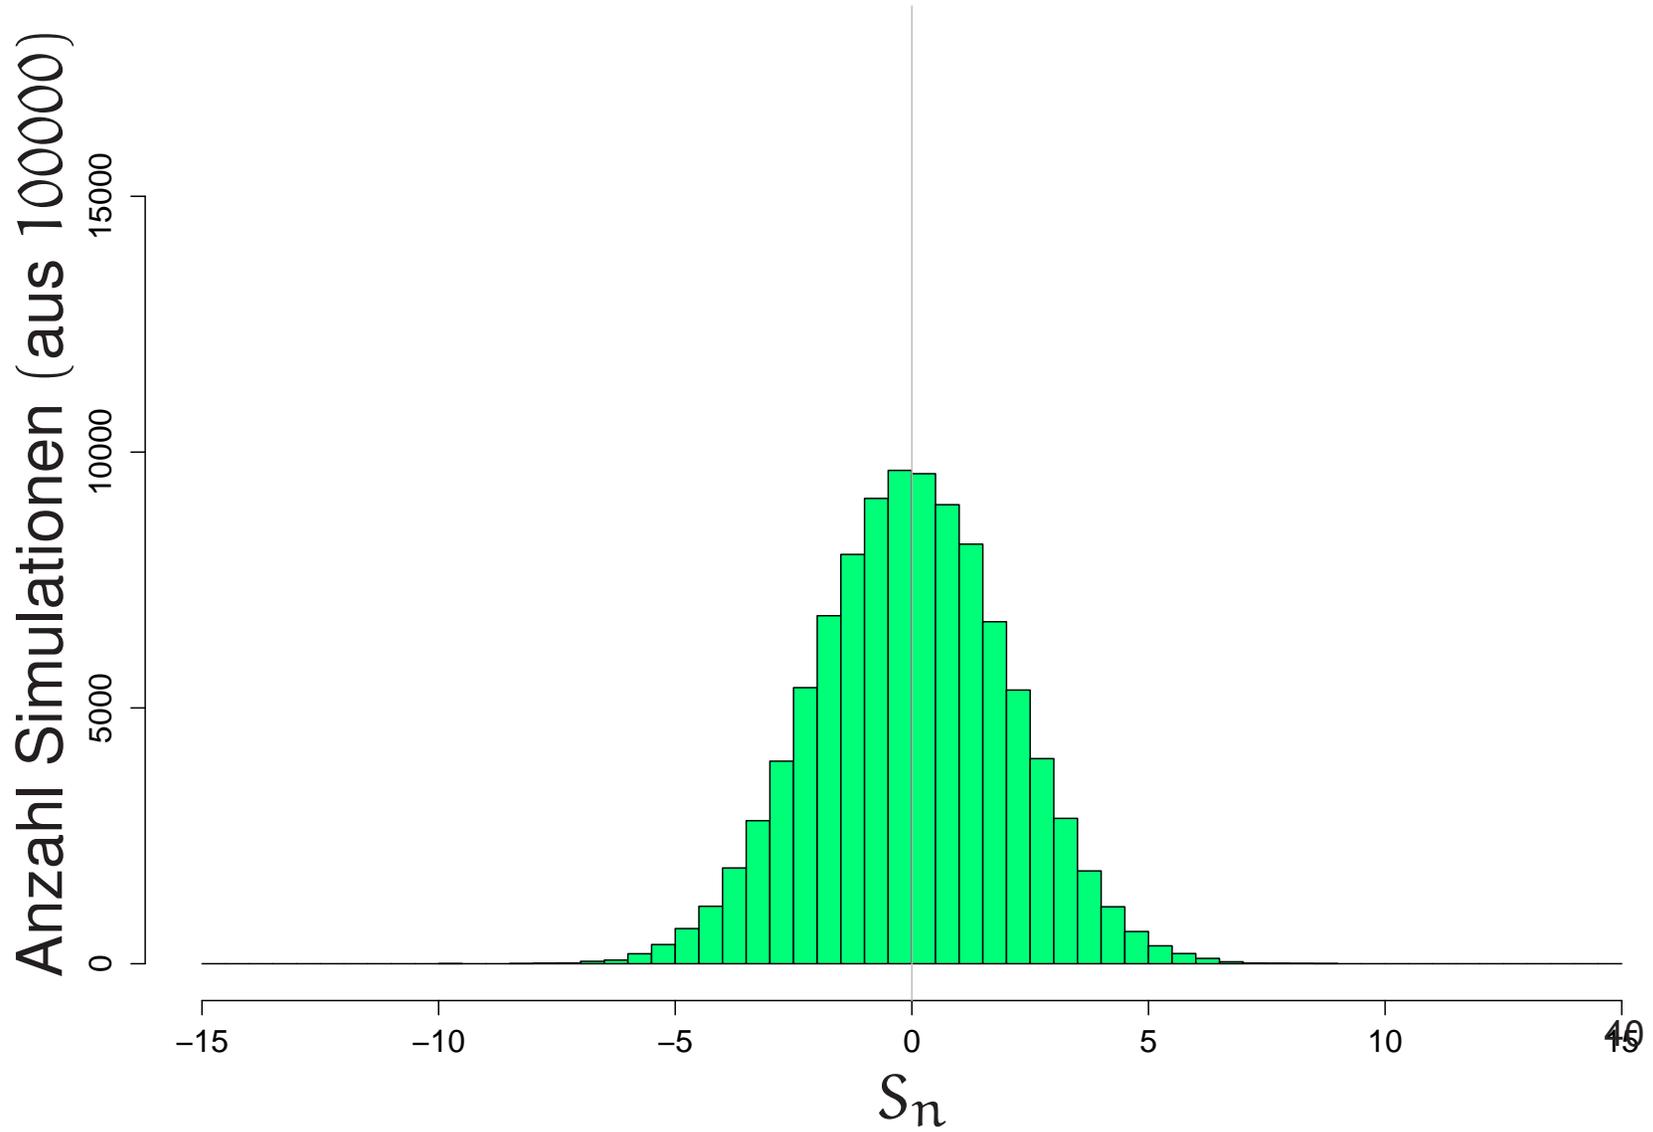
Verteilung von S_n ($n = 40$)



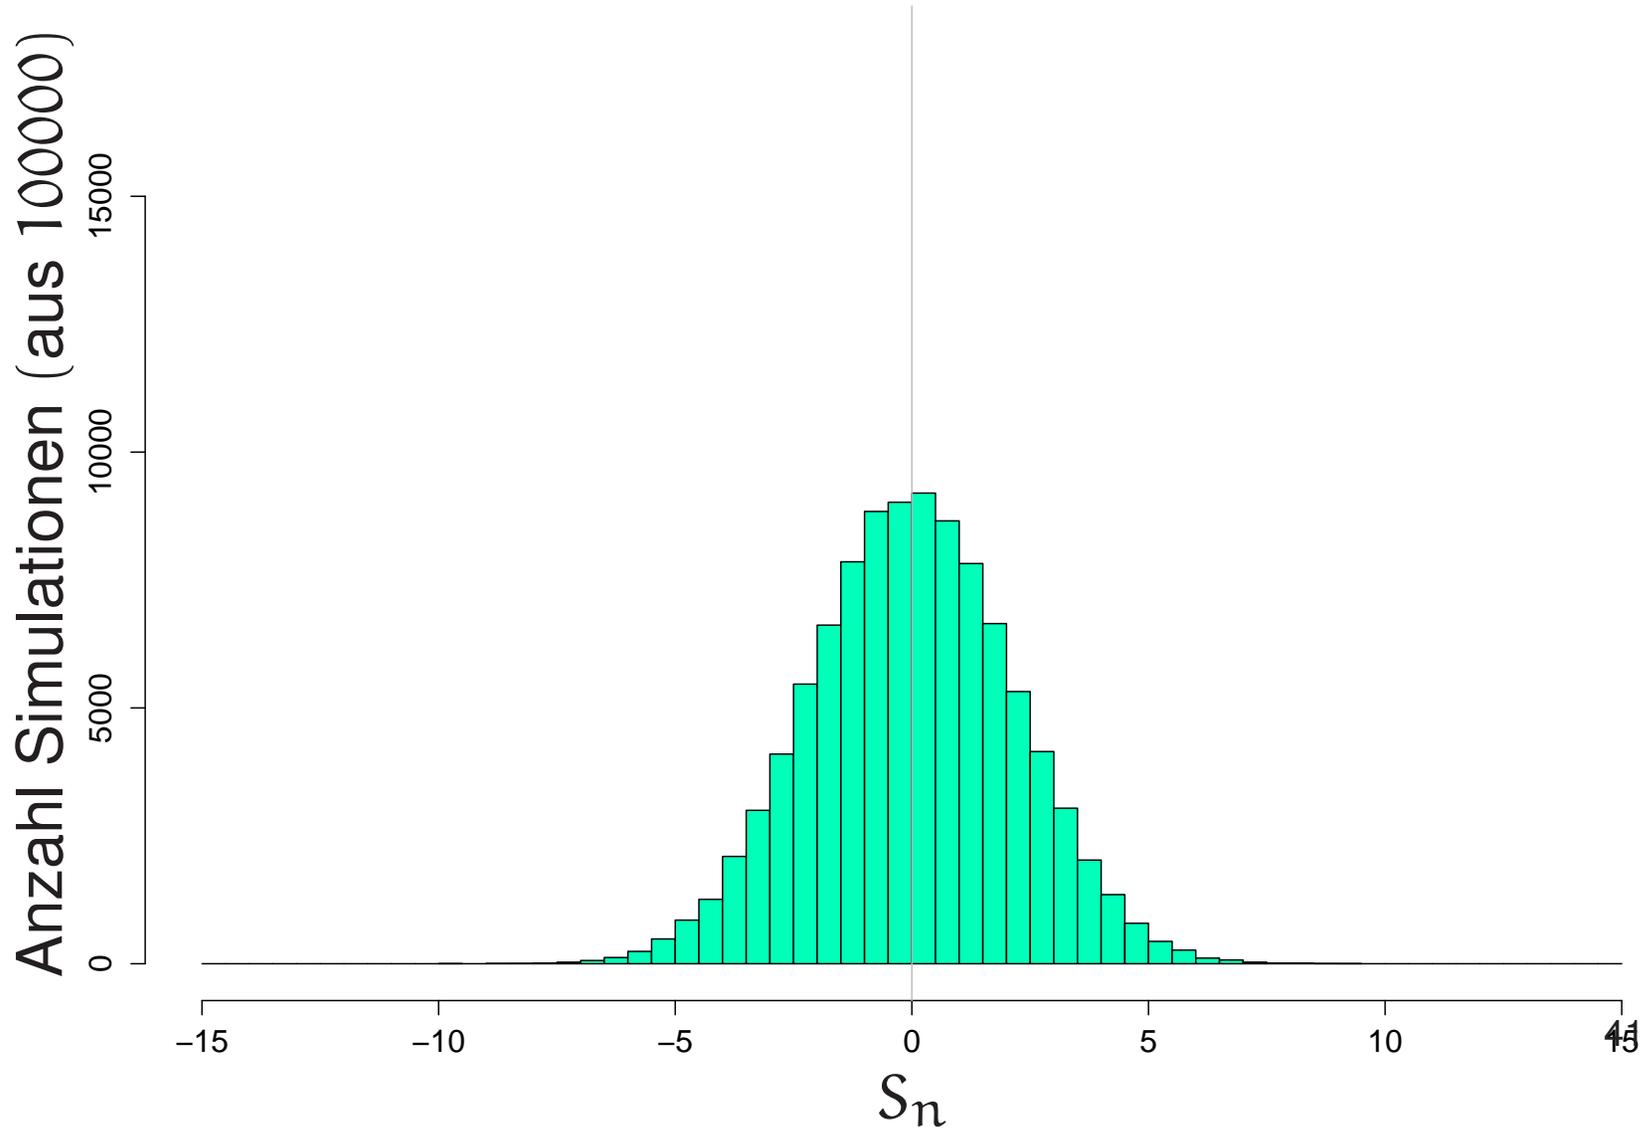
Verteilung von S_n ($n = 45$)



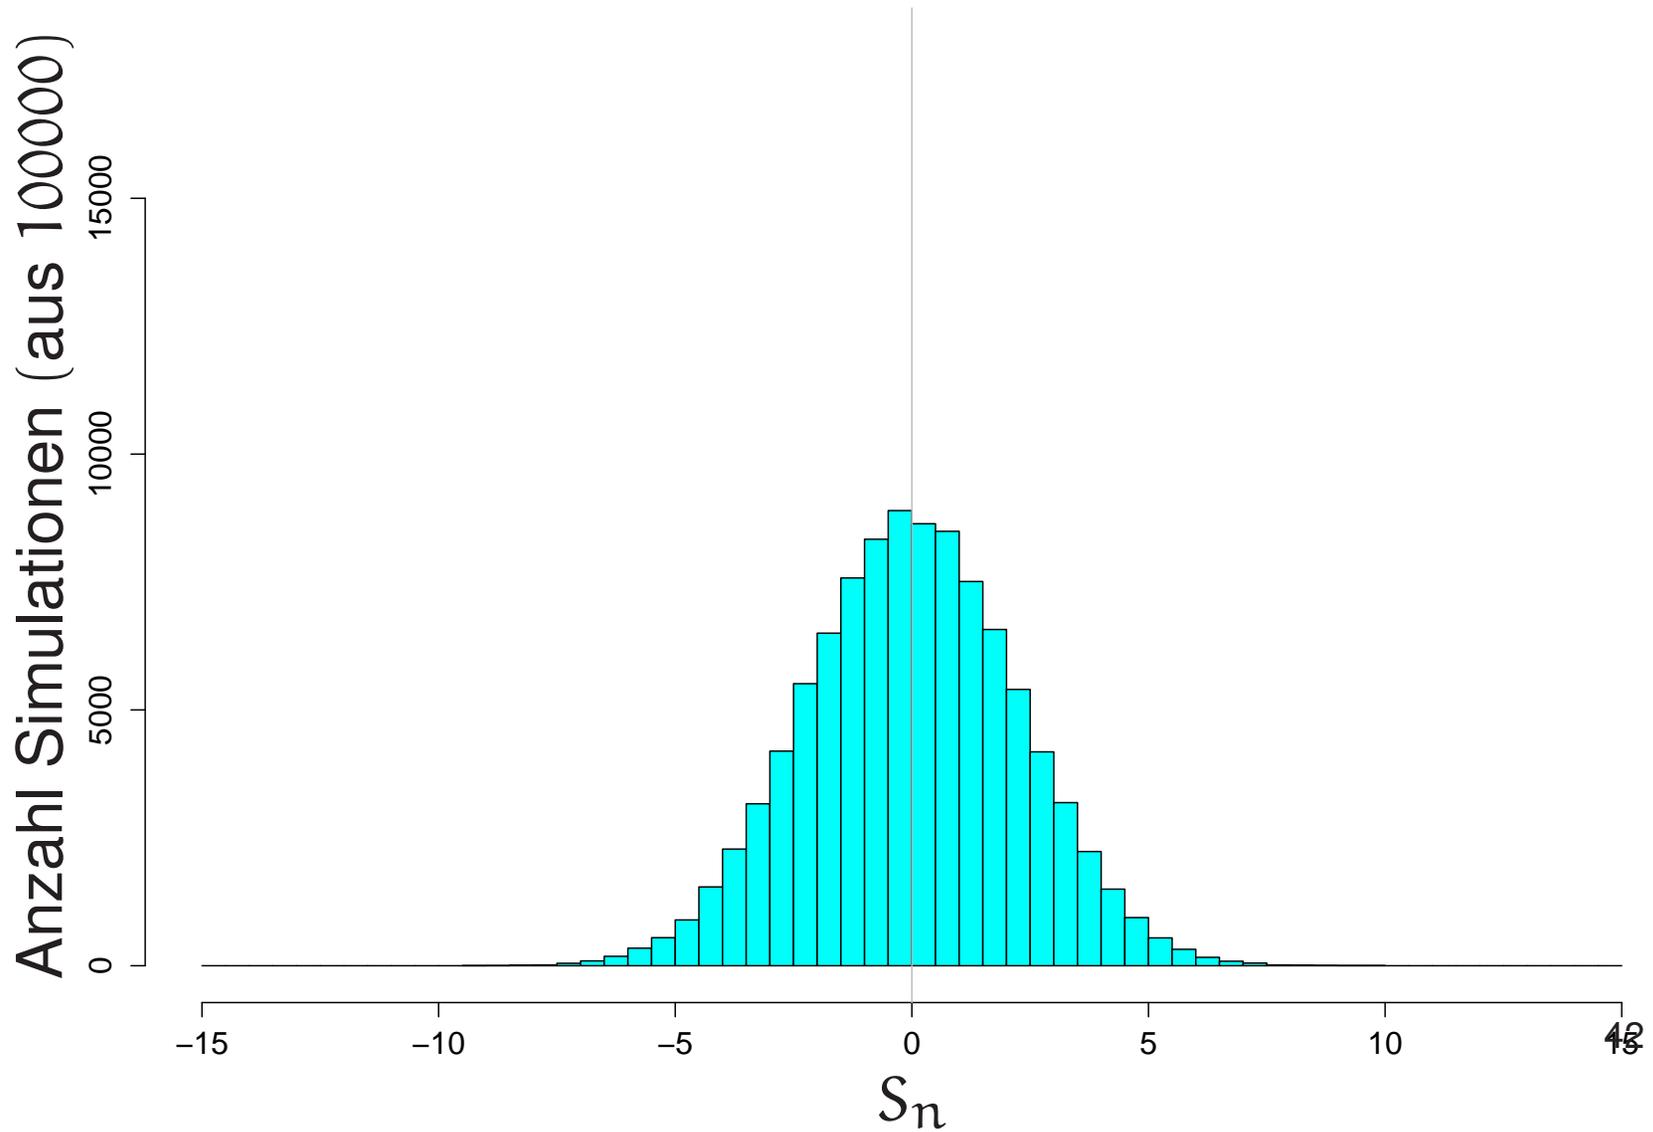
Verteilung von S_n ($n = 50$)



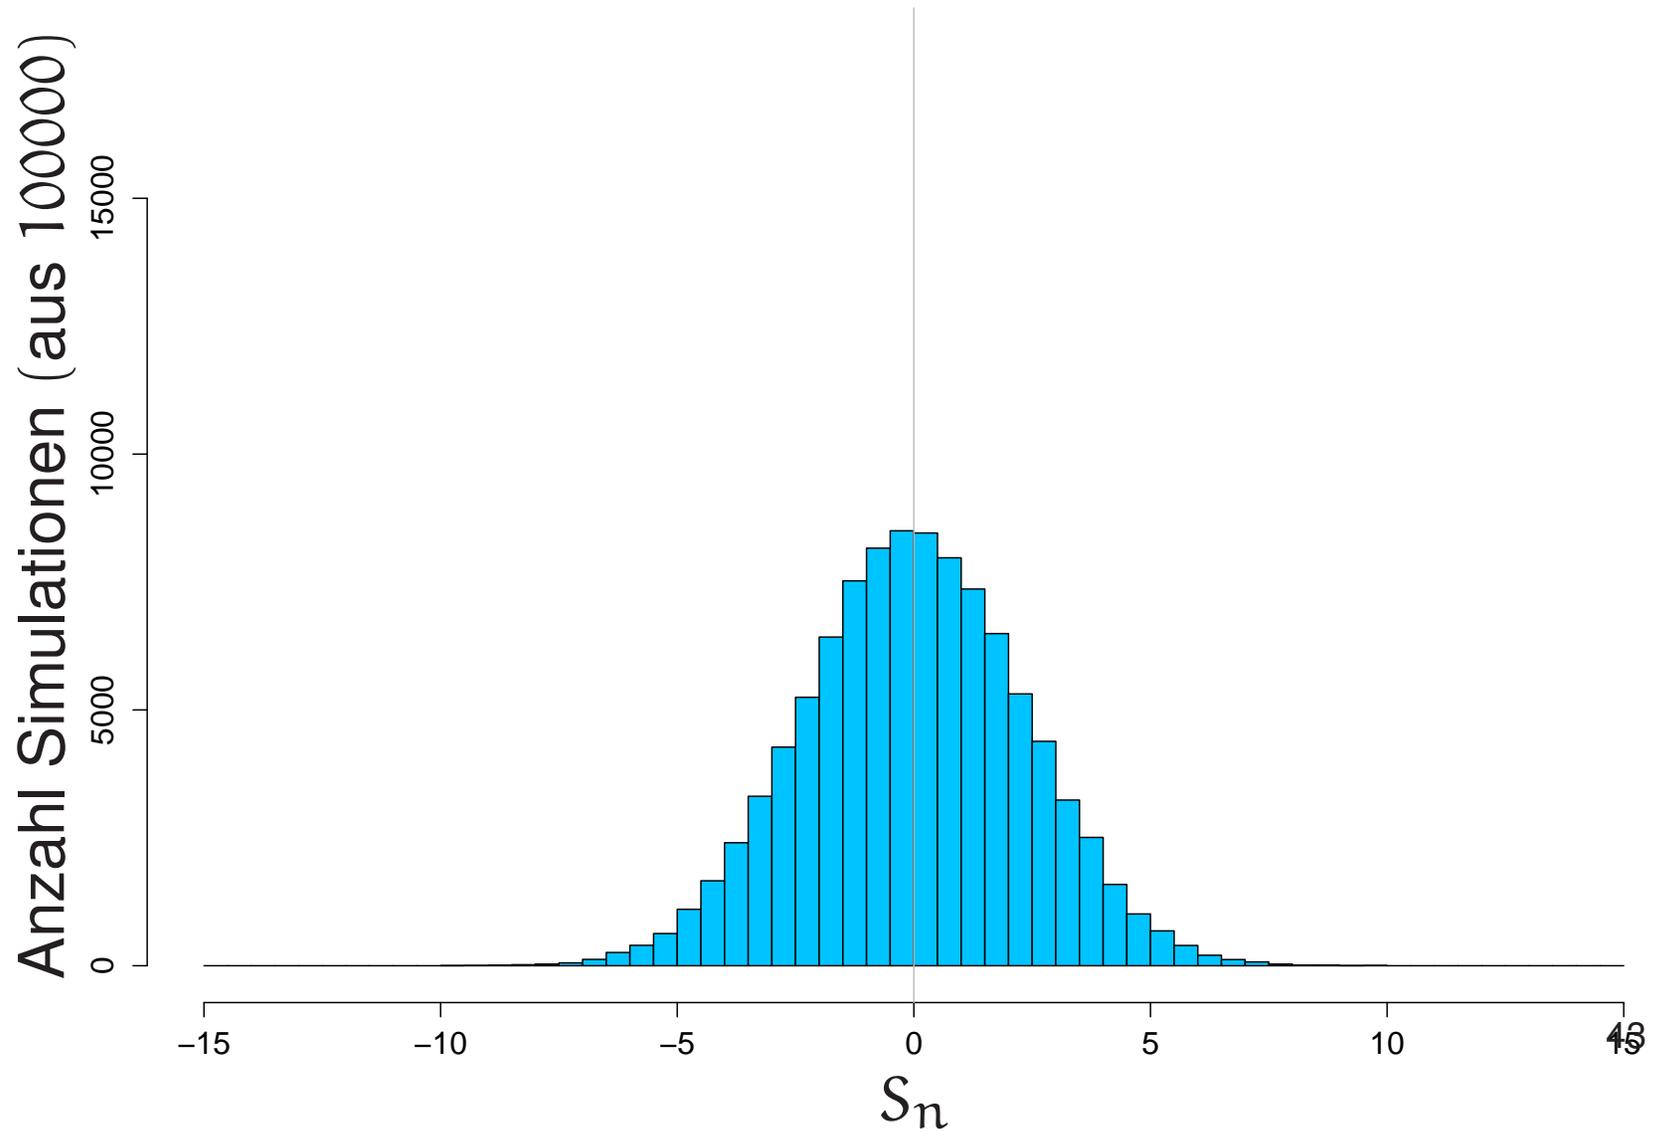
Verteilung von S_n ($n = 55$)



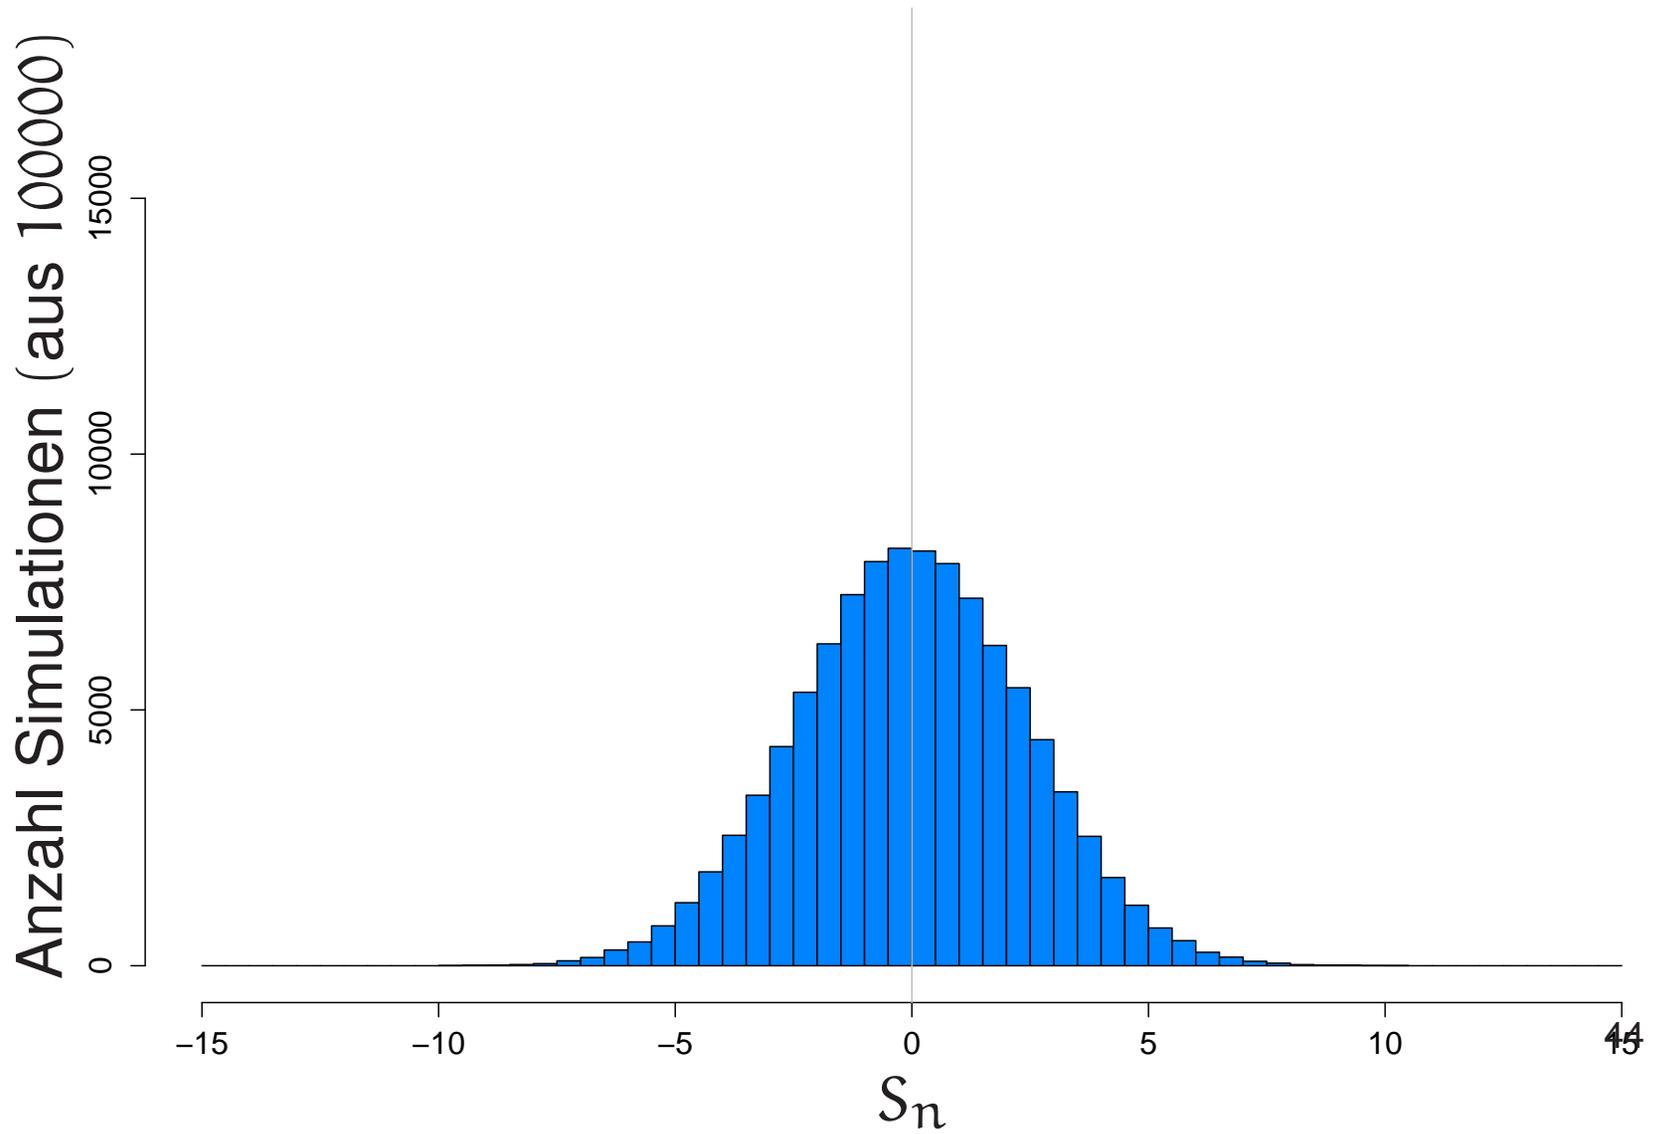
Verteilung von S_n ($n = 60$)



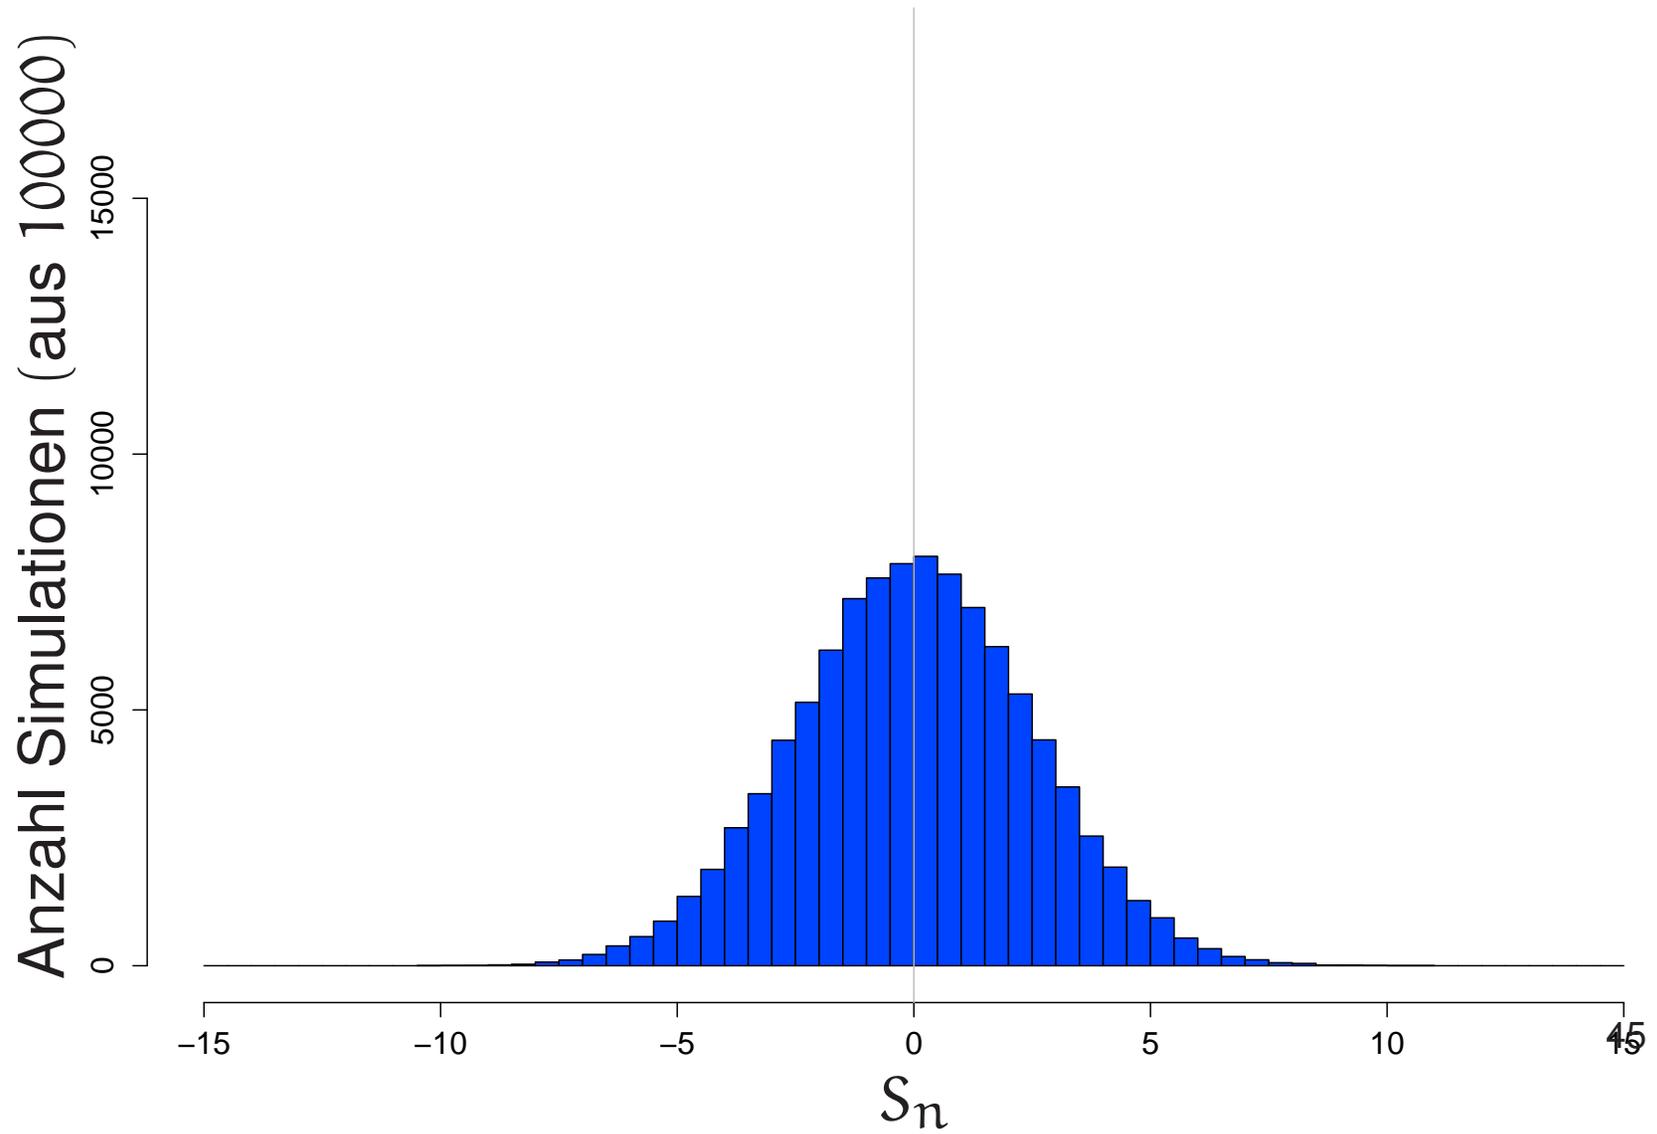
Verteilung von S_n ($n = 65$)



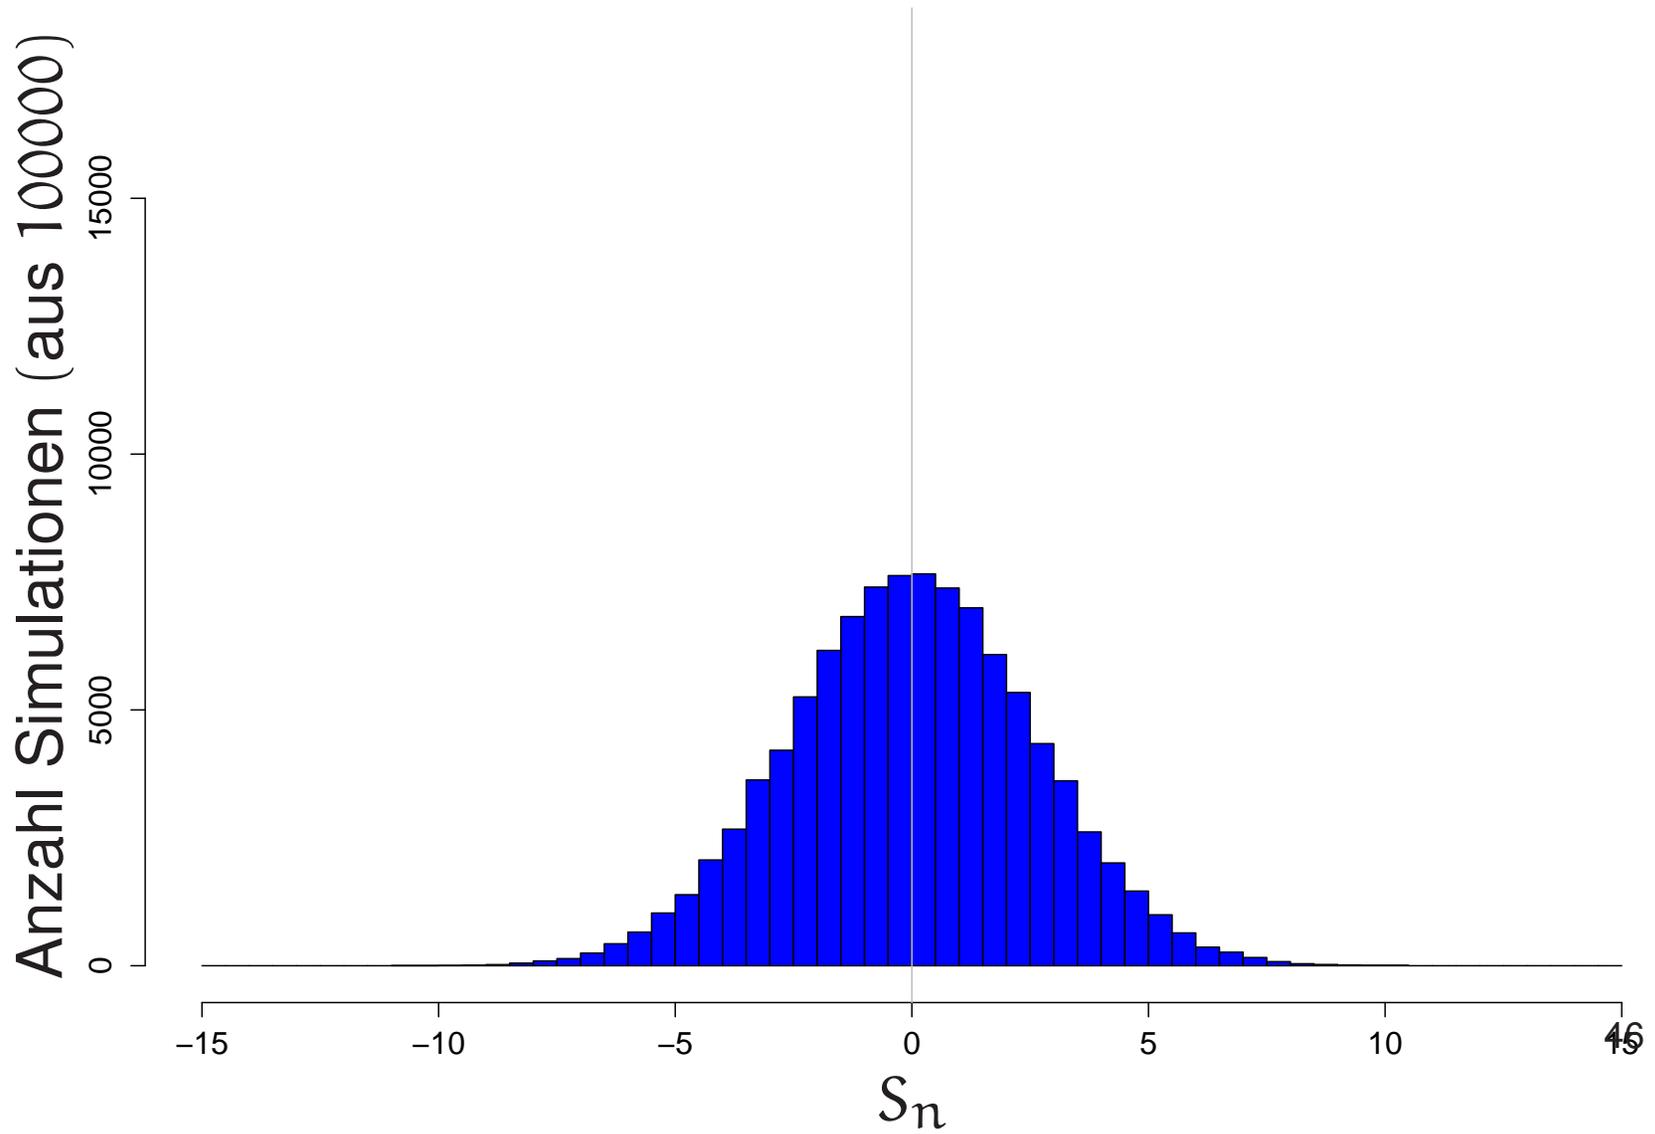
Verteilung von S_n ($n = 70$)



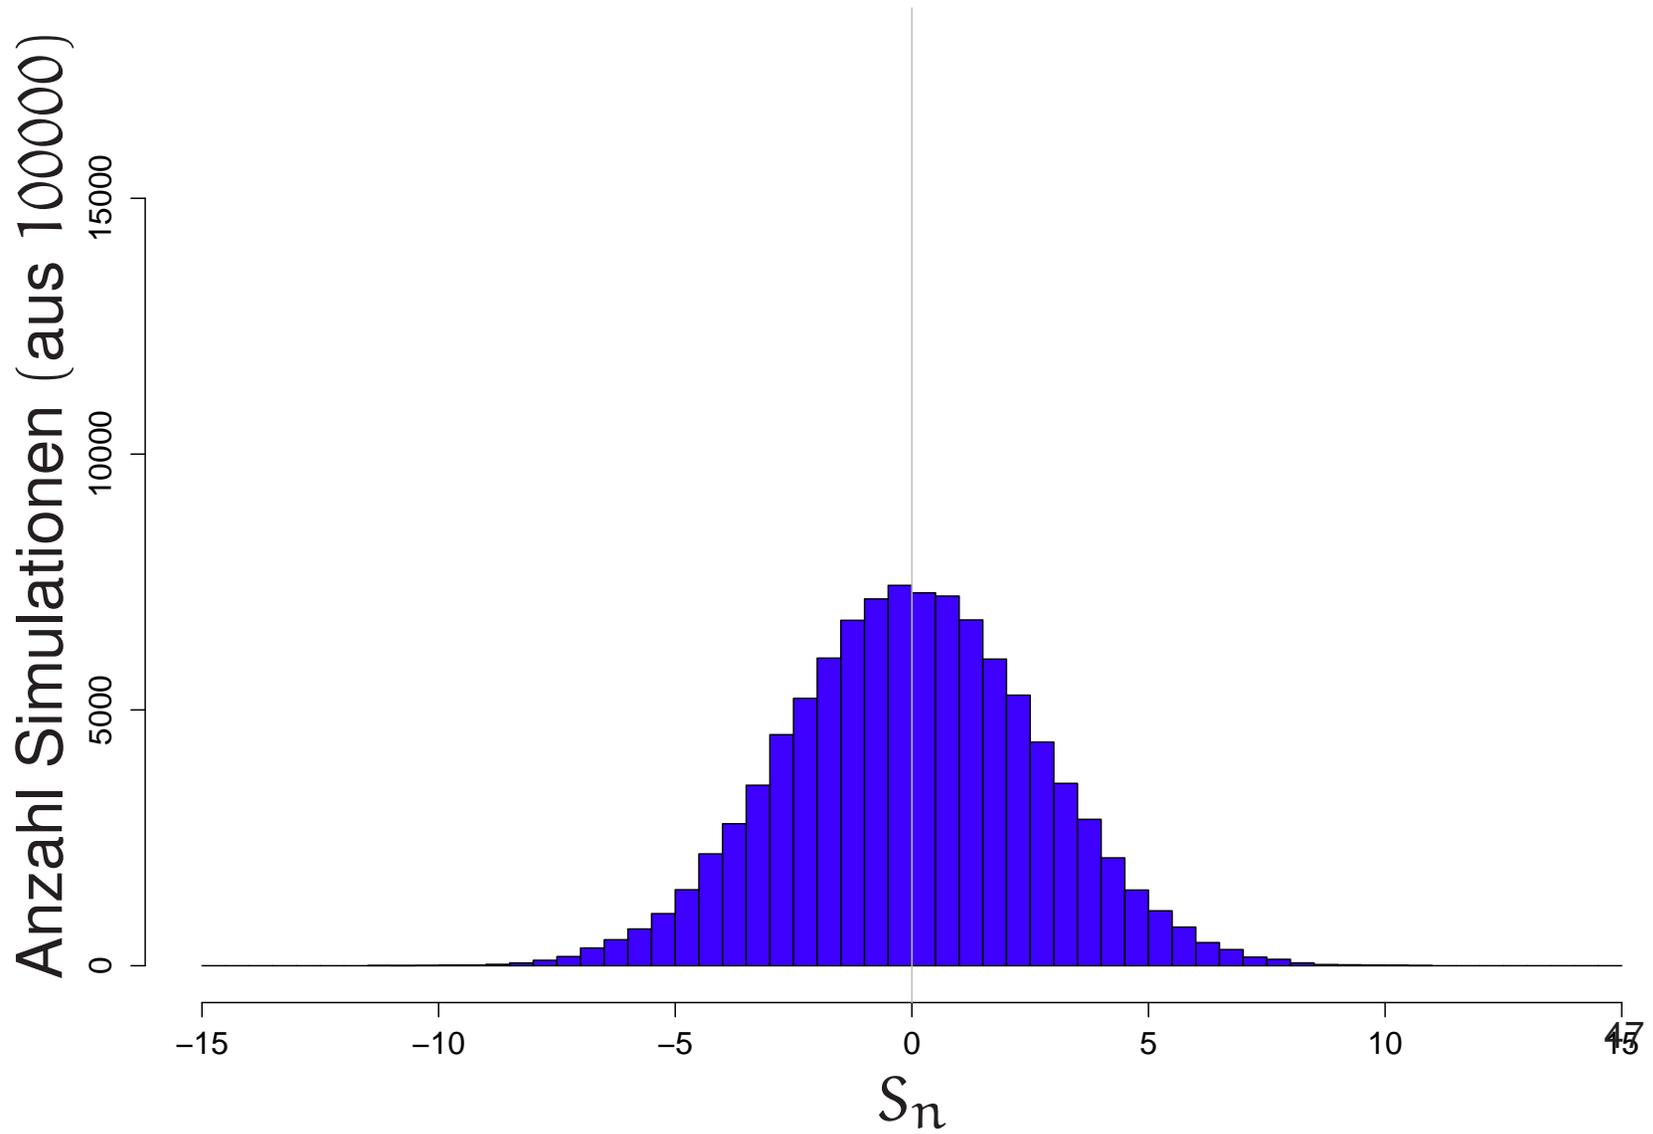
Verteilung von S_n ($n = 75$)



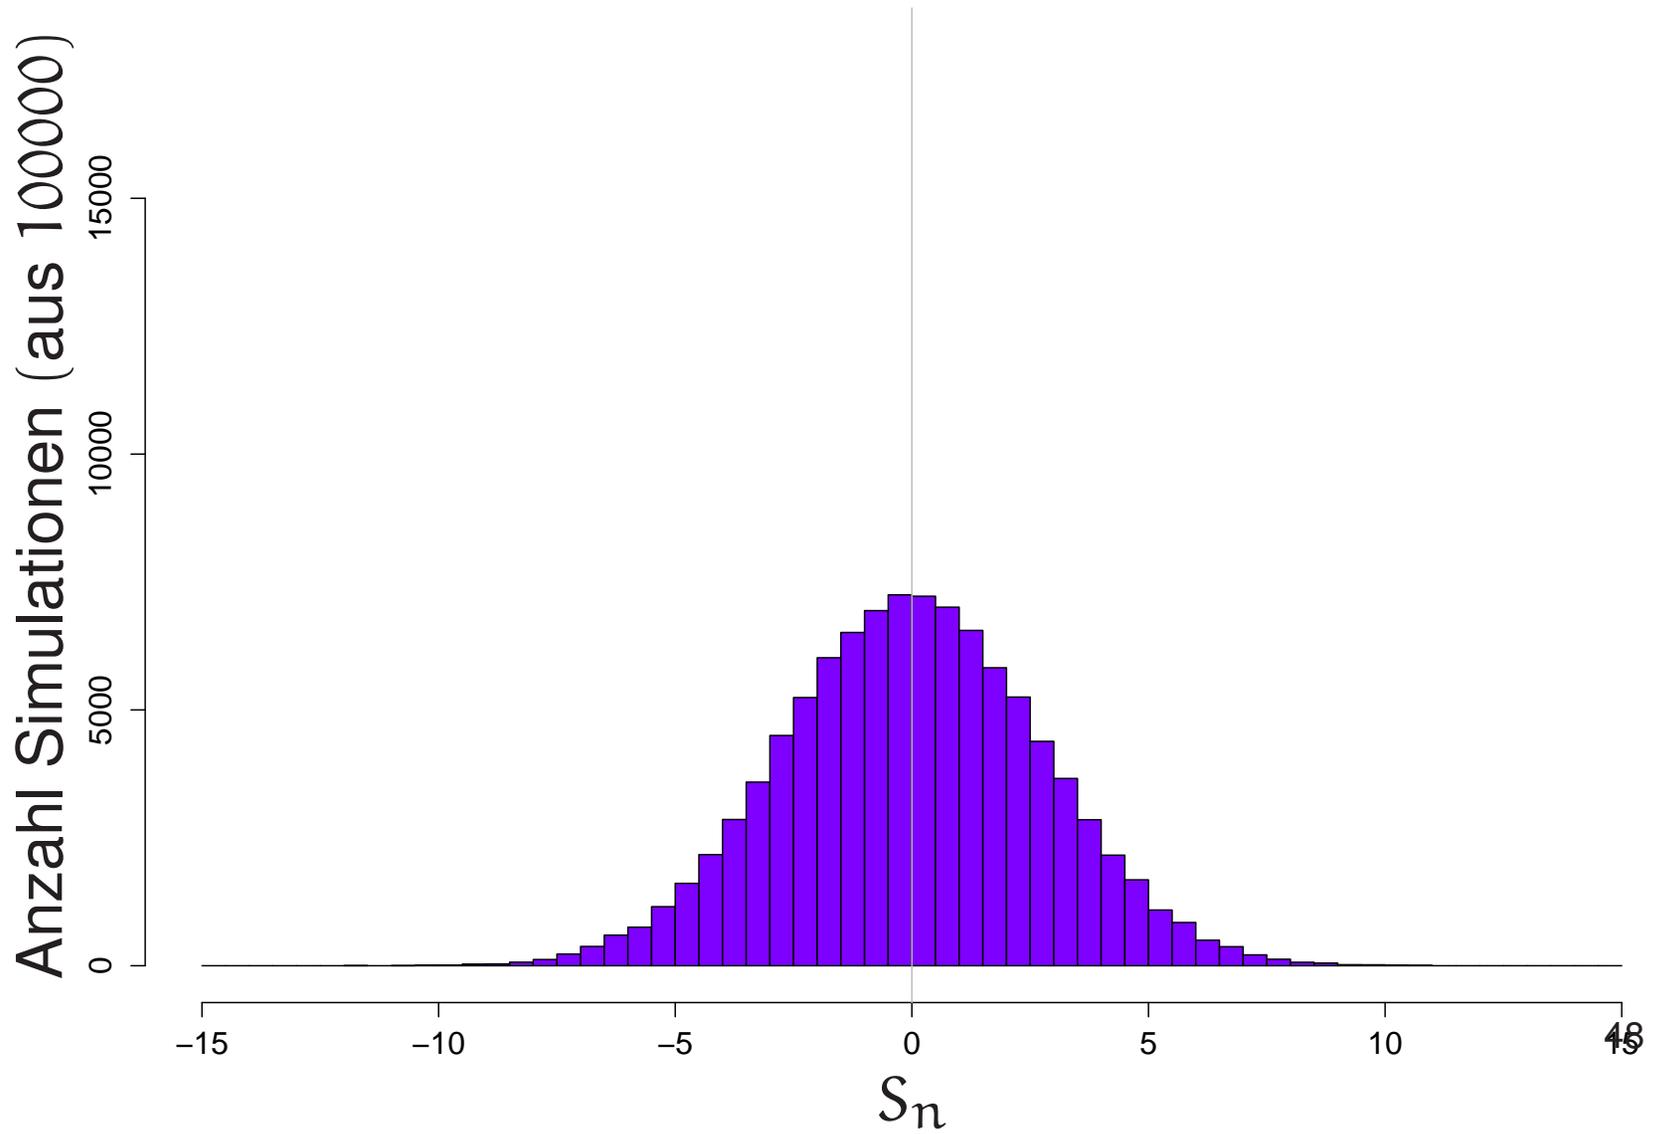
Verteilung von S_n ($n = 80$)



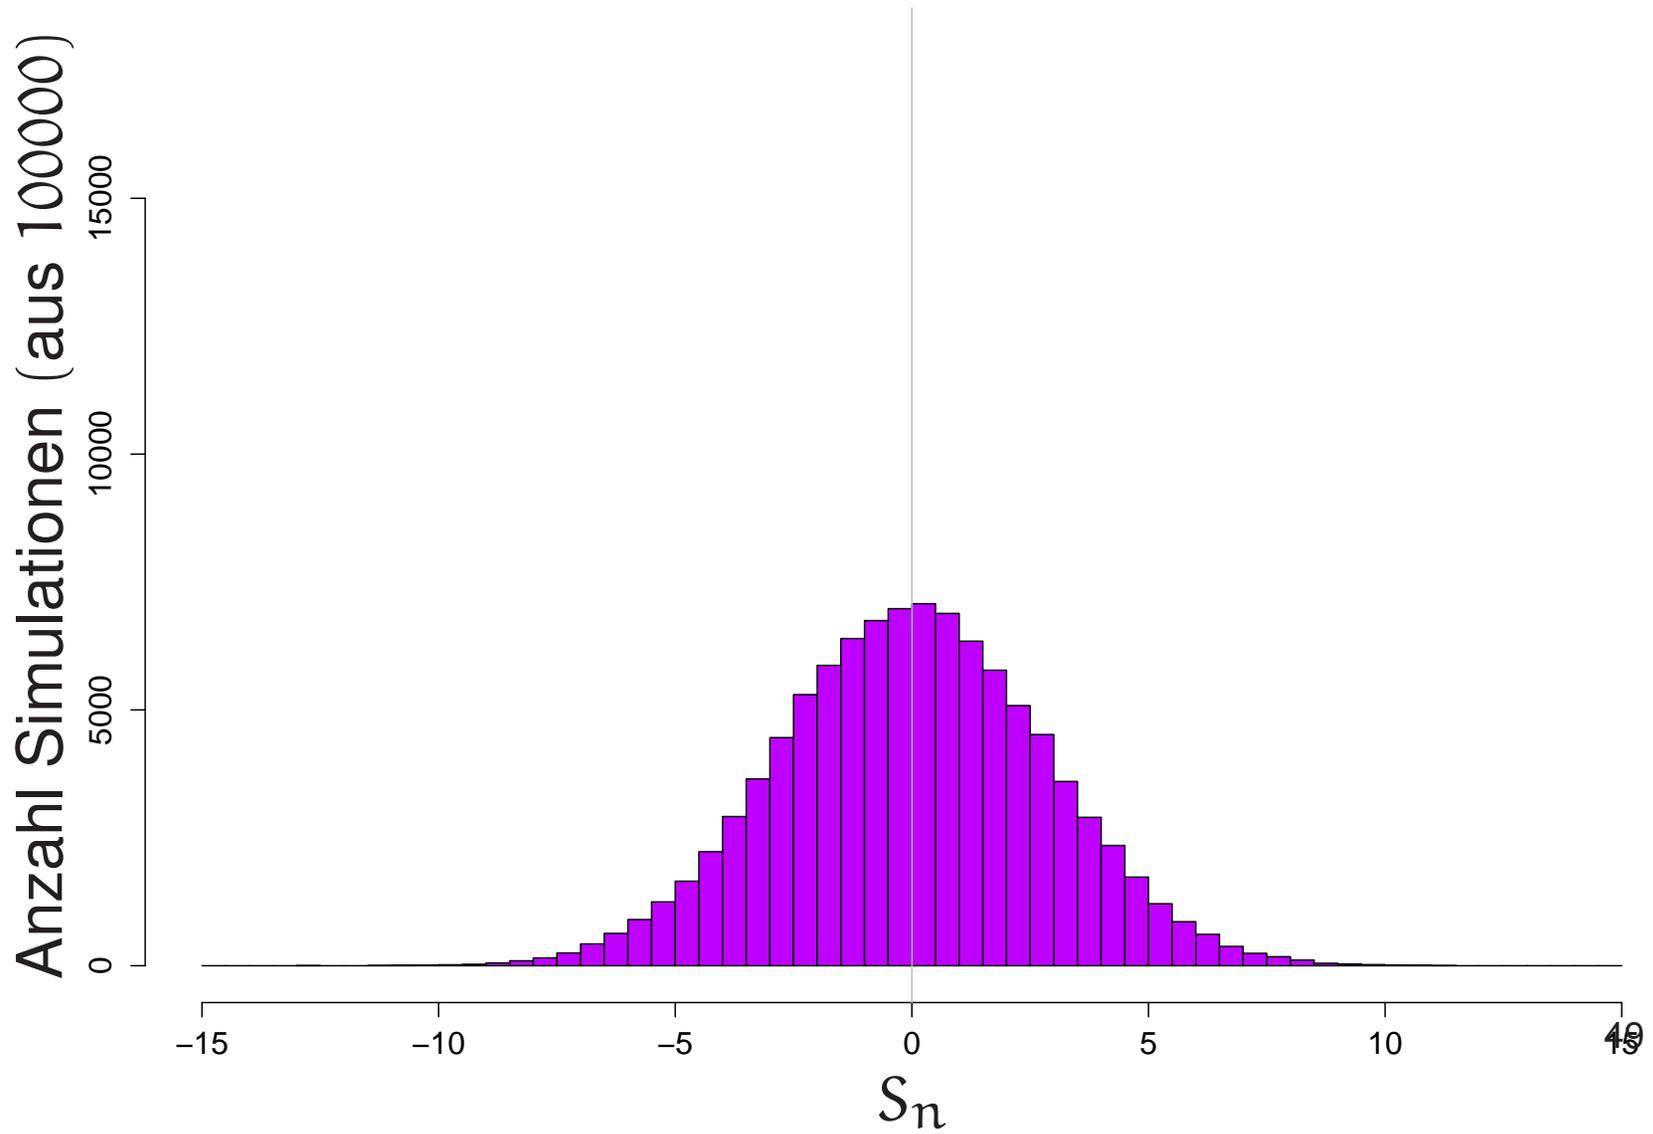
Verteilung von S_n ($n = 85$)



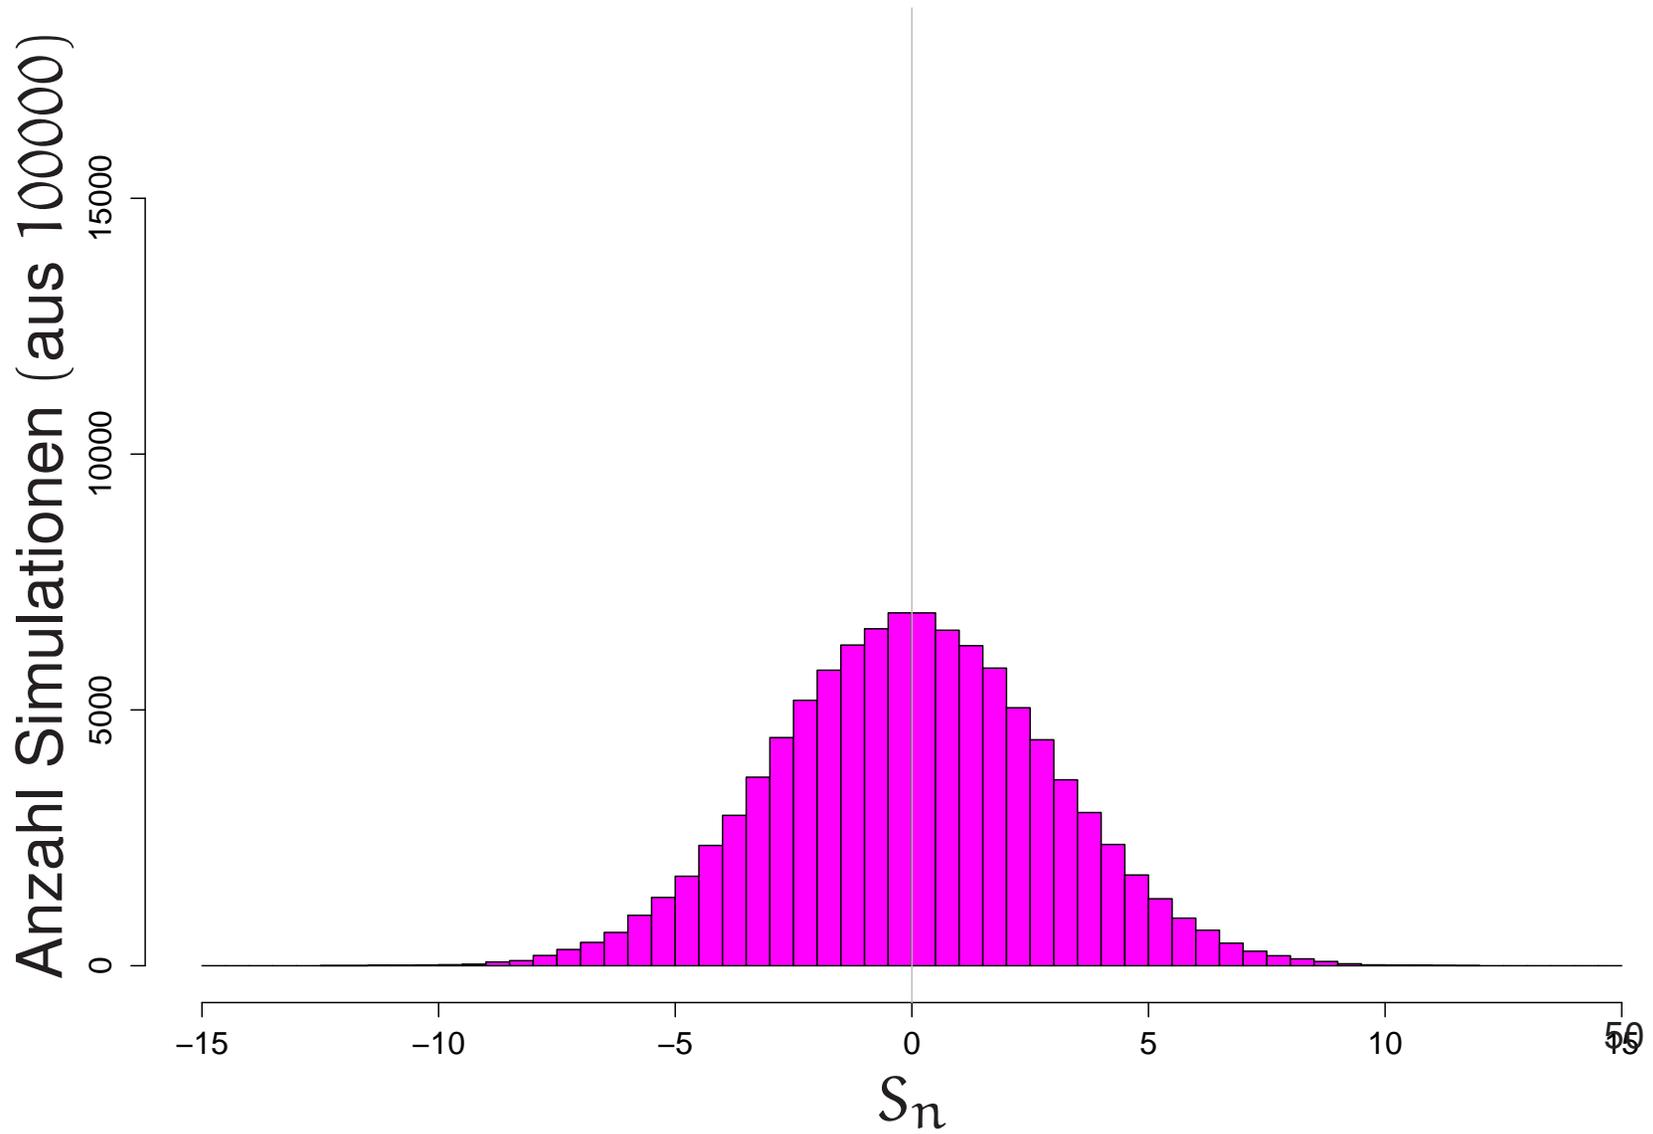
Verteilung von S_n ($n = 90$)



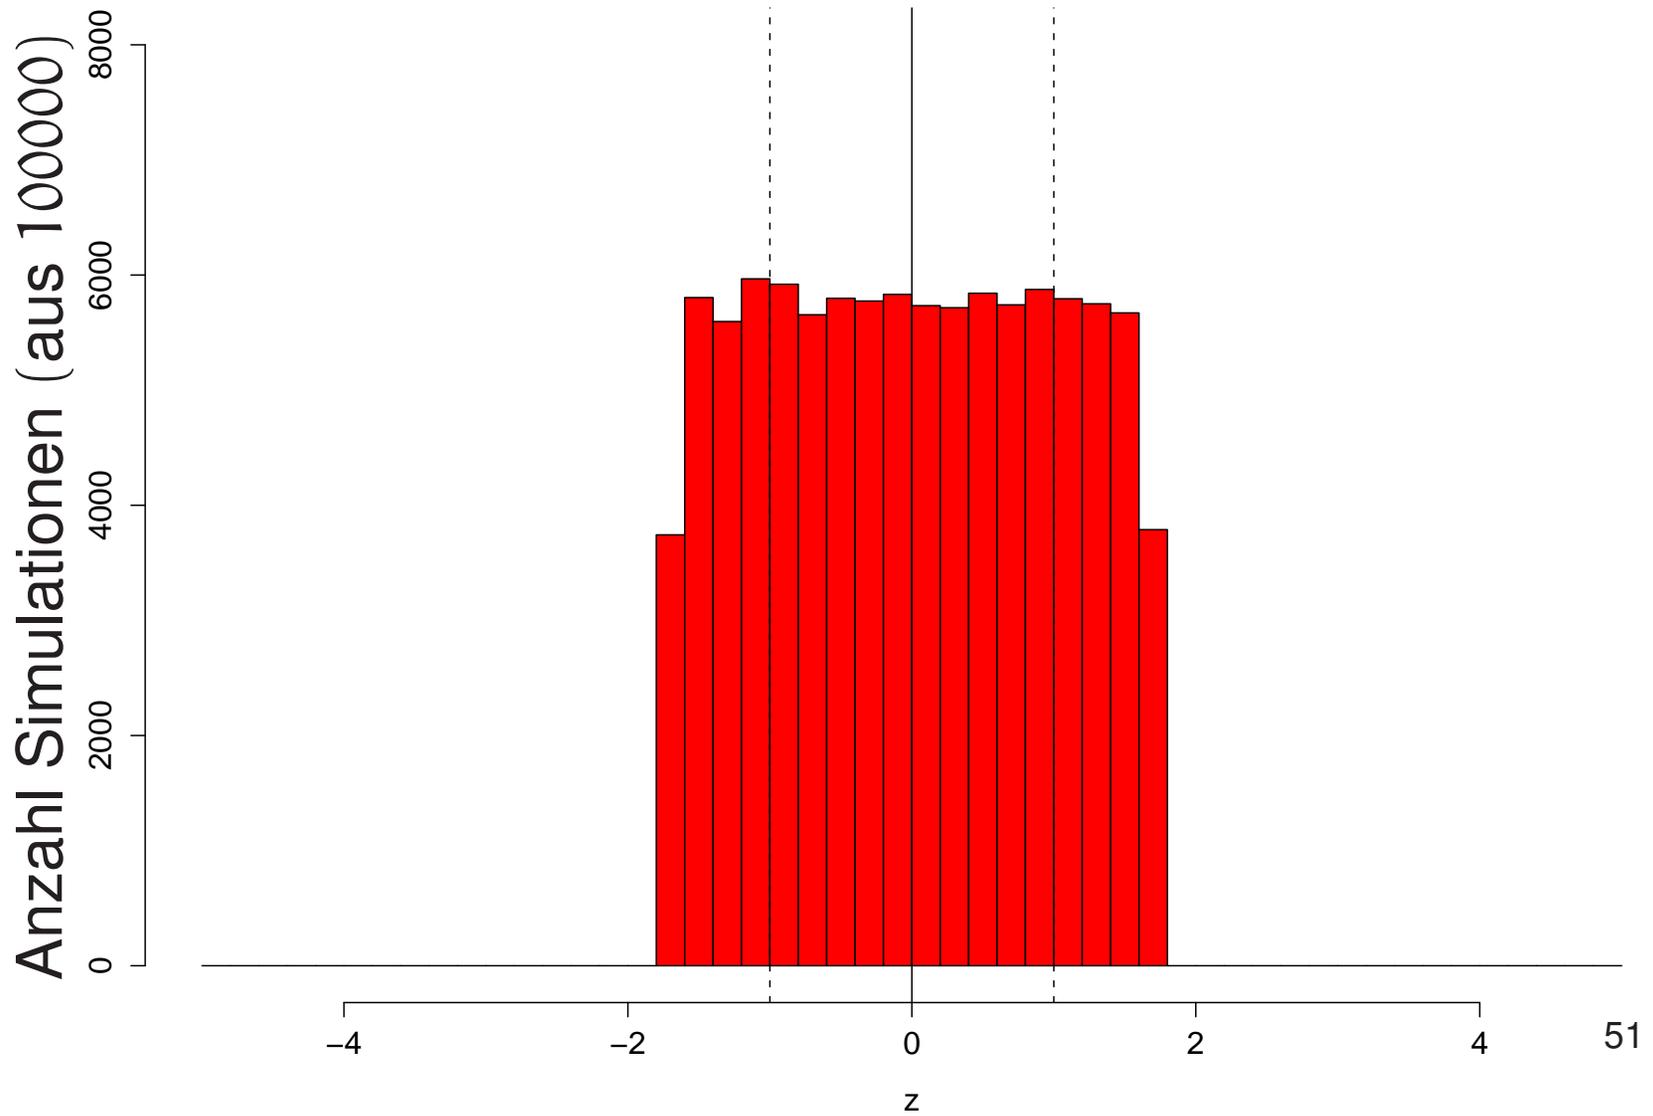
Verteilung von S_n ($n = 95$)



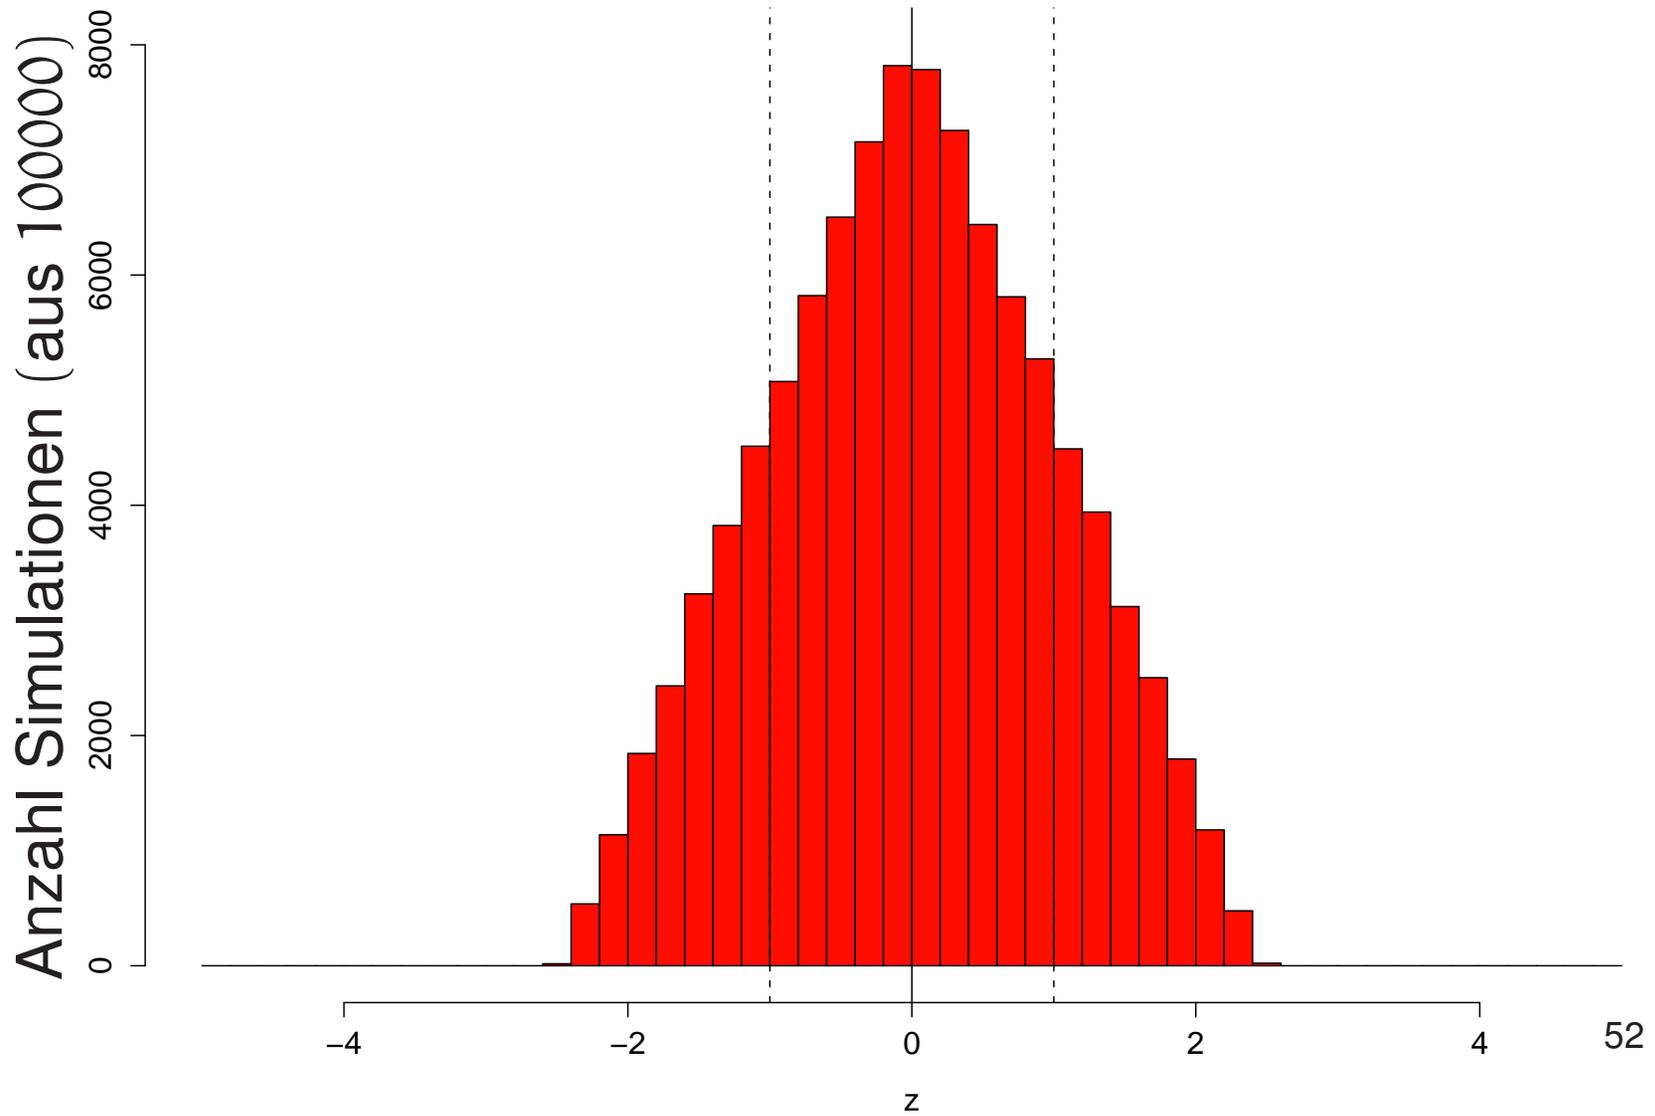
Verteilung von S_n ($n = 100$)



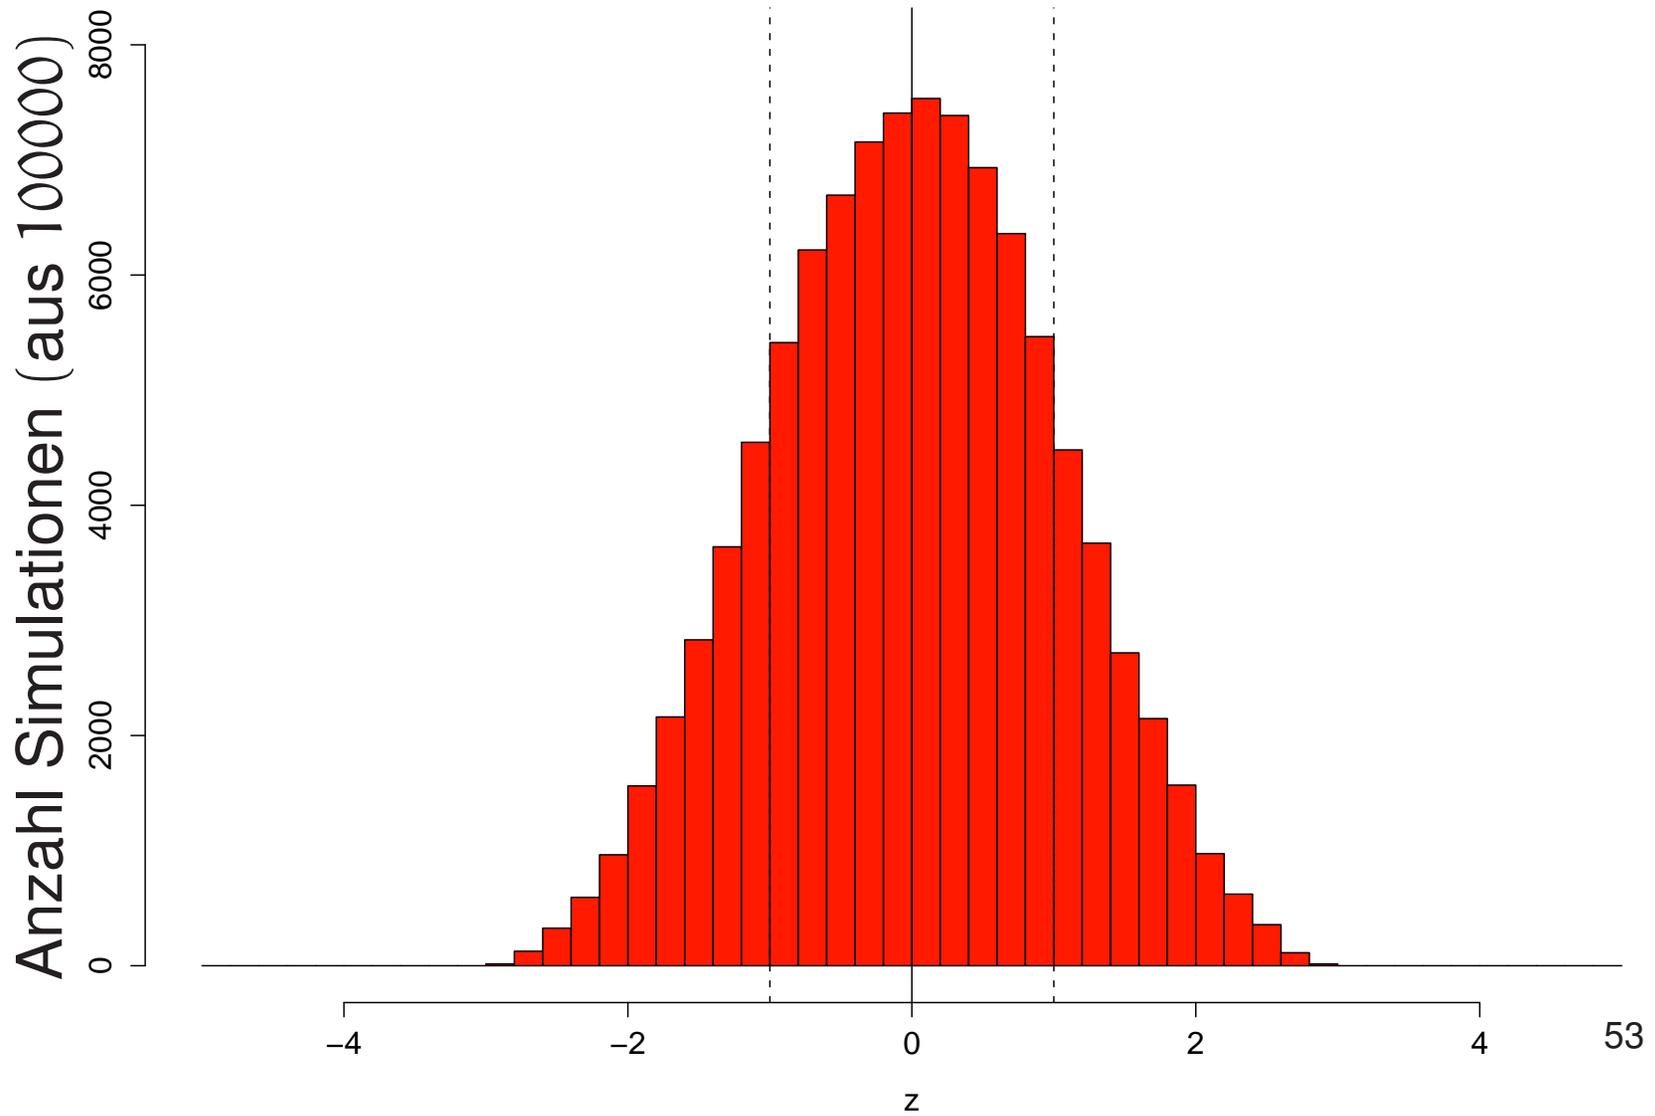
Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n} \quad (n = 1)$



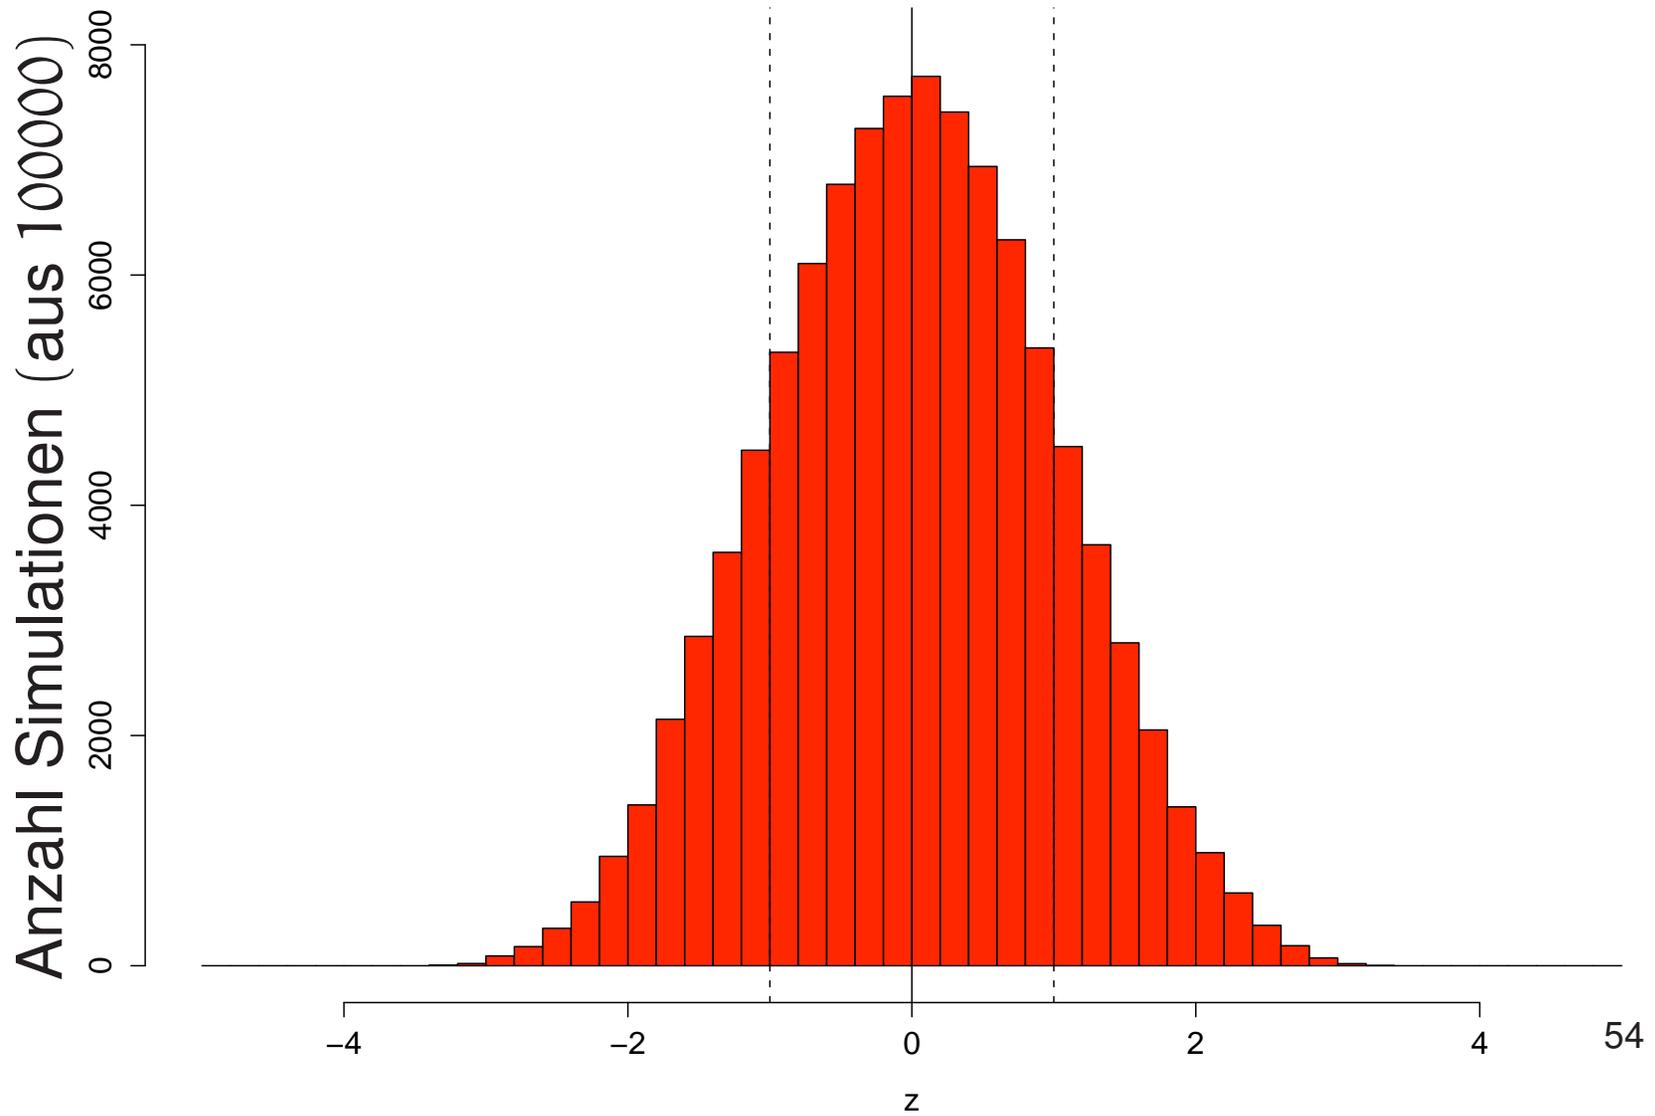
Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n} \quad (n = 2)$



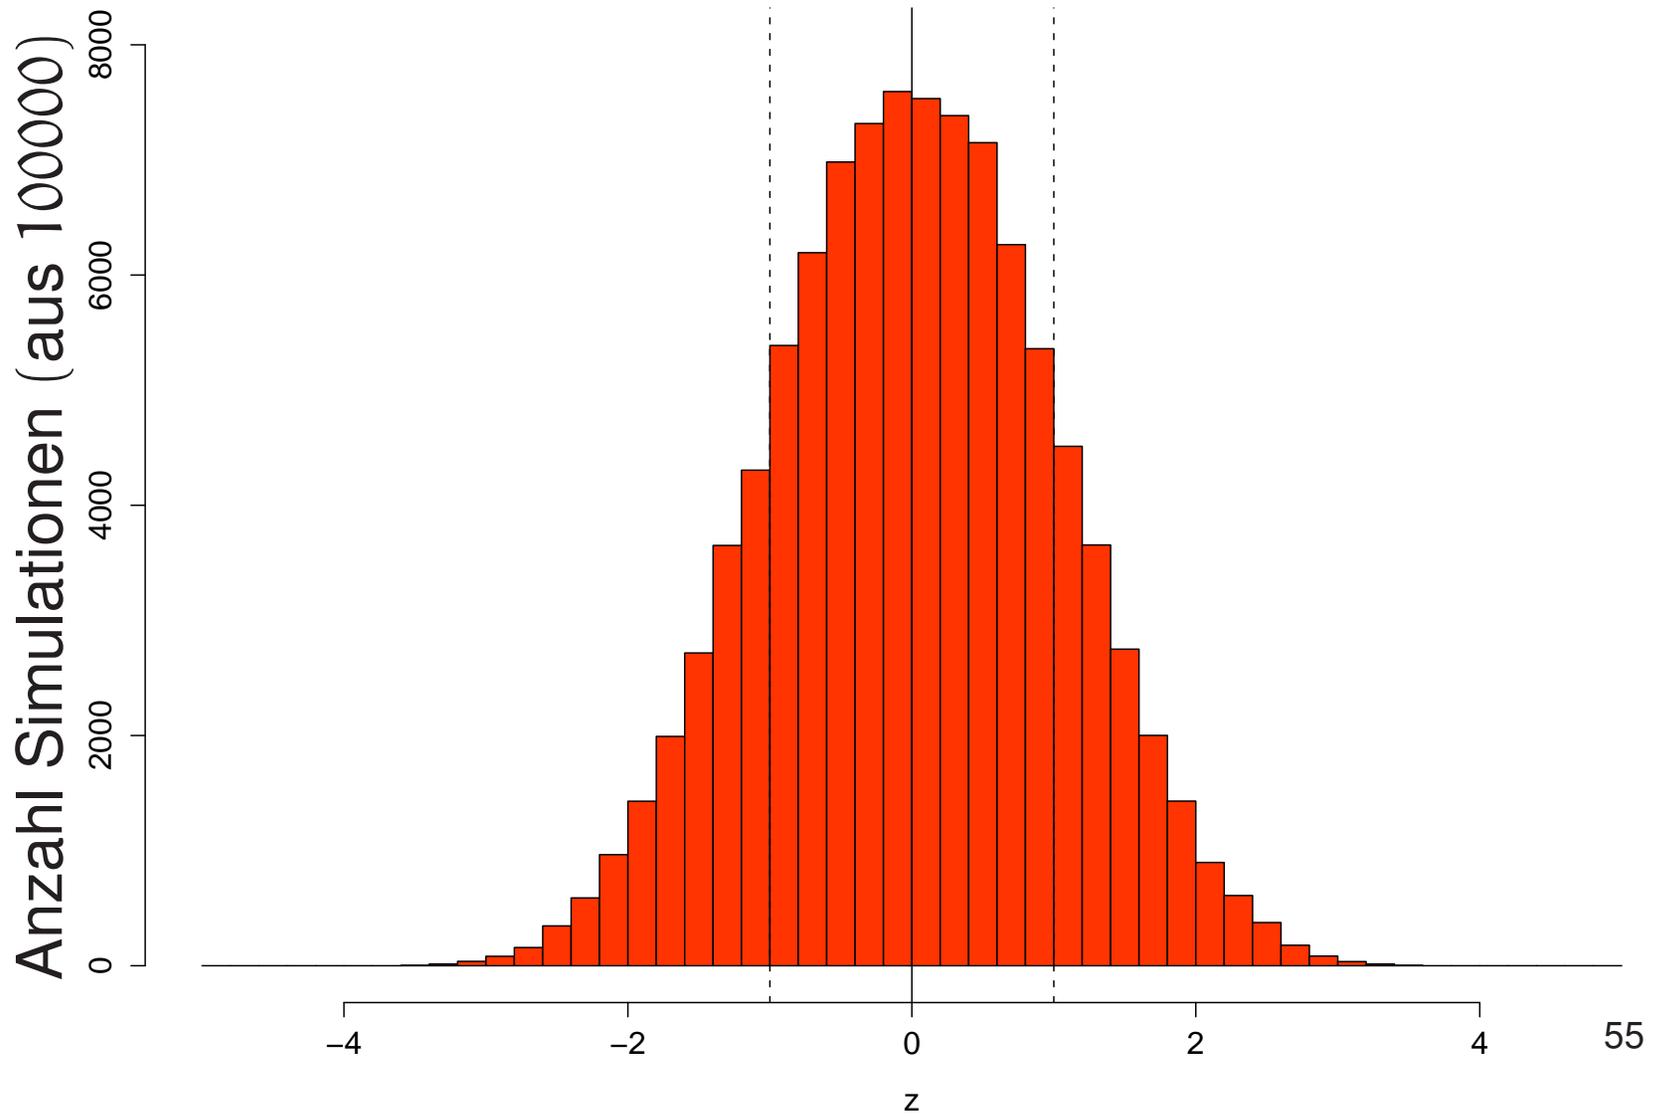
Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n} \quad (n = 3)$



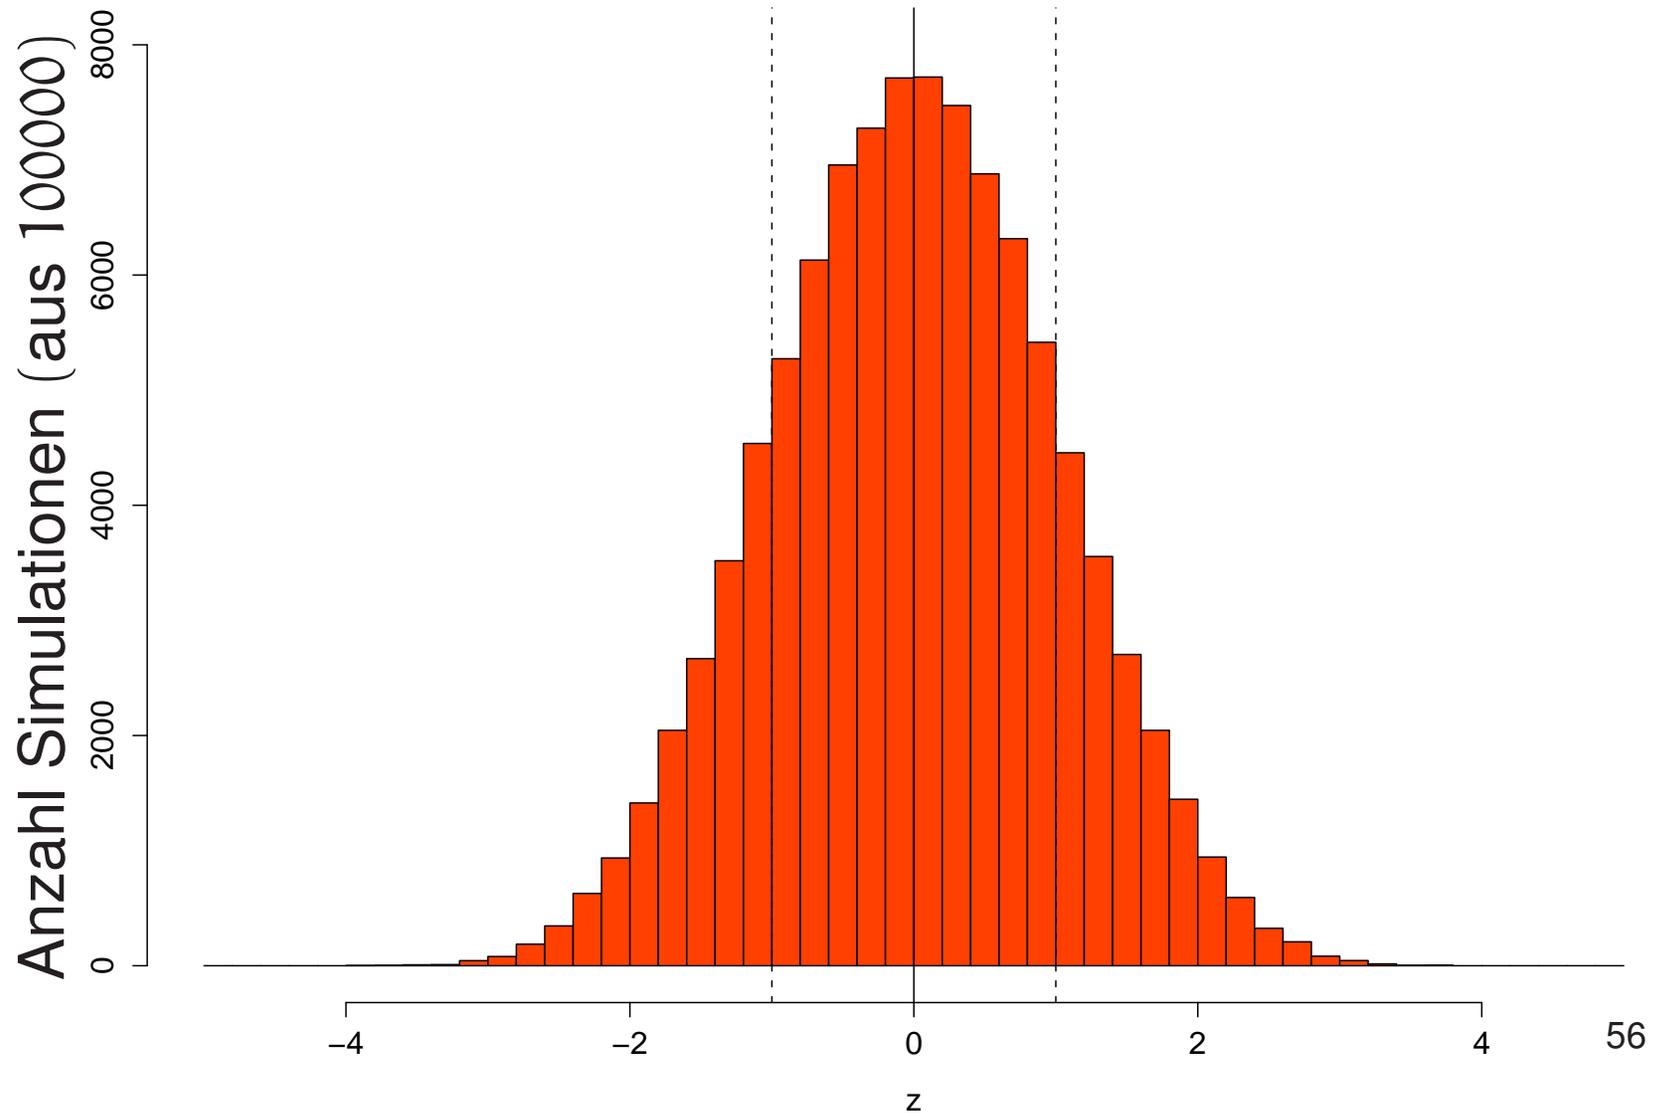
Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n} \quad (n = 4)$



Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n} \quad (n = 5)$

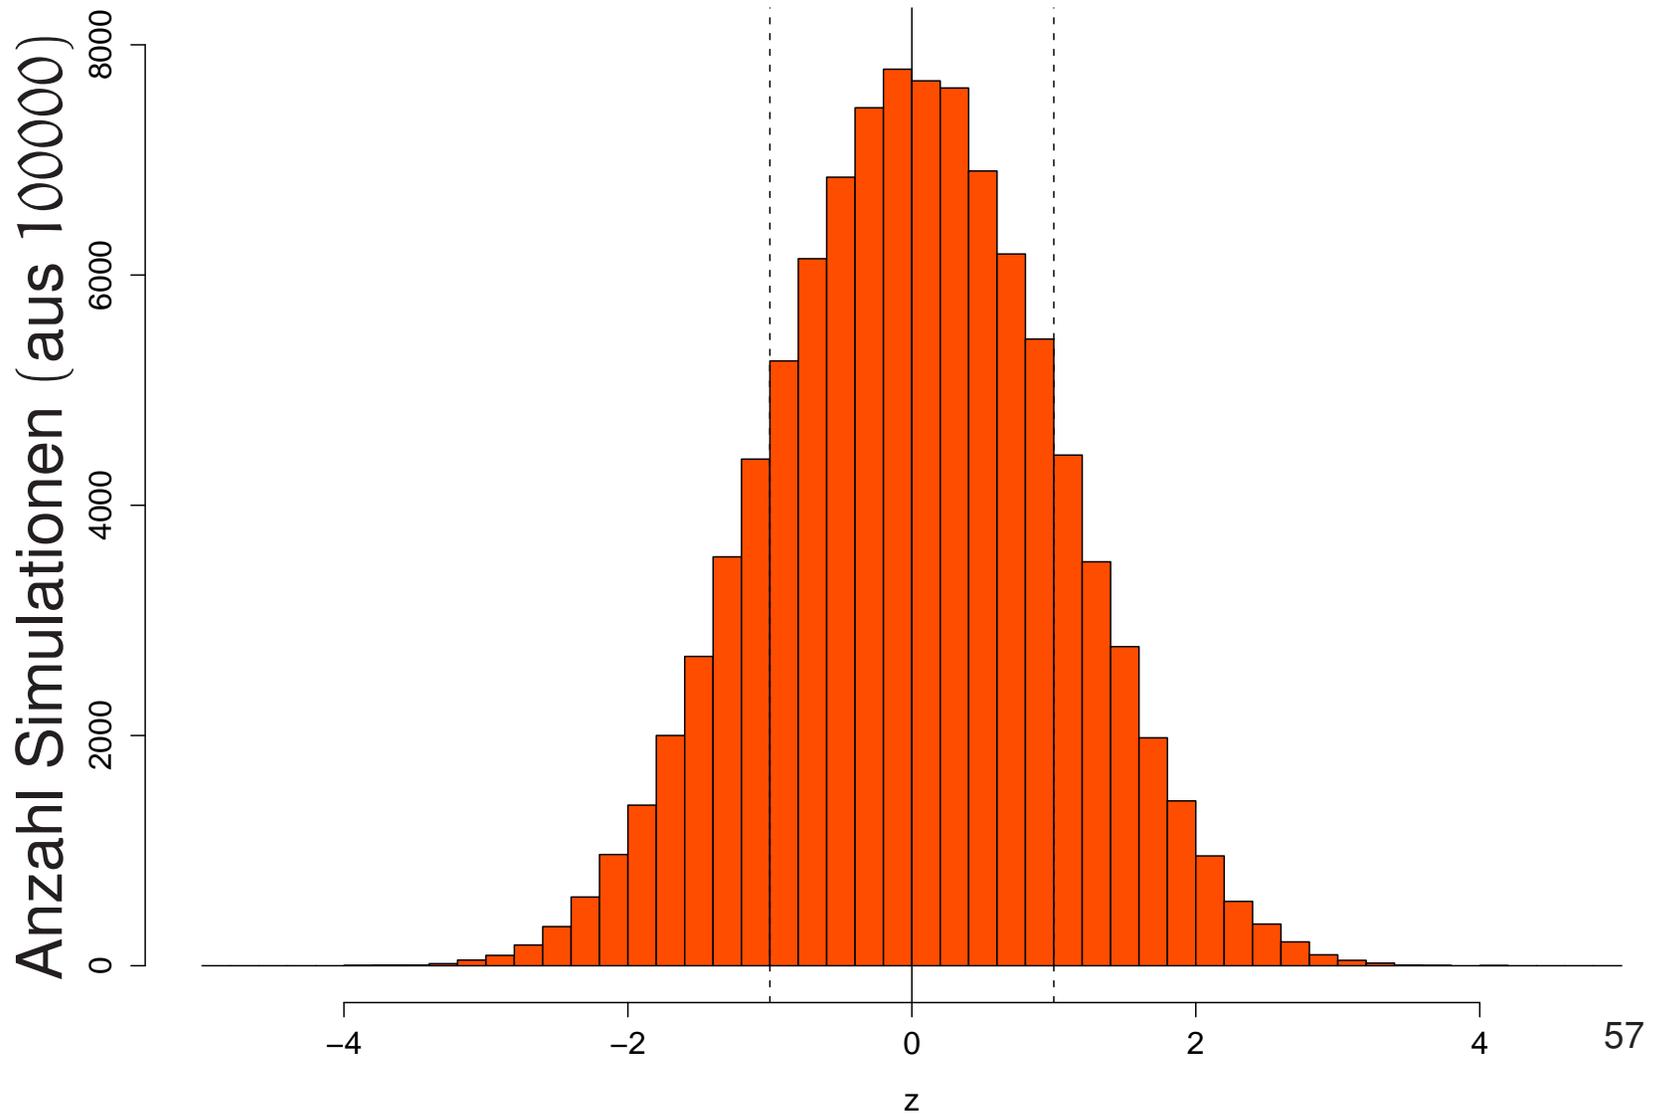


Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n} \quad (n = 6)$

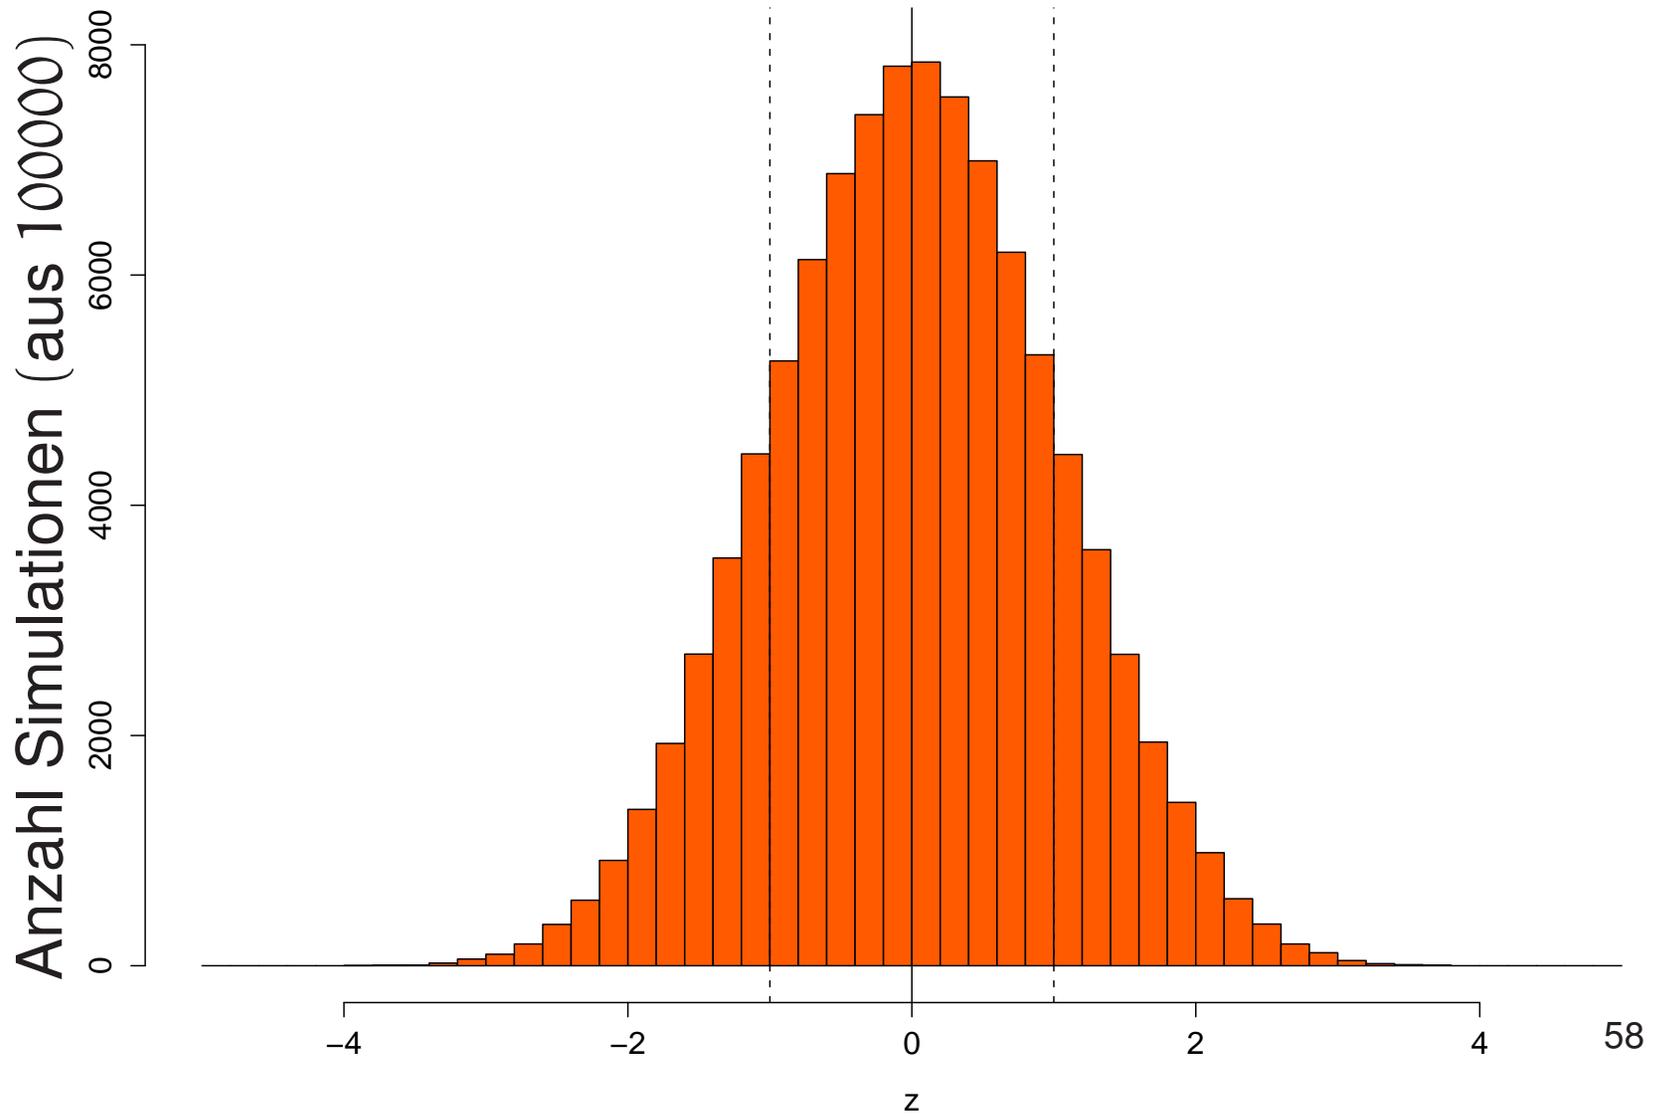


Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 7)$$

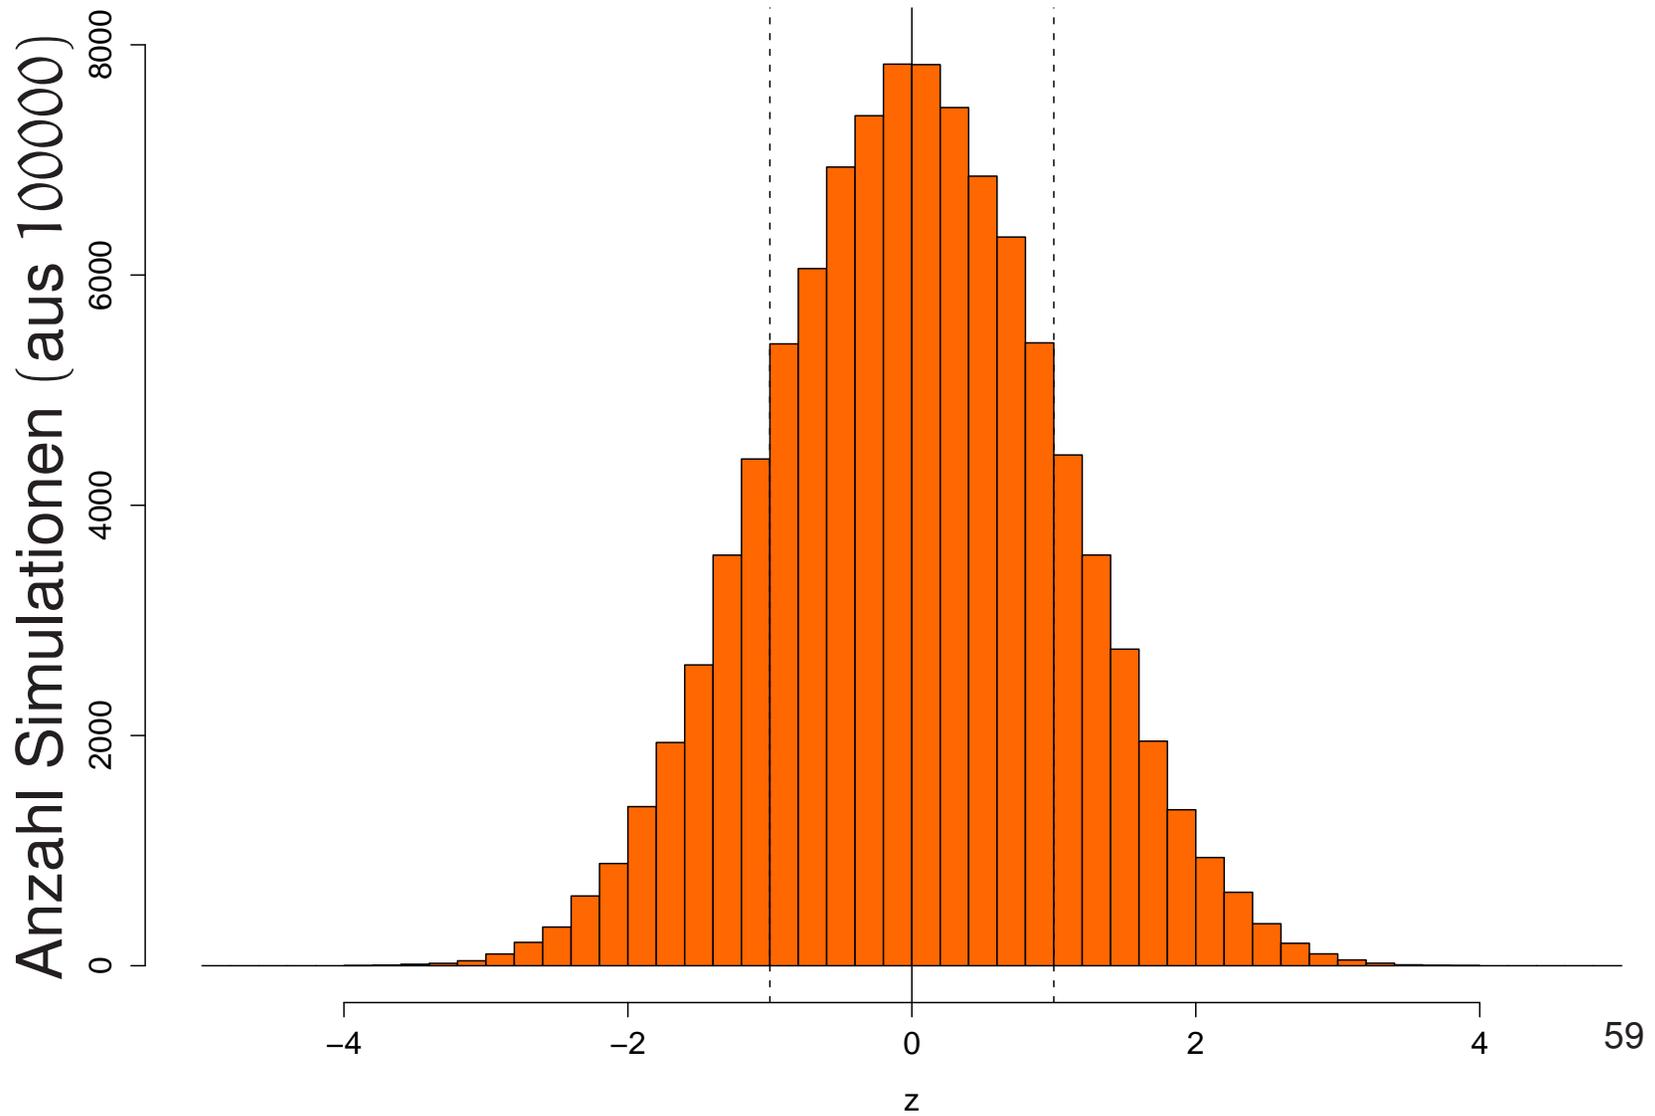


Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n} \quad (n = 8)$



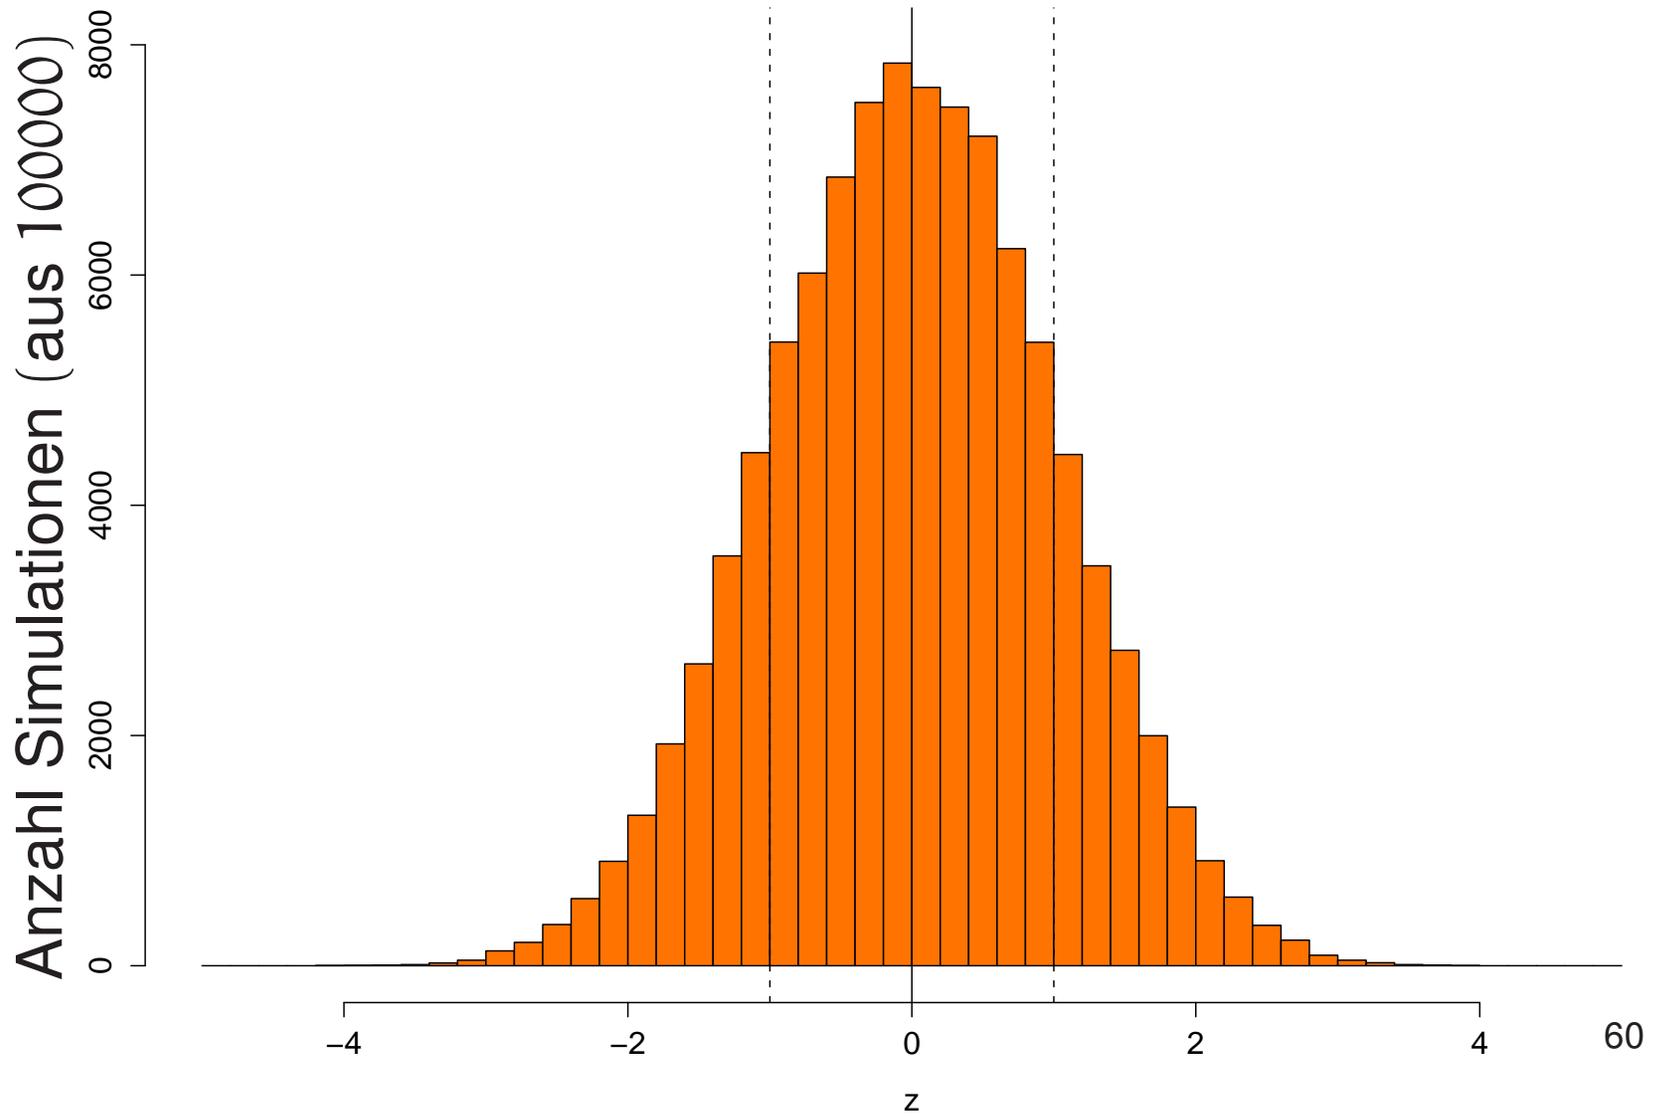
Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 9)$$



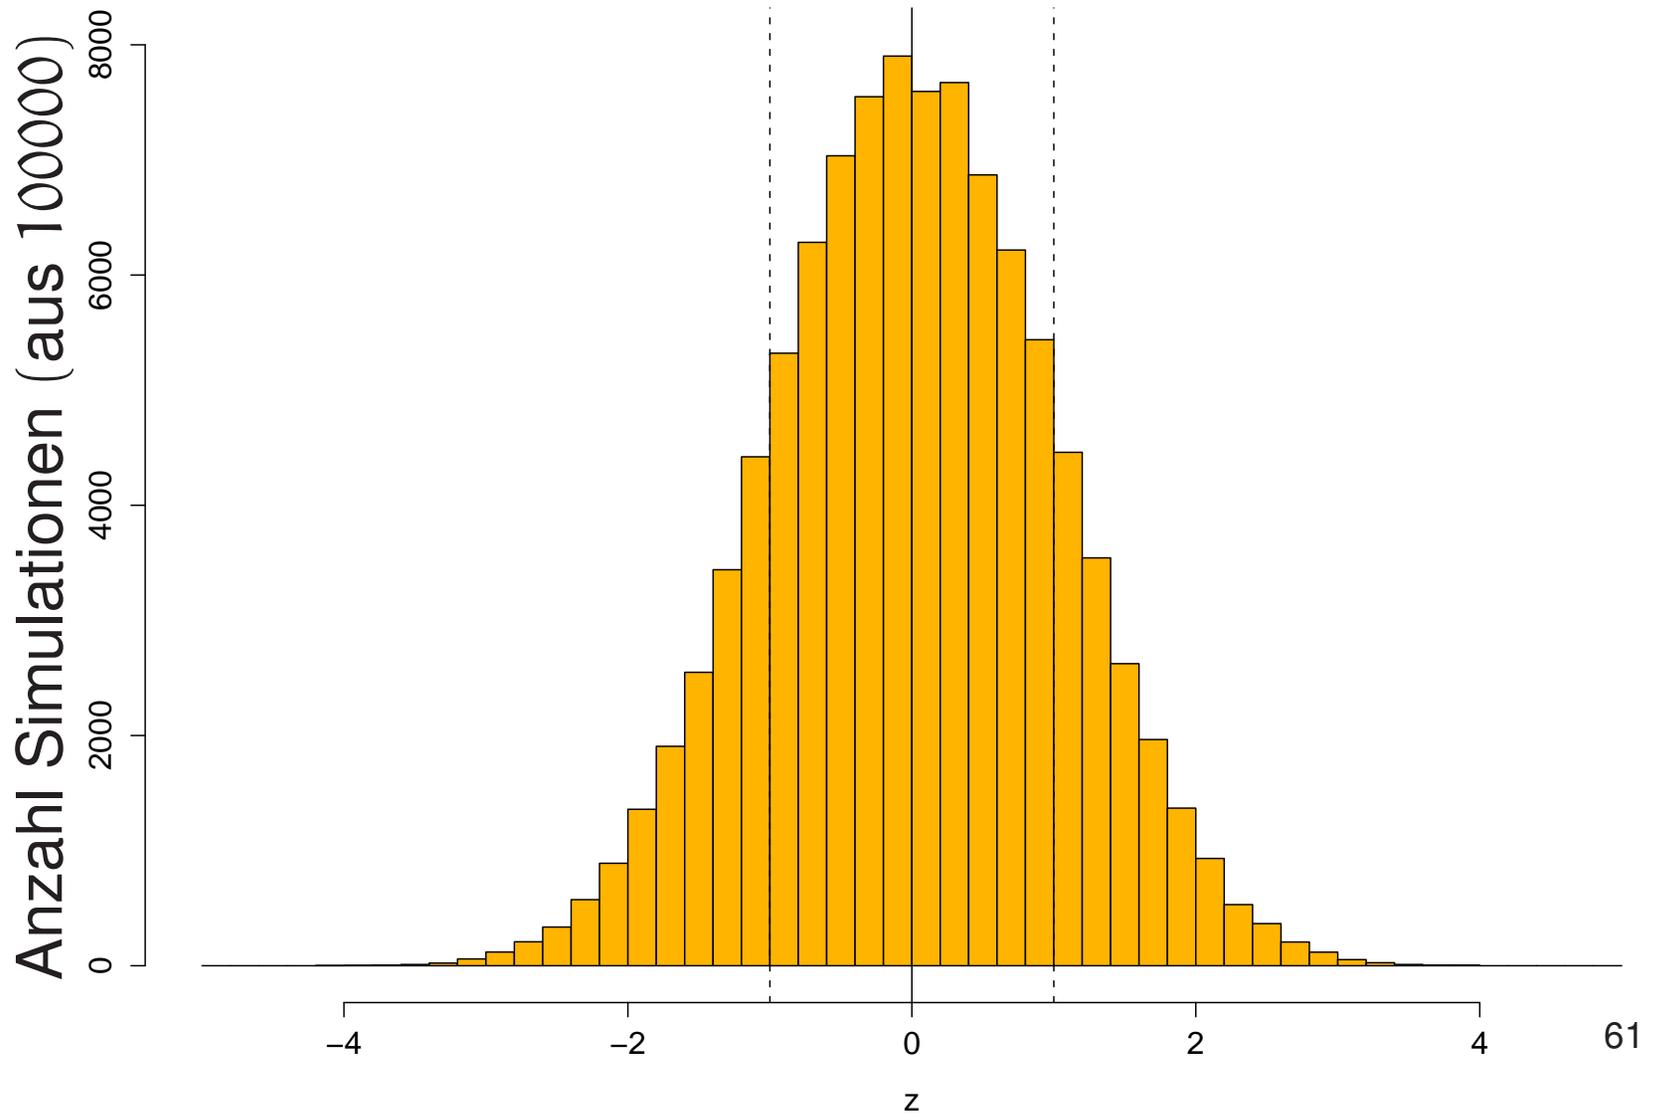
Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 10)$$

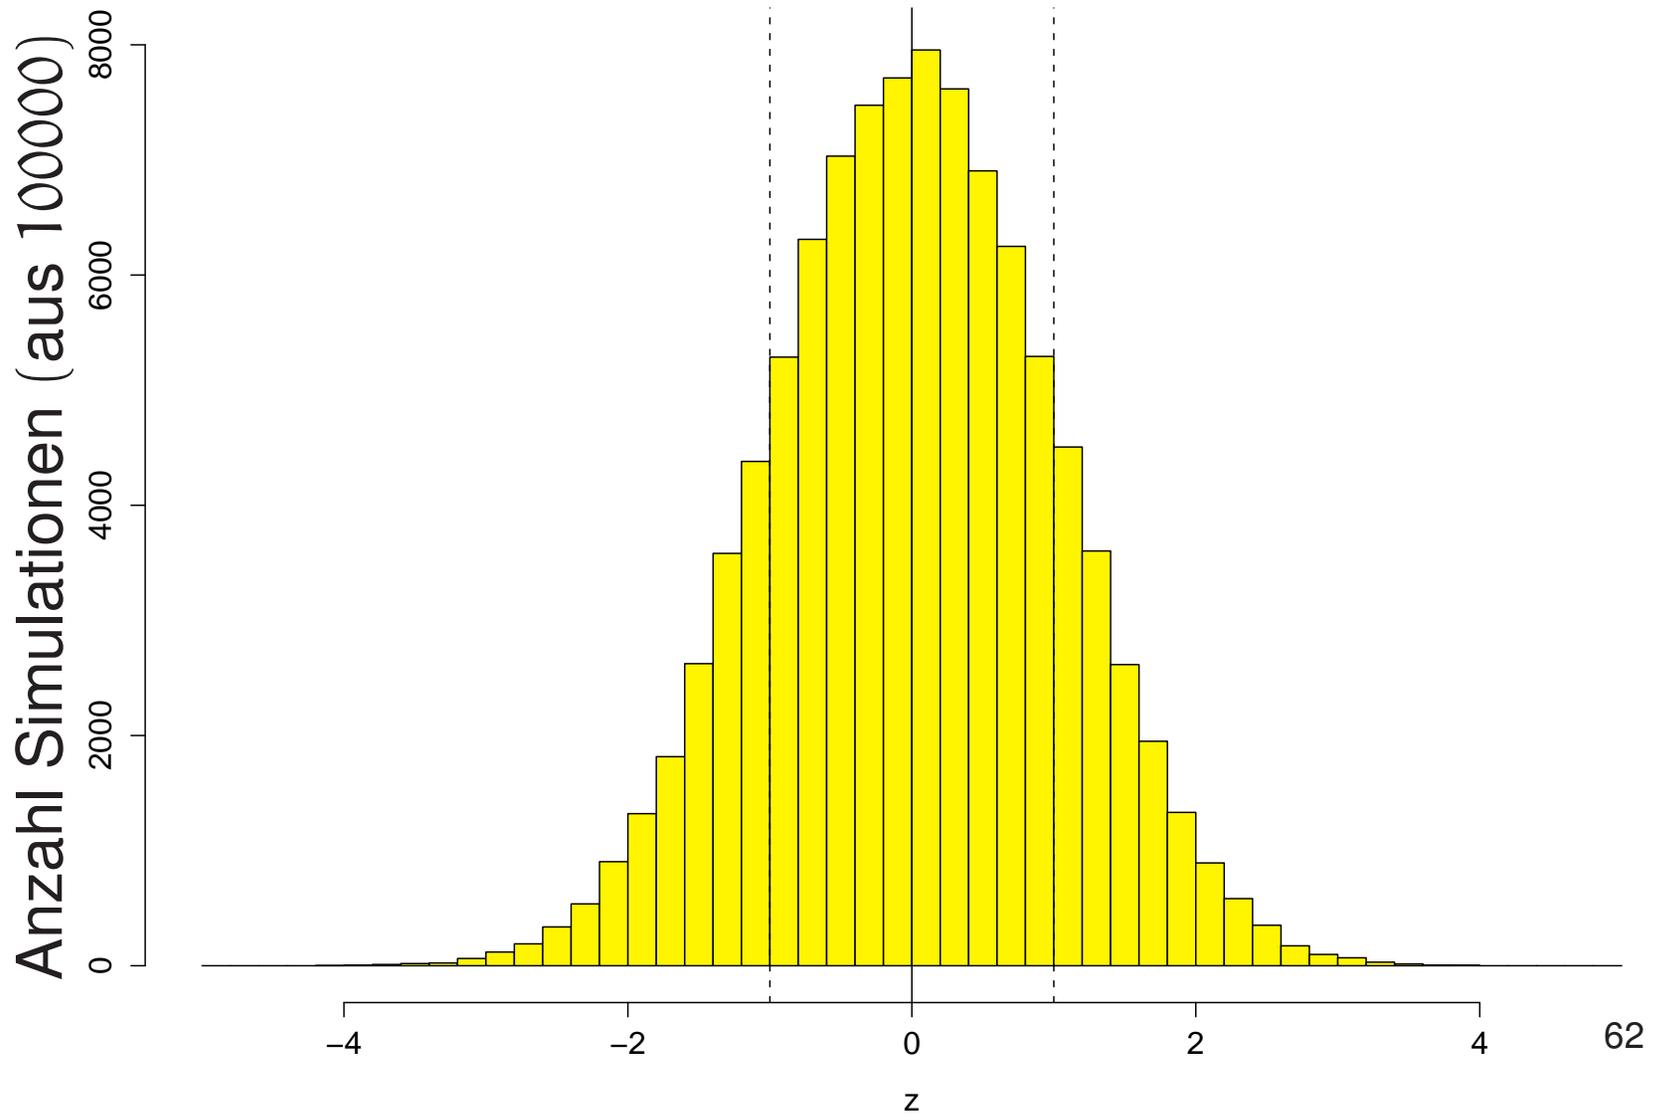


Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 15)$$

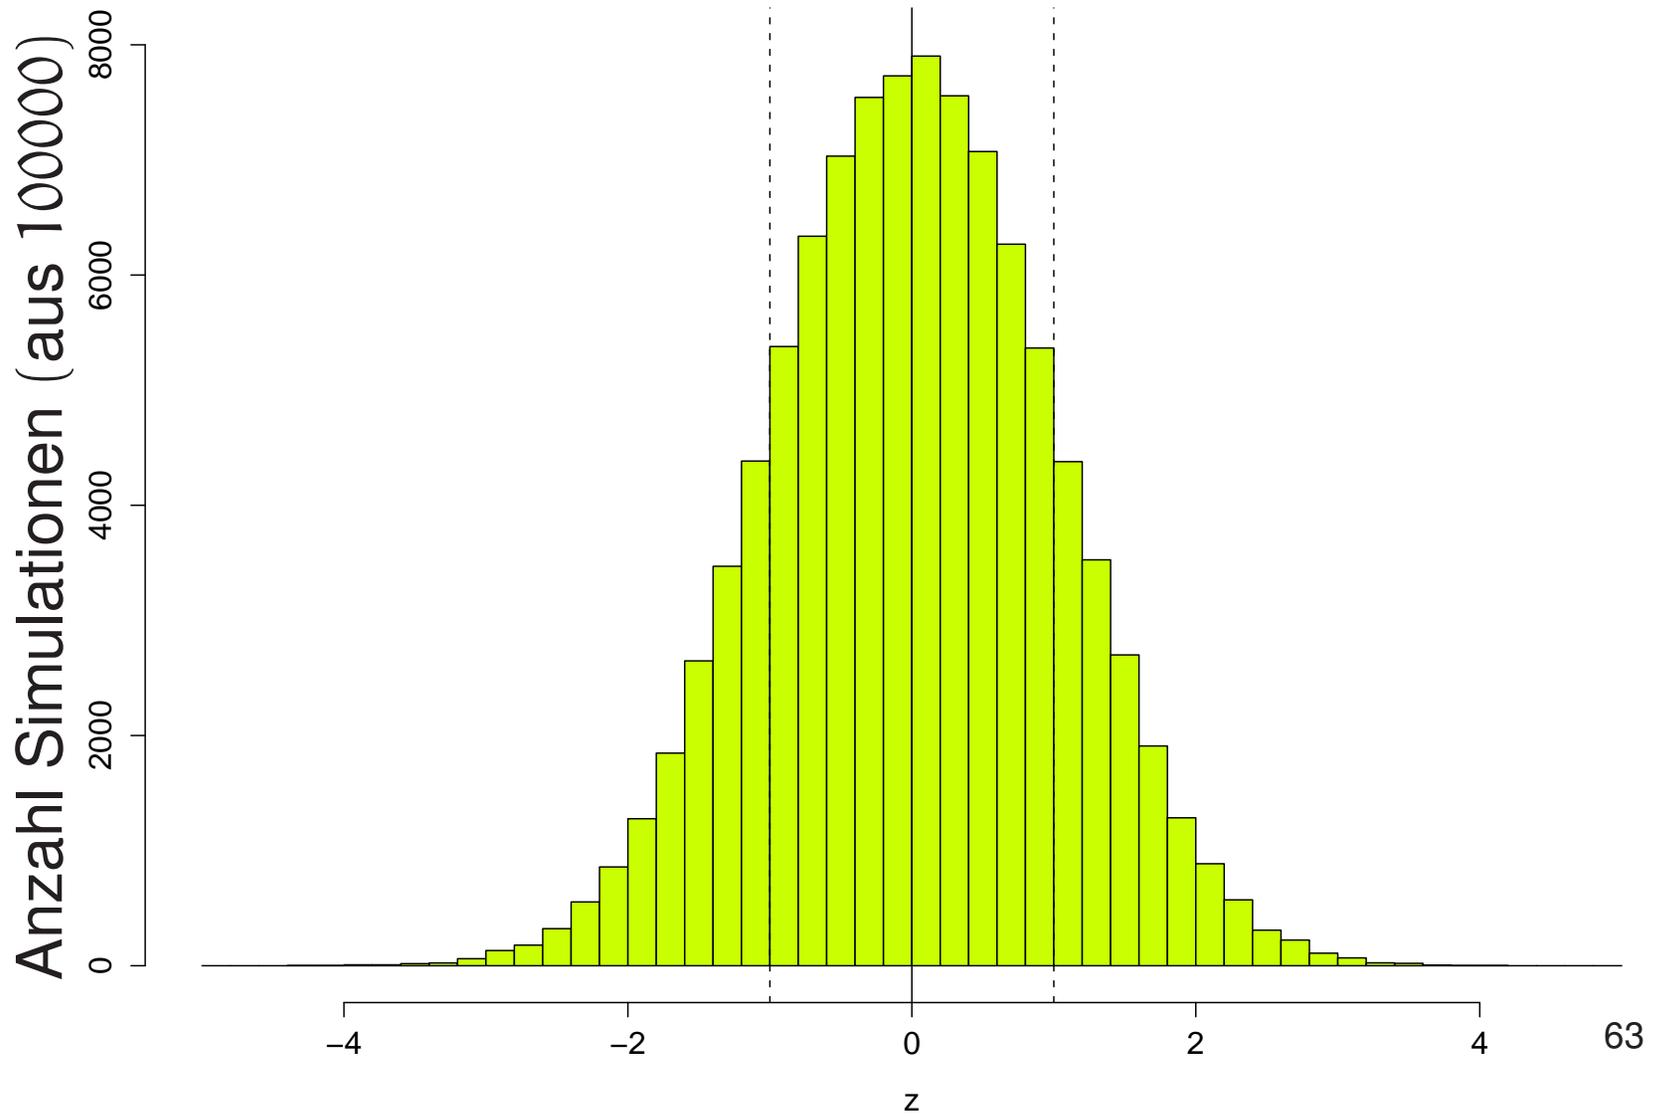


Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n}$ ($n = 20$)



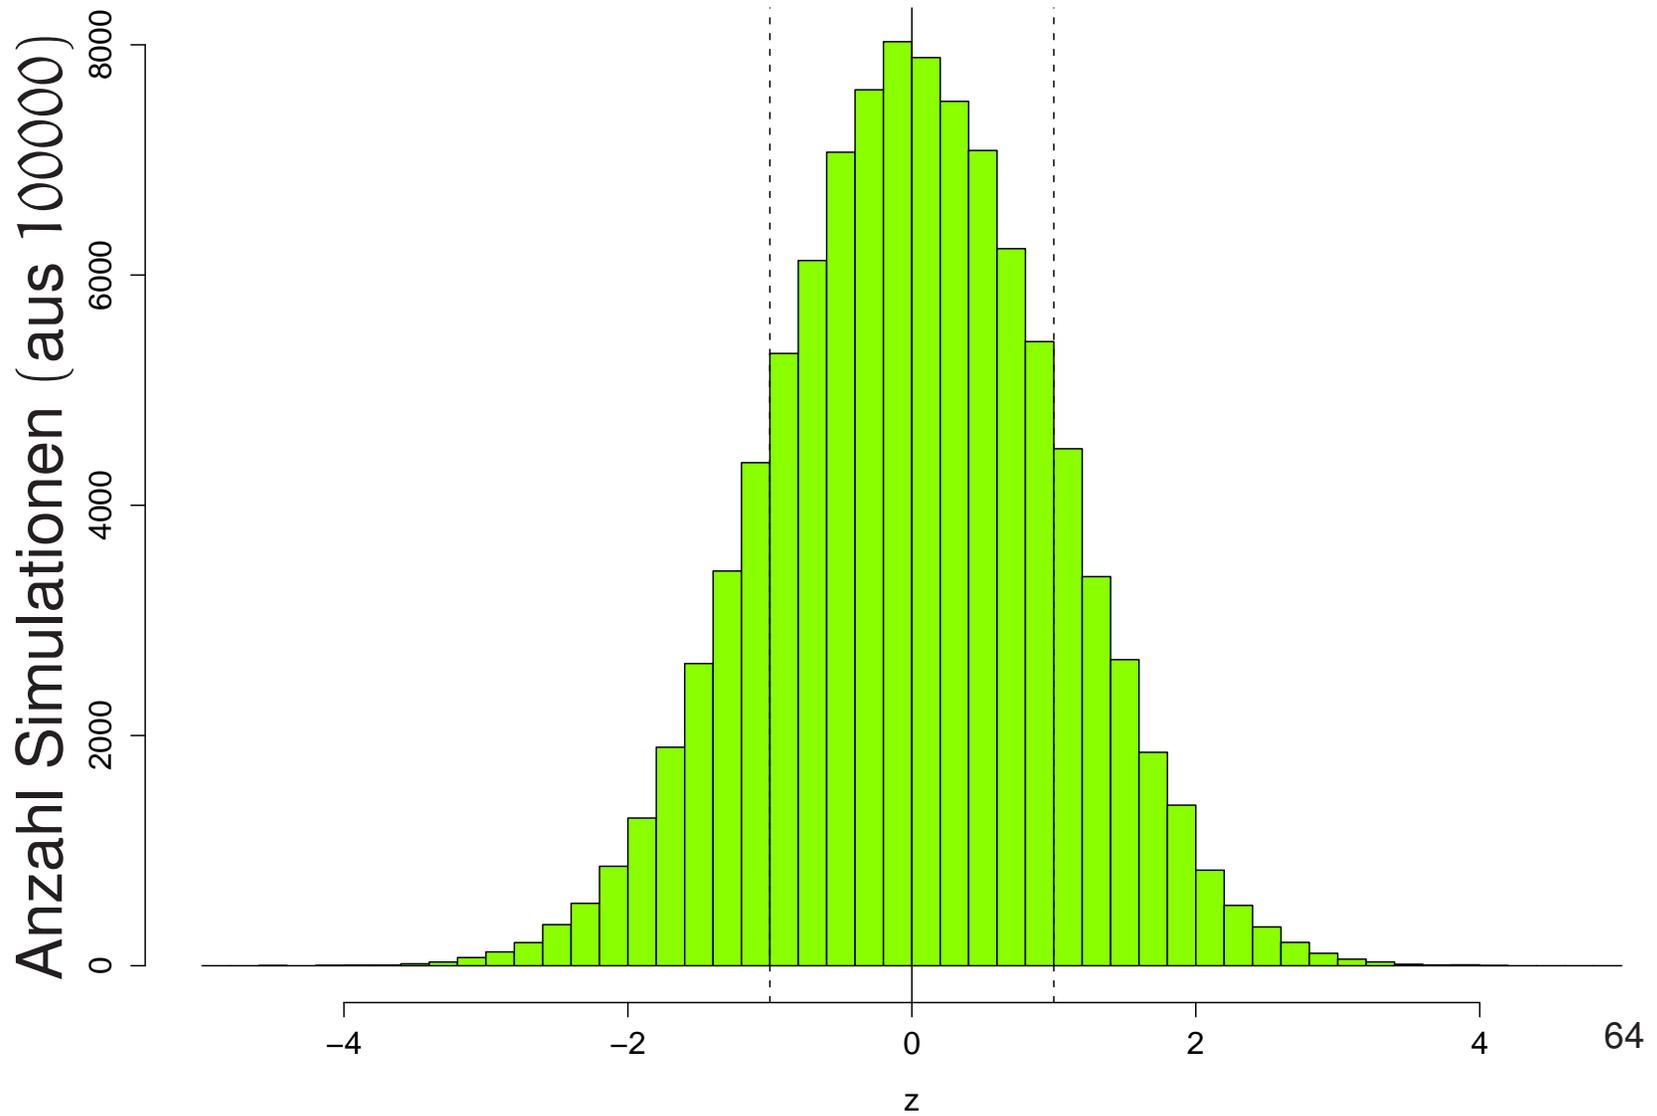
Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 25)$$



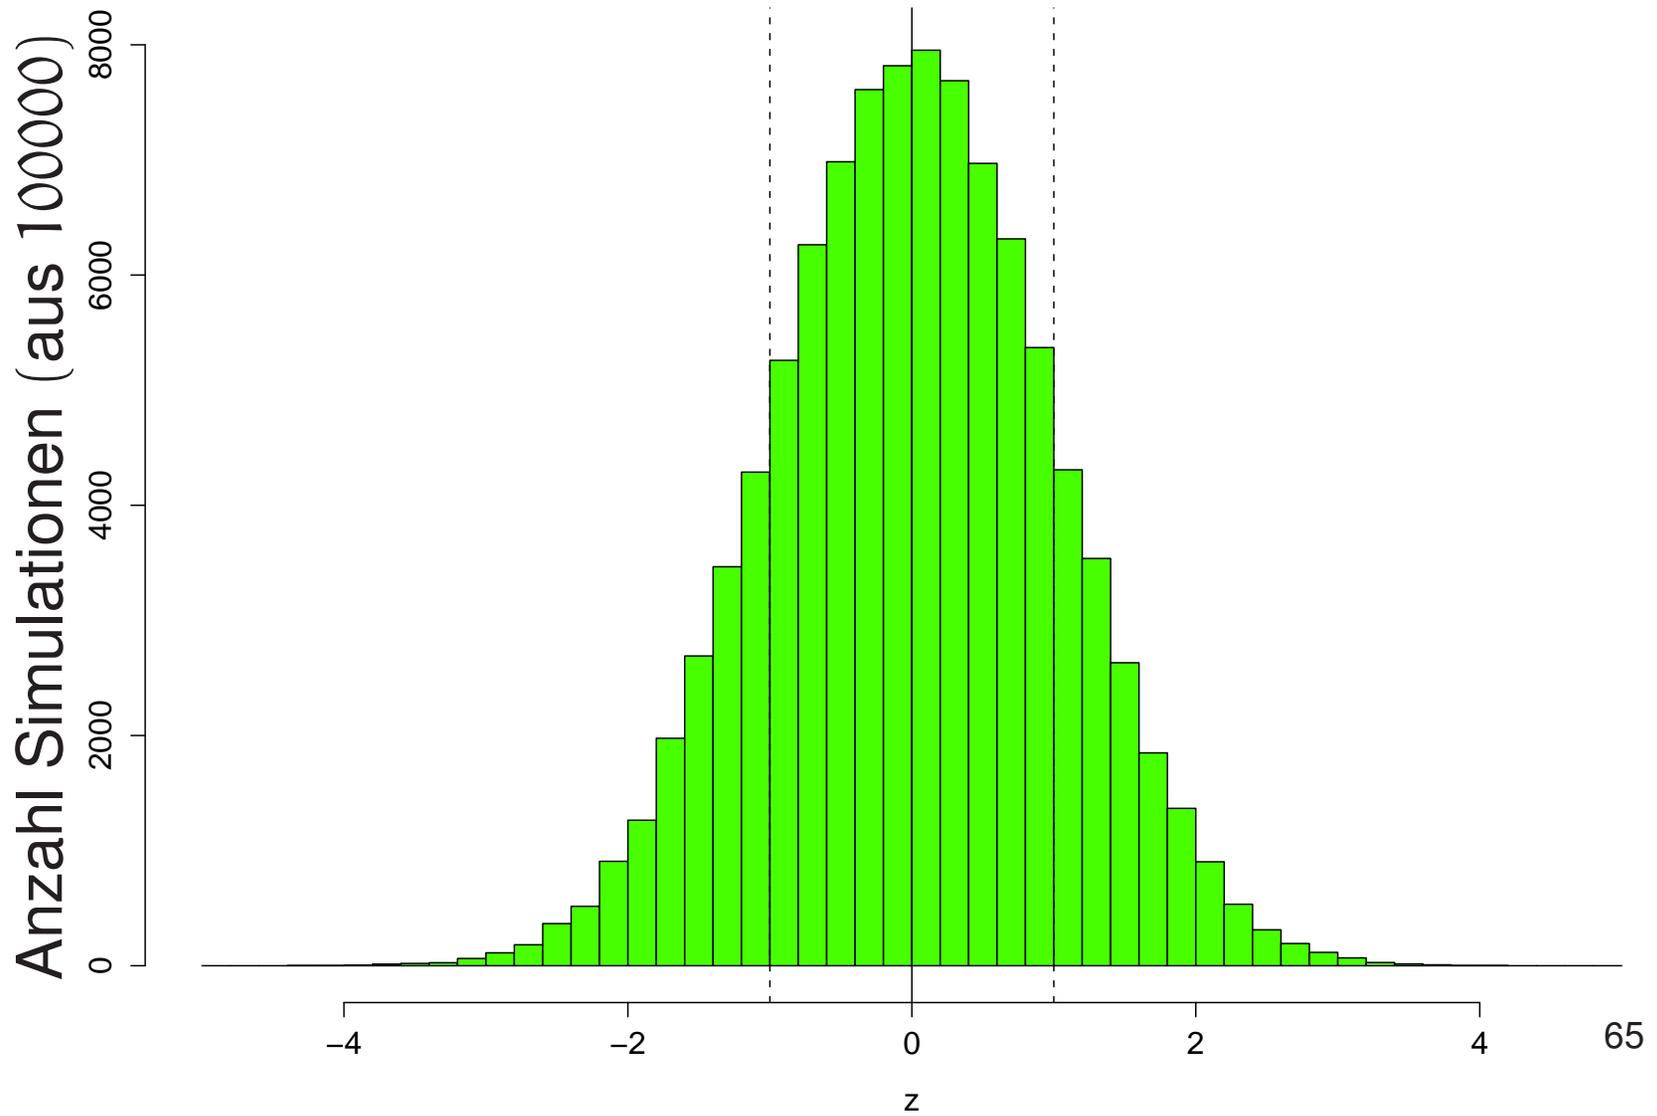
Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 30)$$

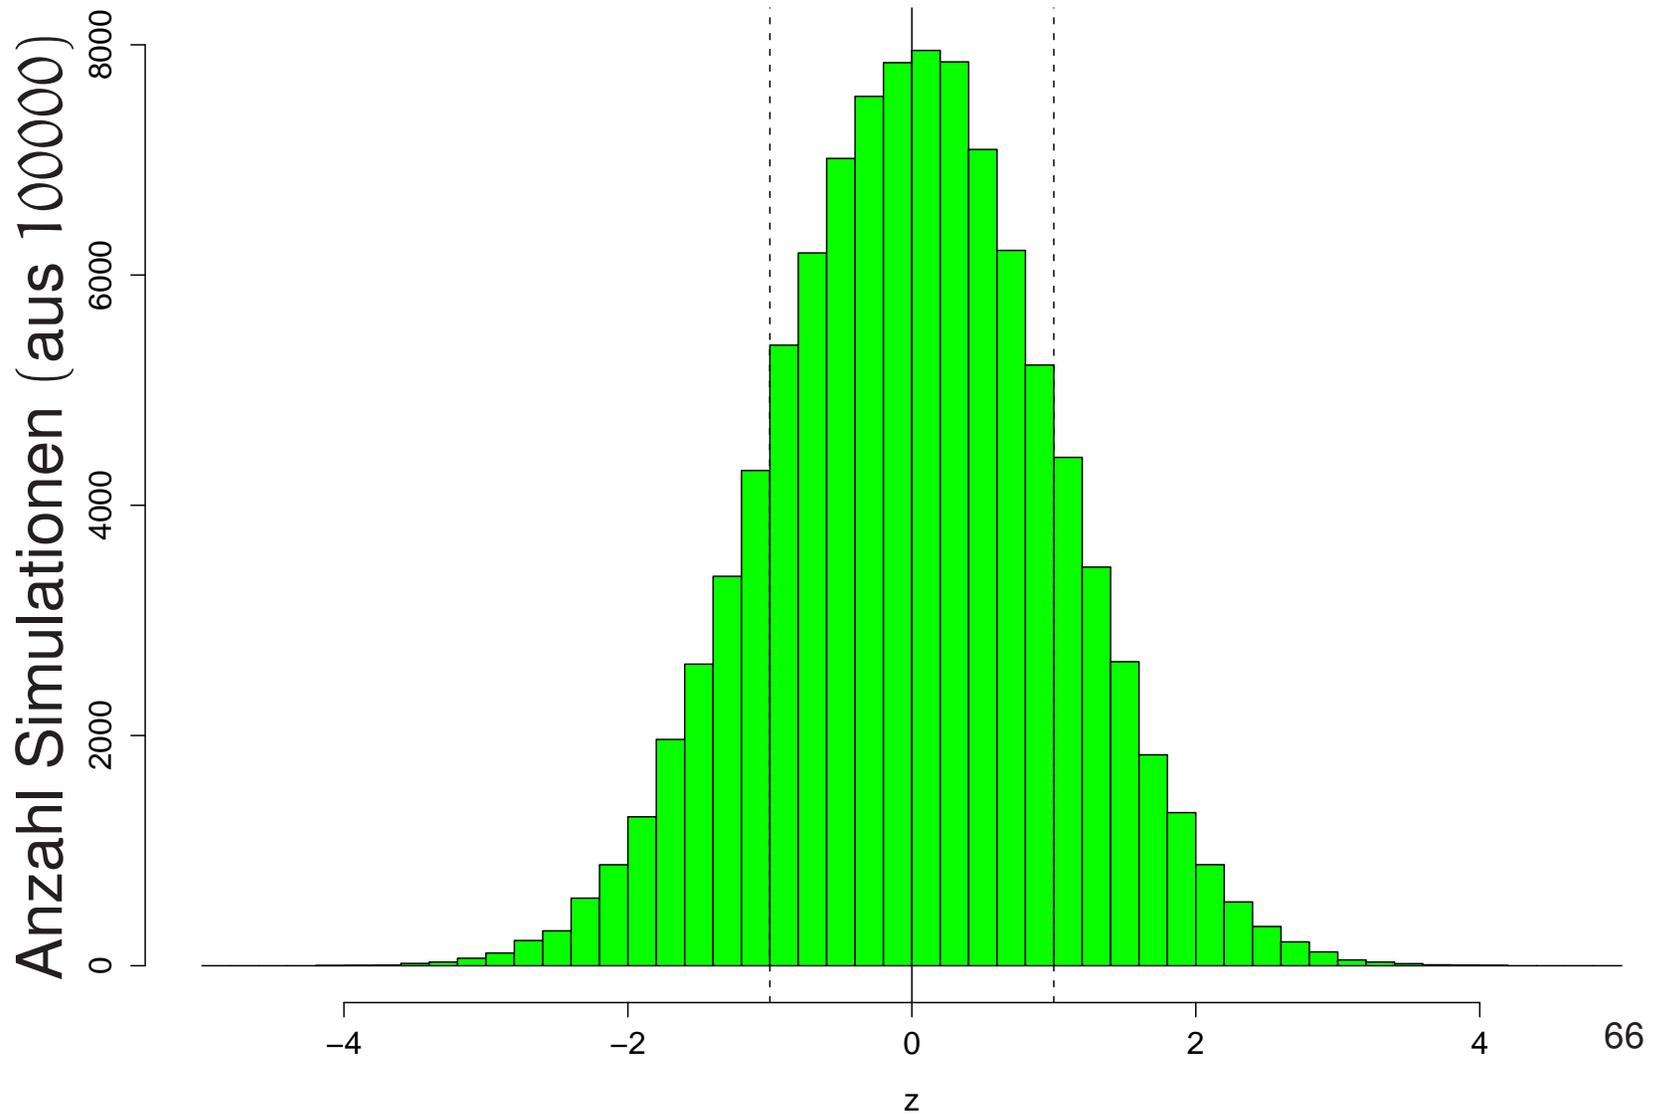


Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 35)$$

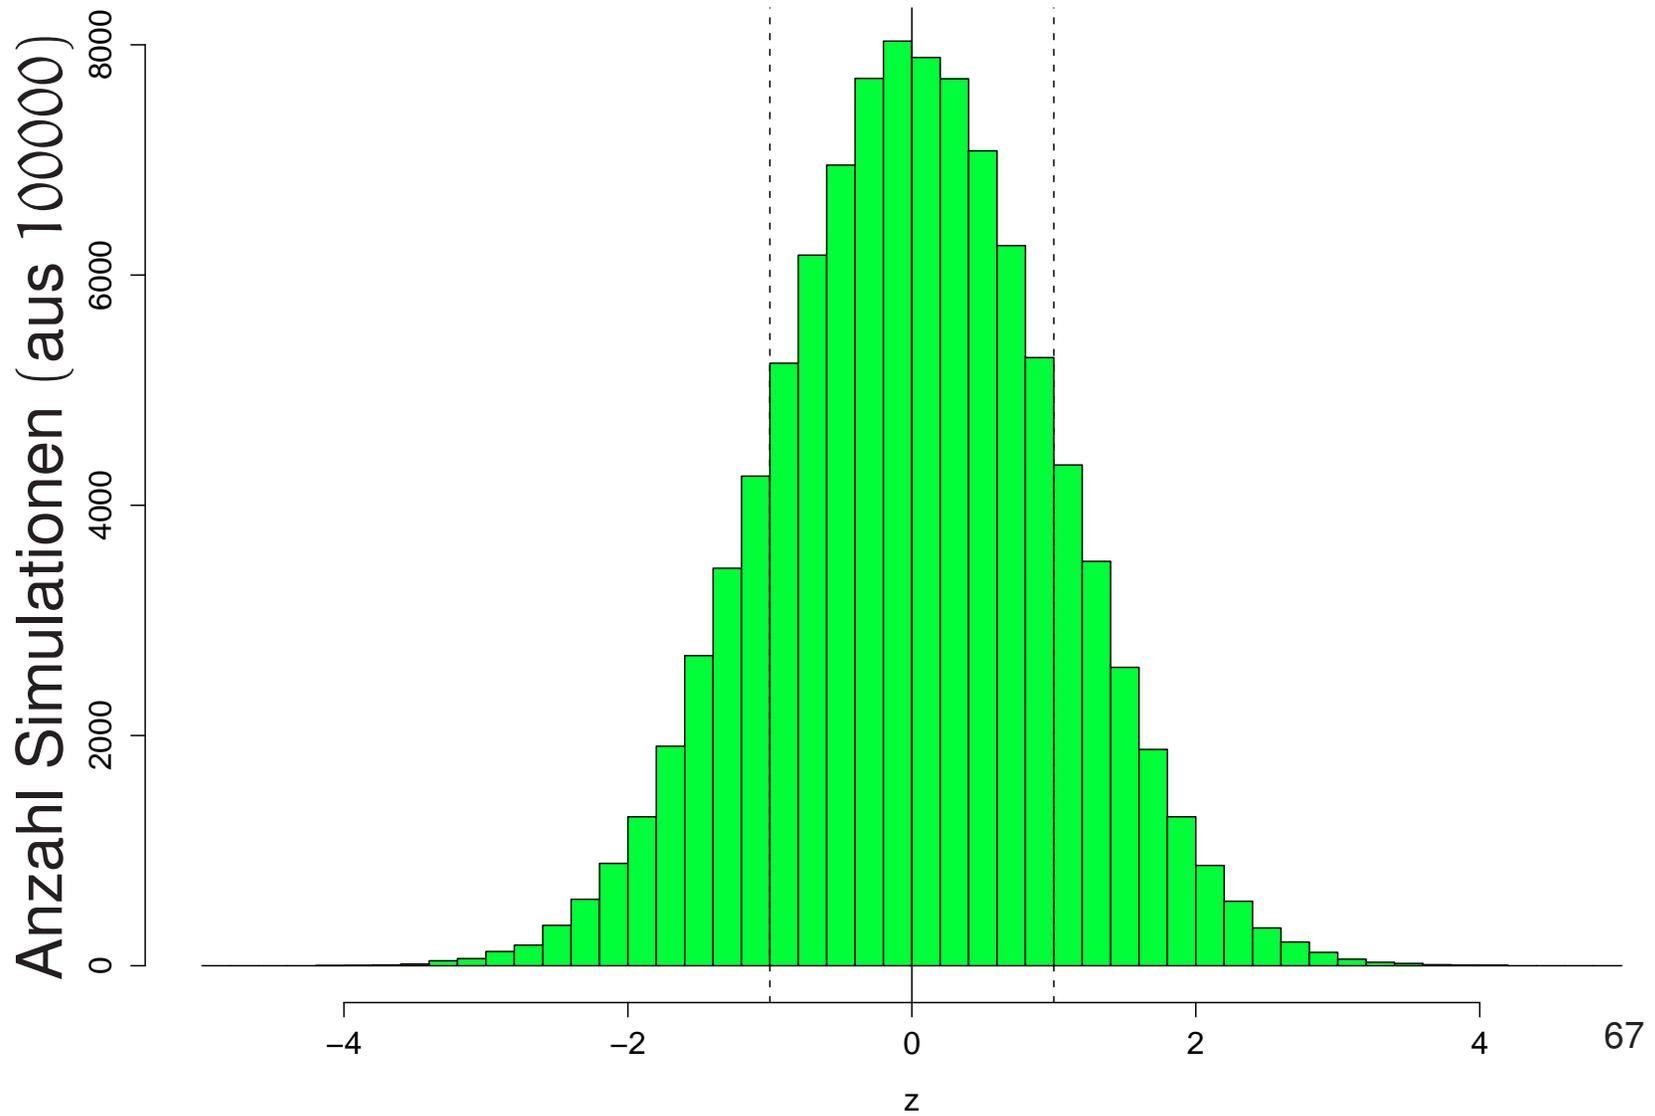


Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n}$ ($n = 40$)



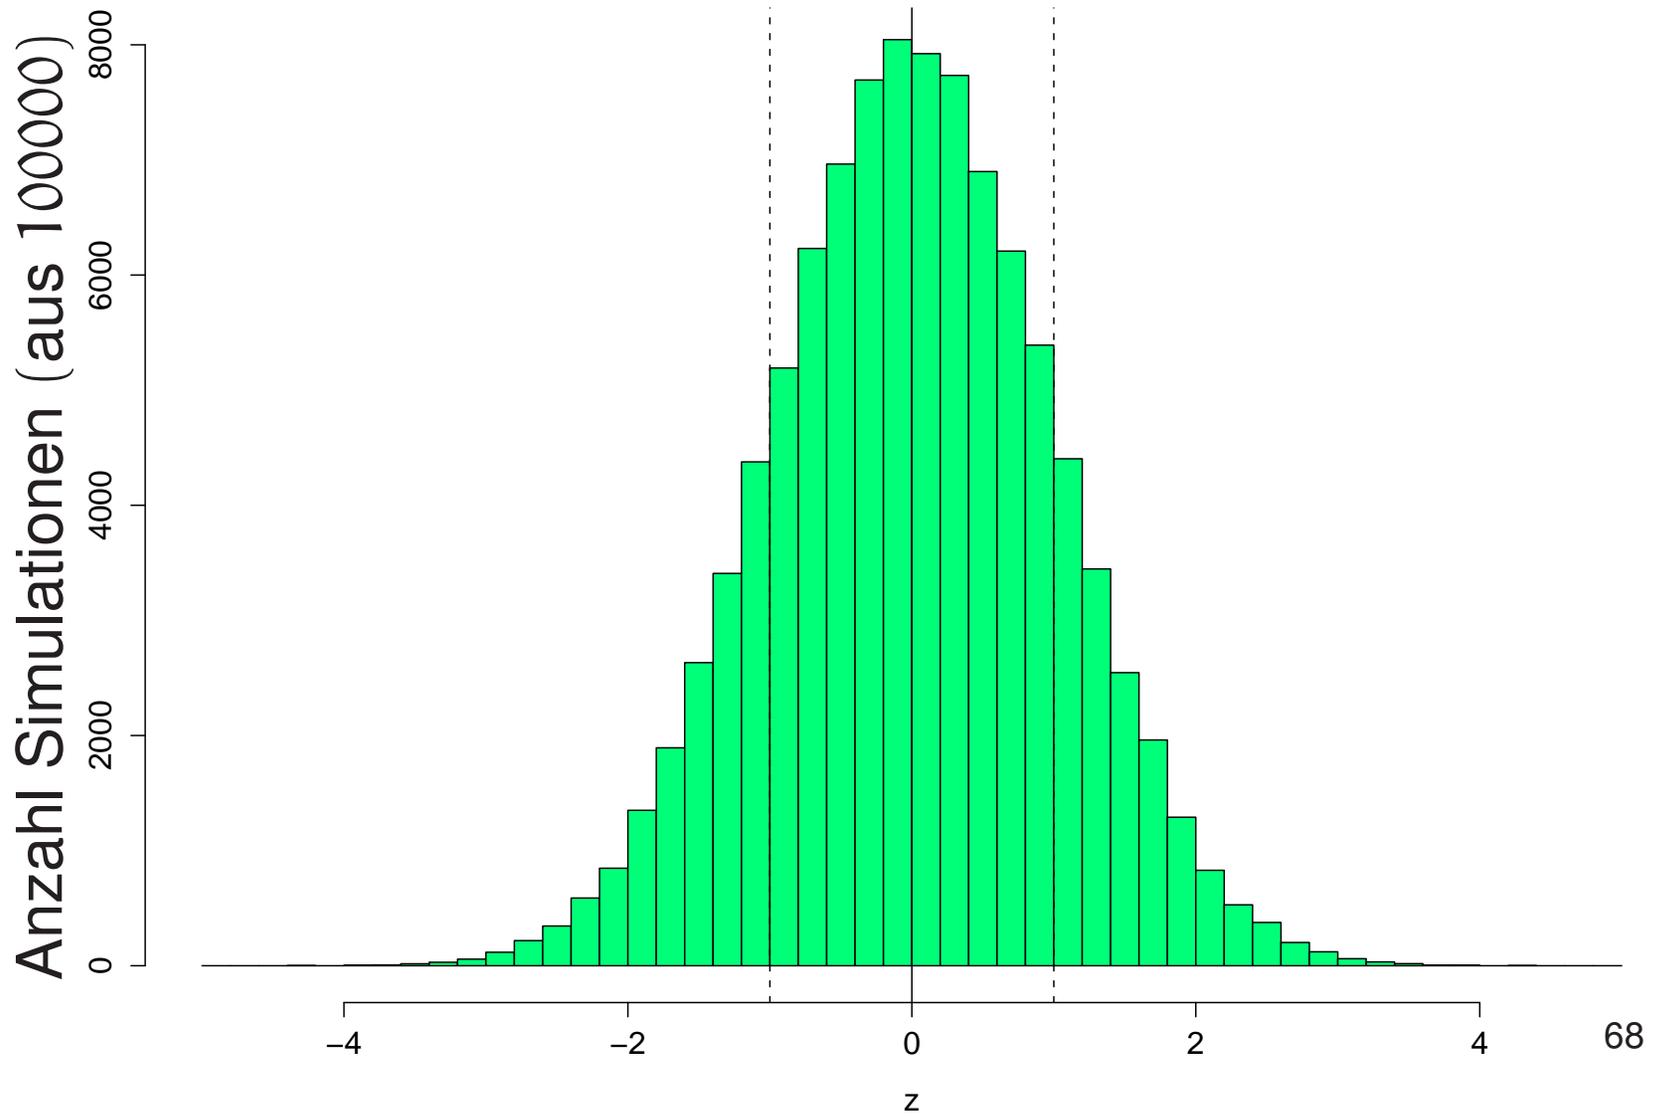
Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 45)$$



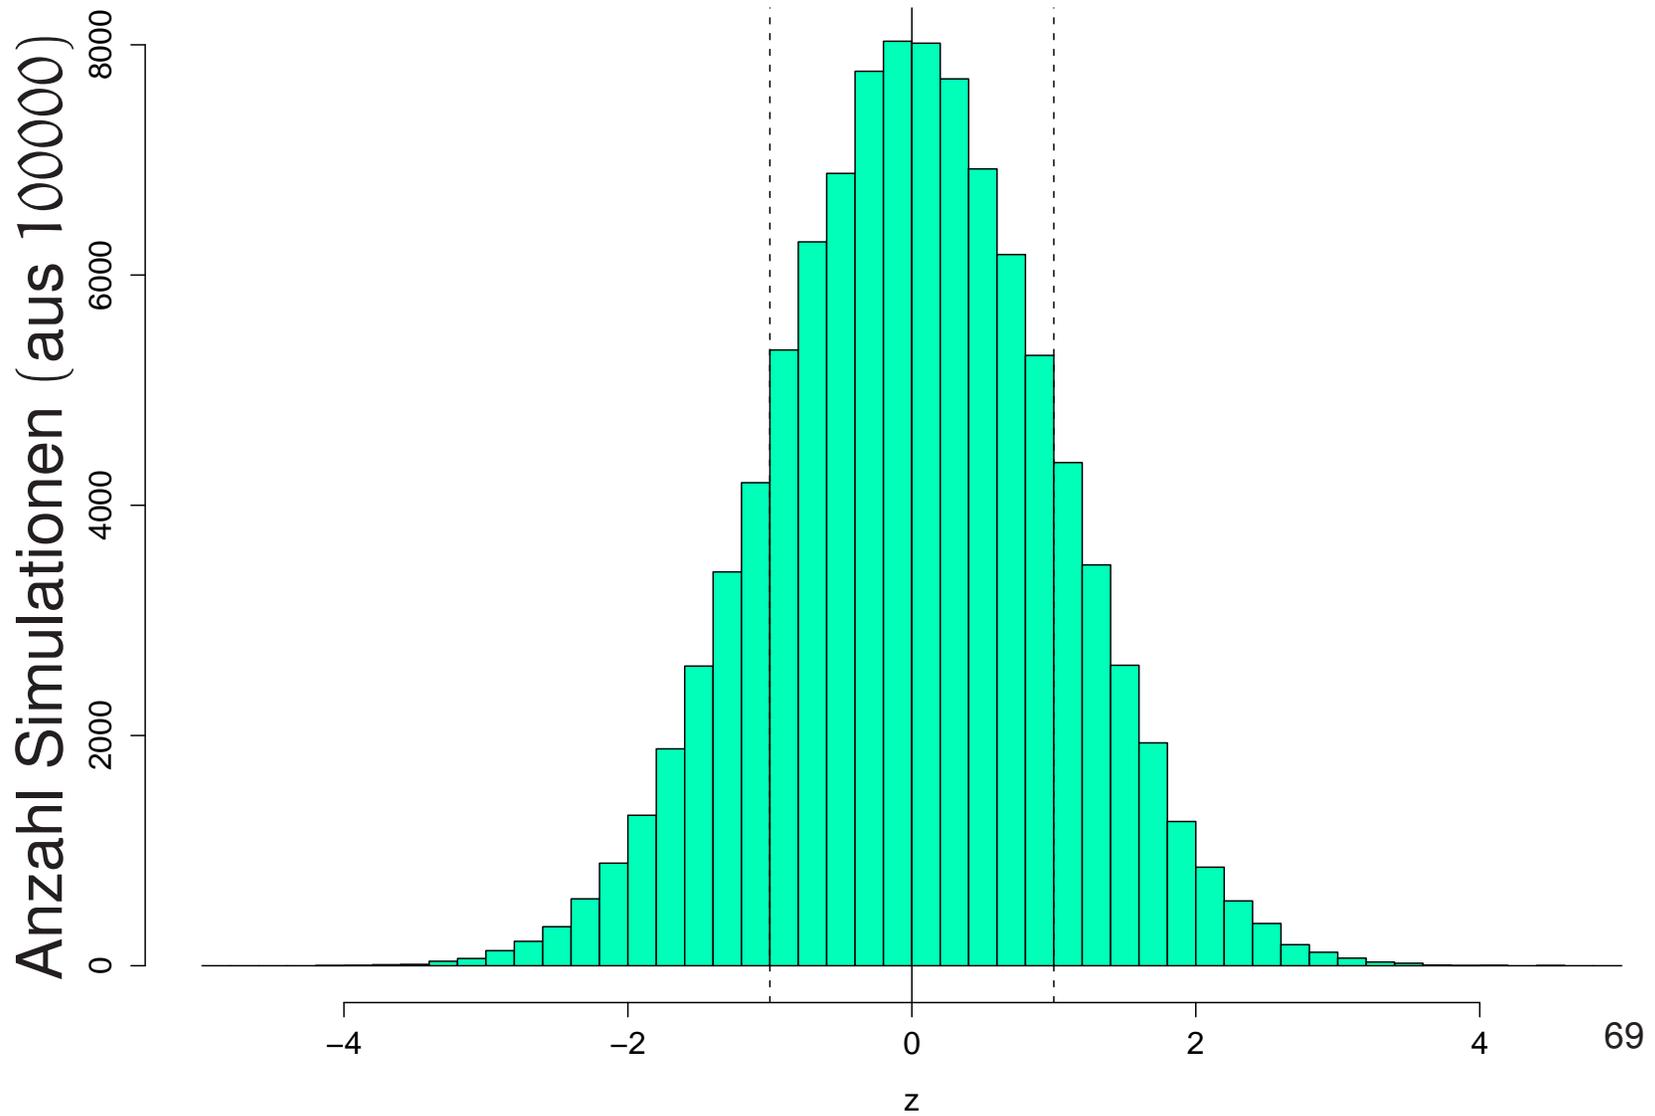
Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 50)$$



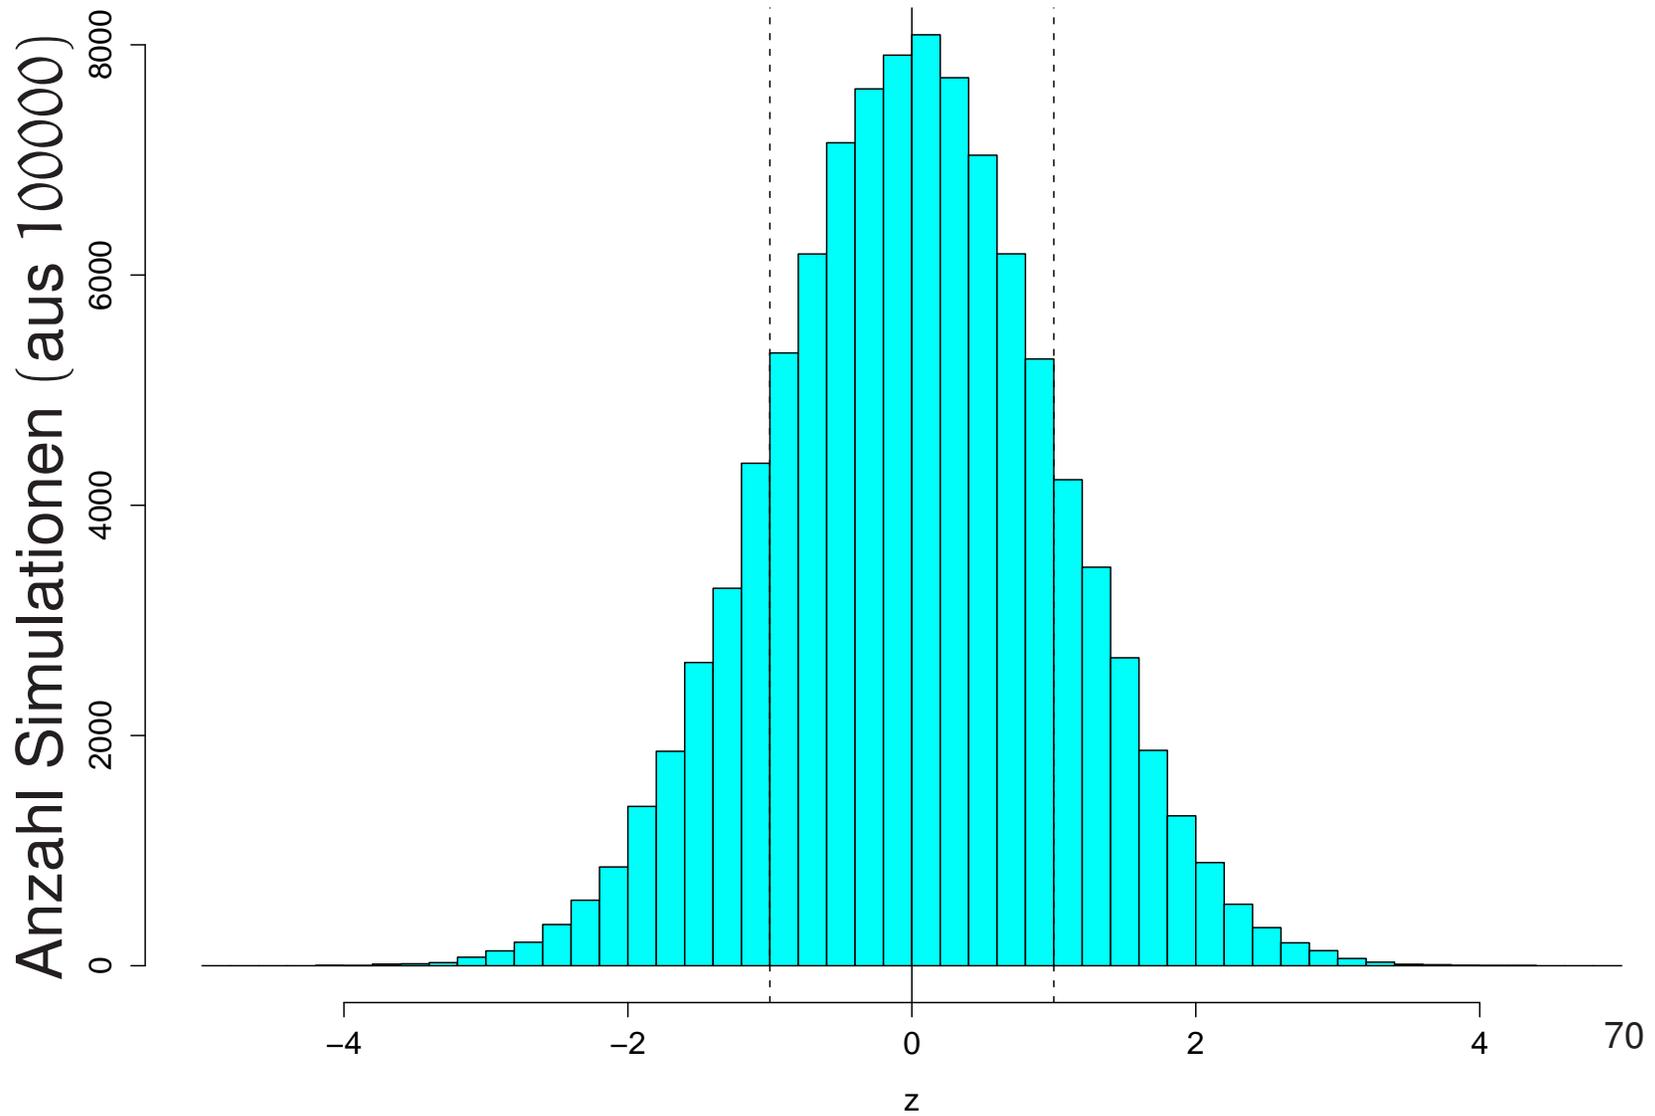
Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 55)$$

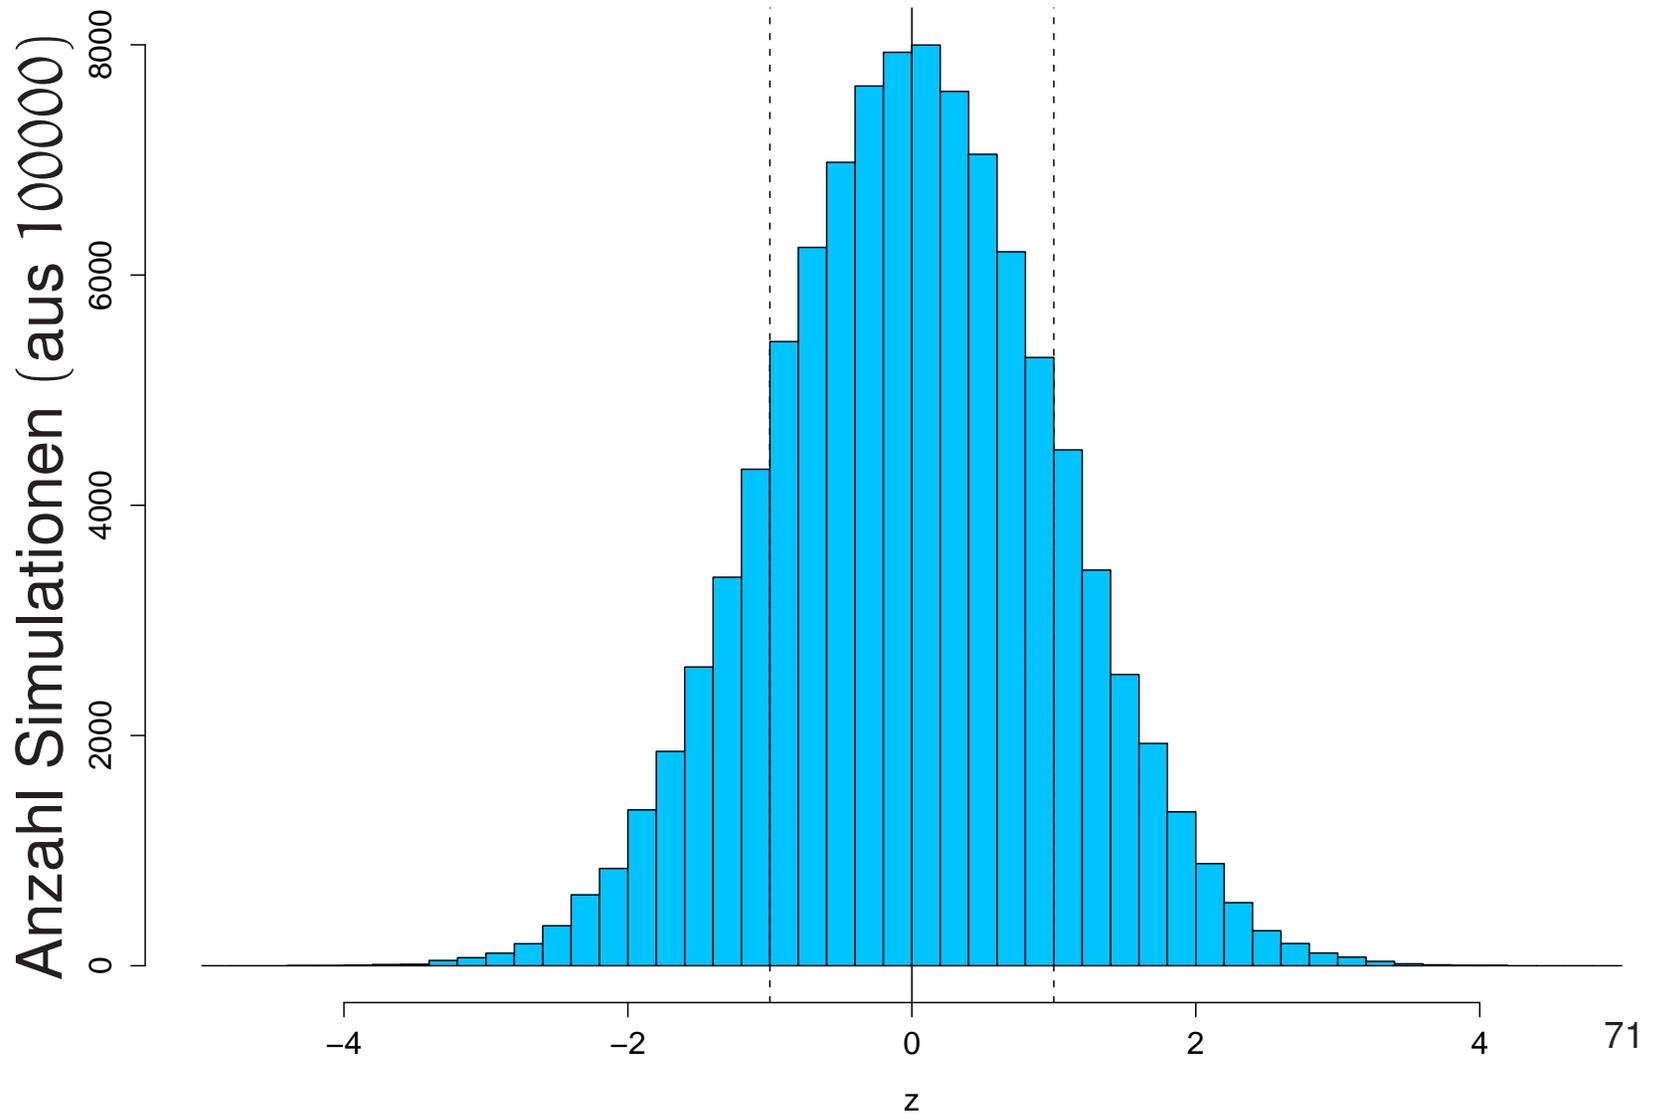


Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 60)$$

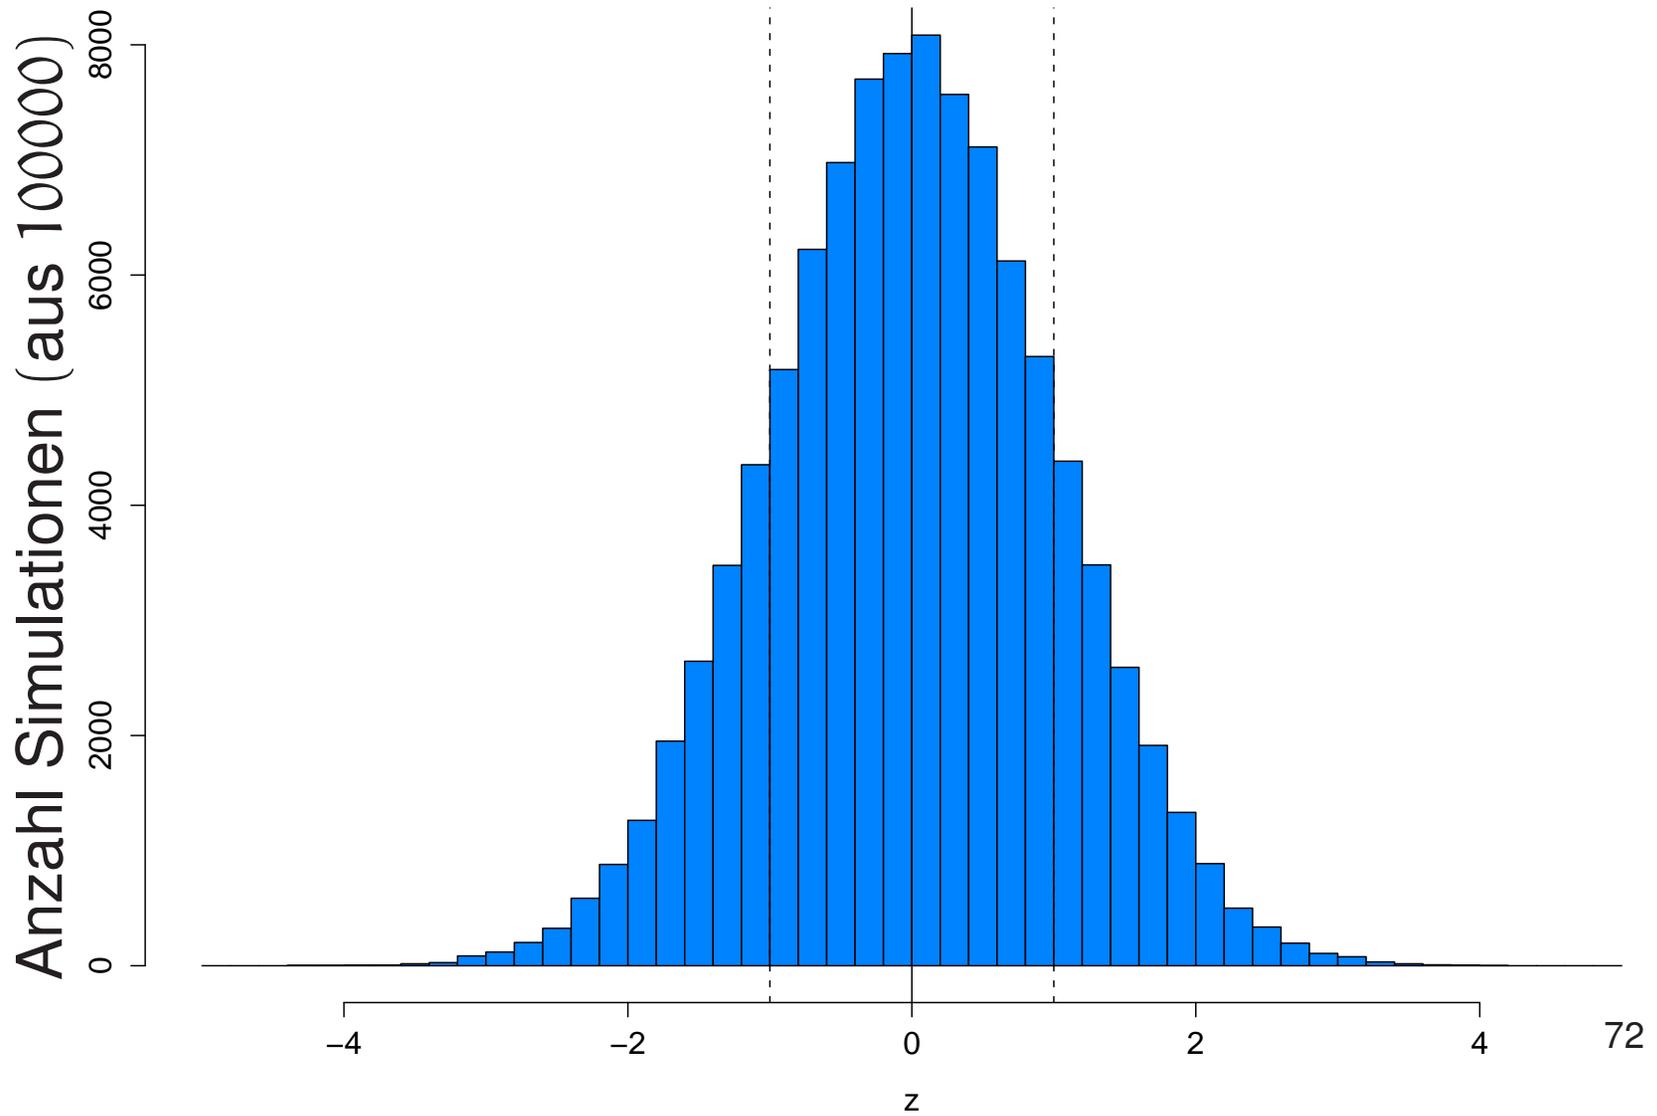


Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n}$ ($n = 65$)

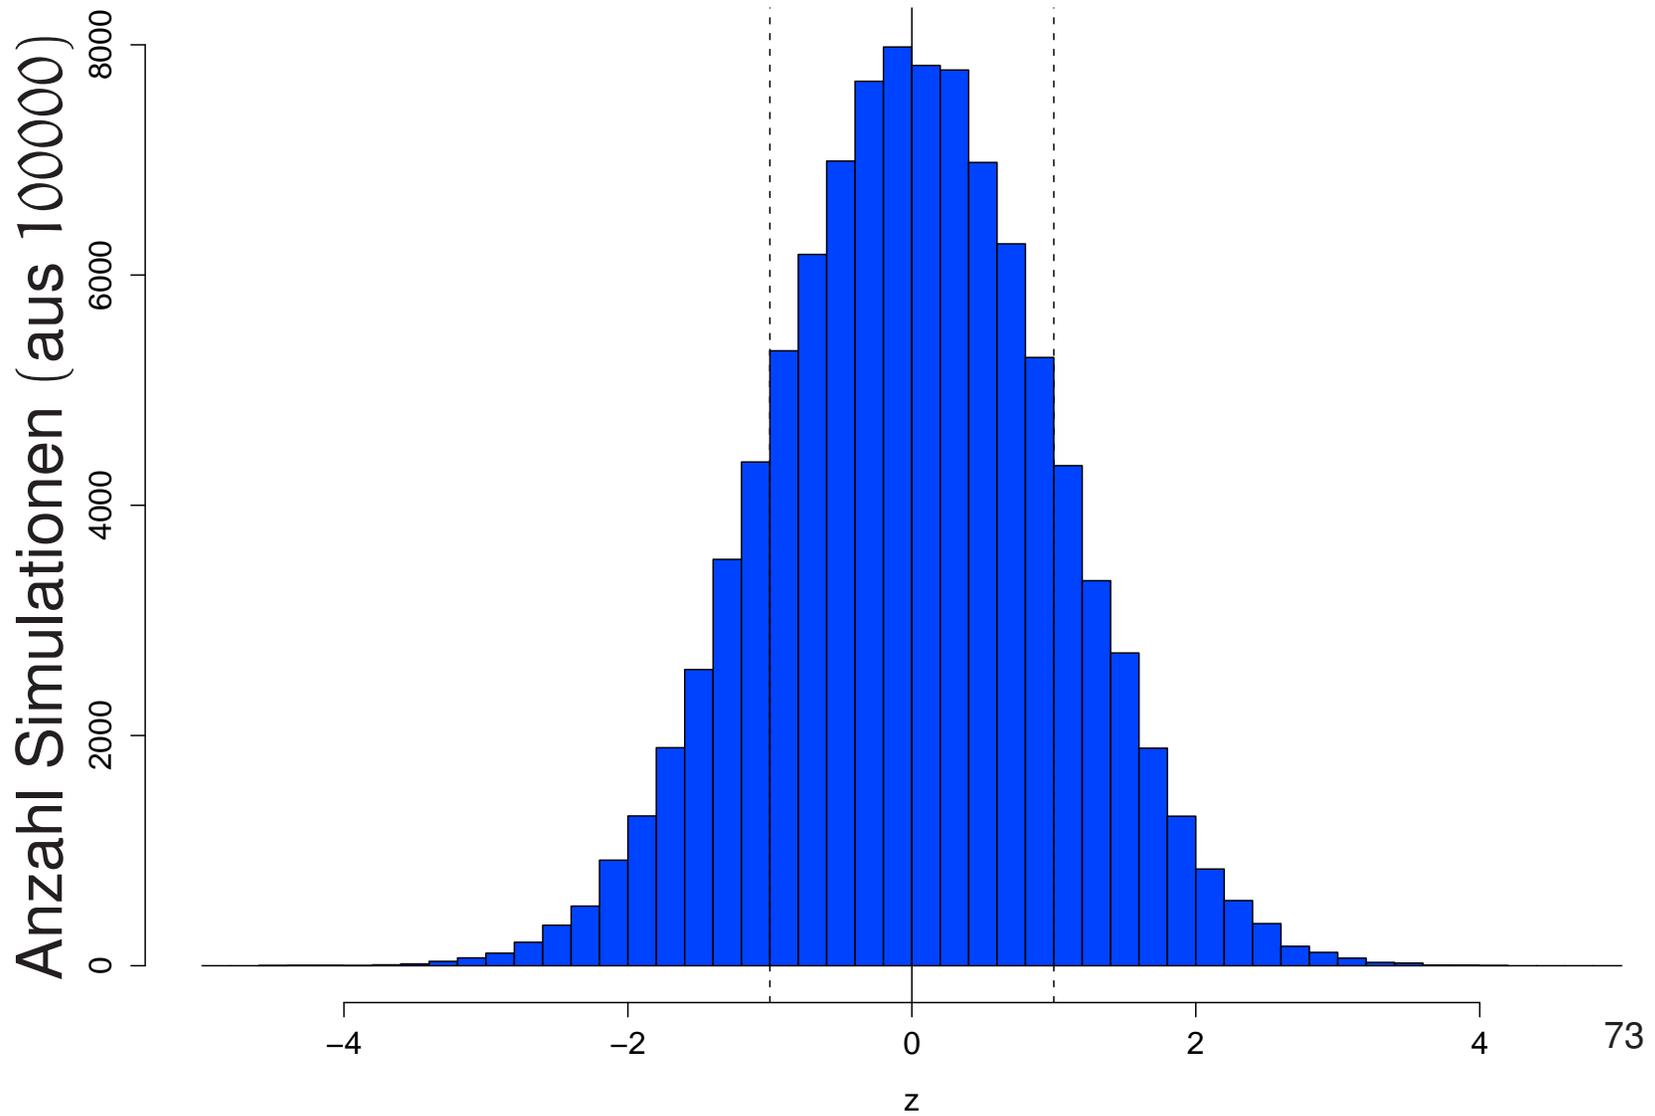


Standardisierung:

$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 70)$$

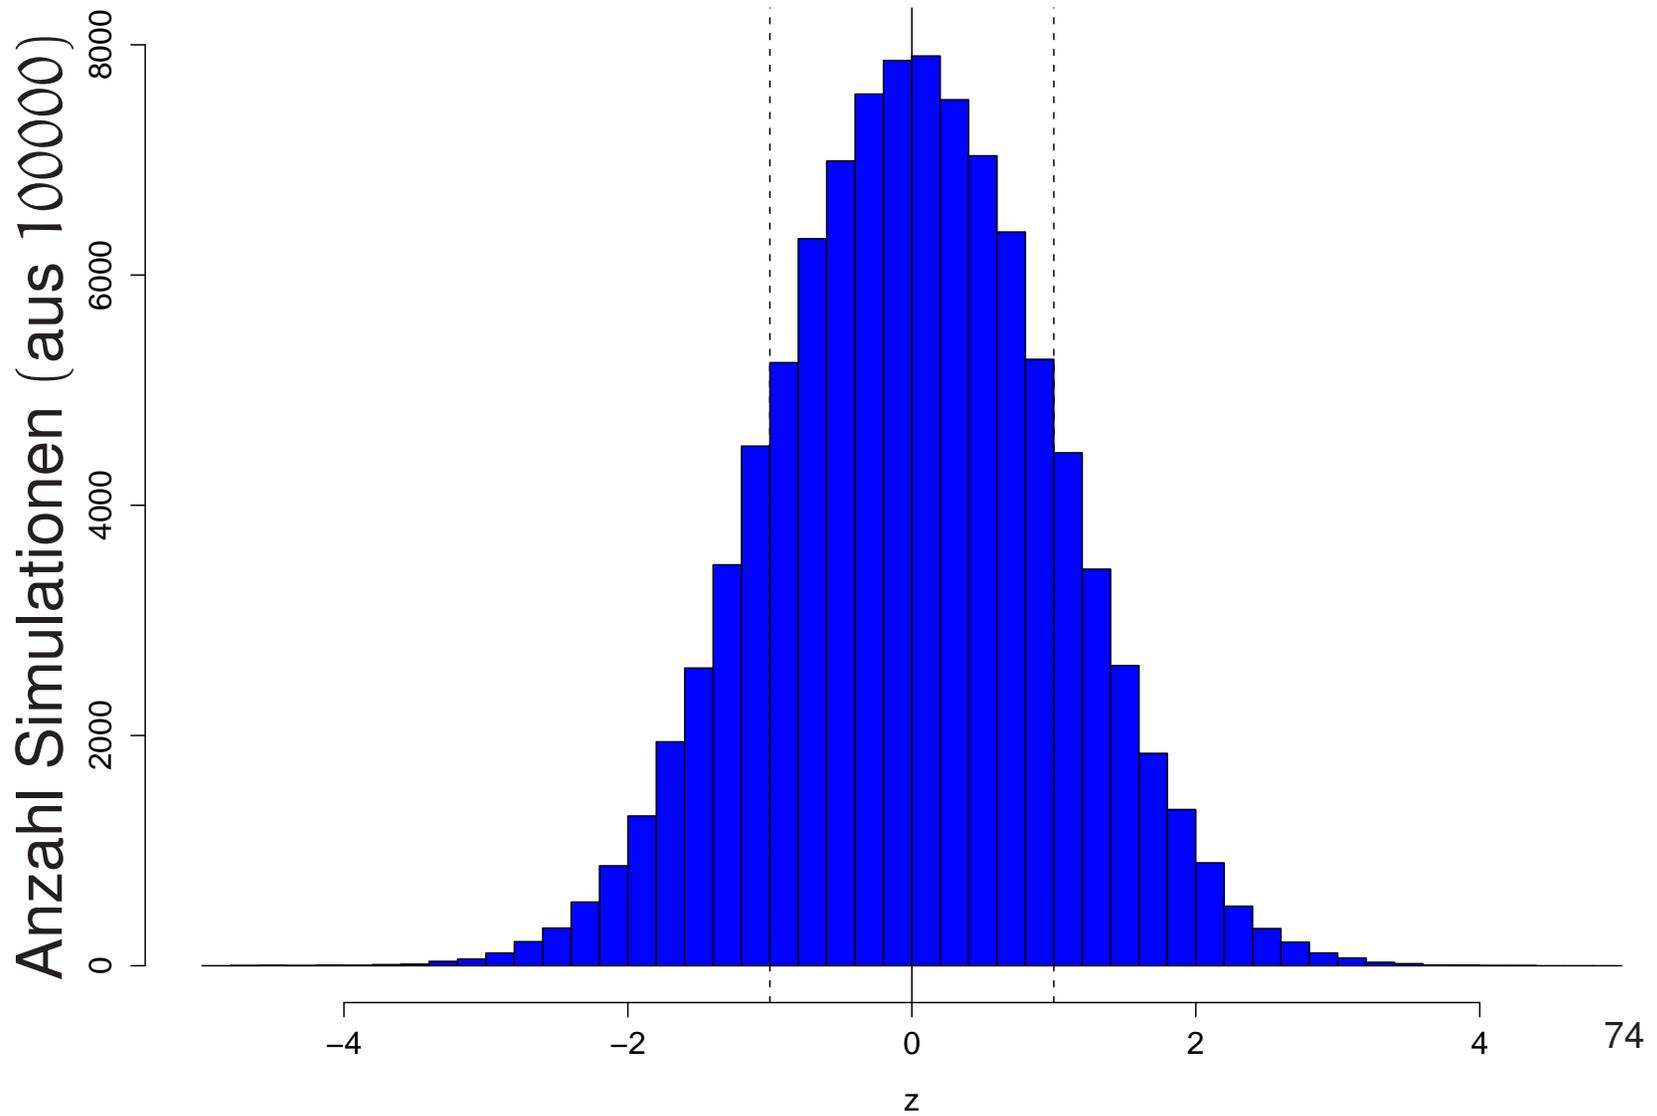


Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n}$ ($n = 75$)

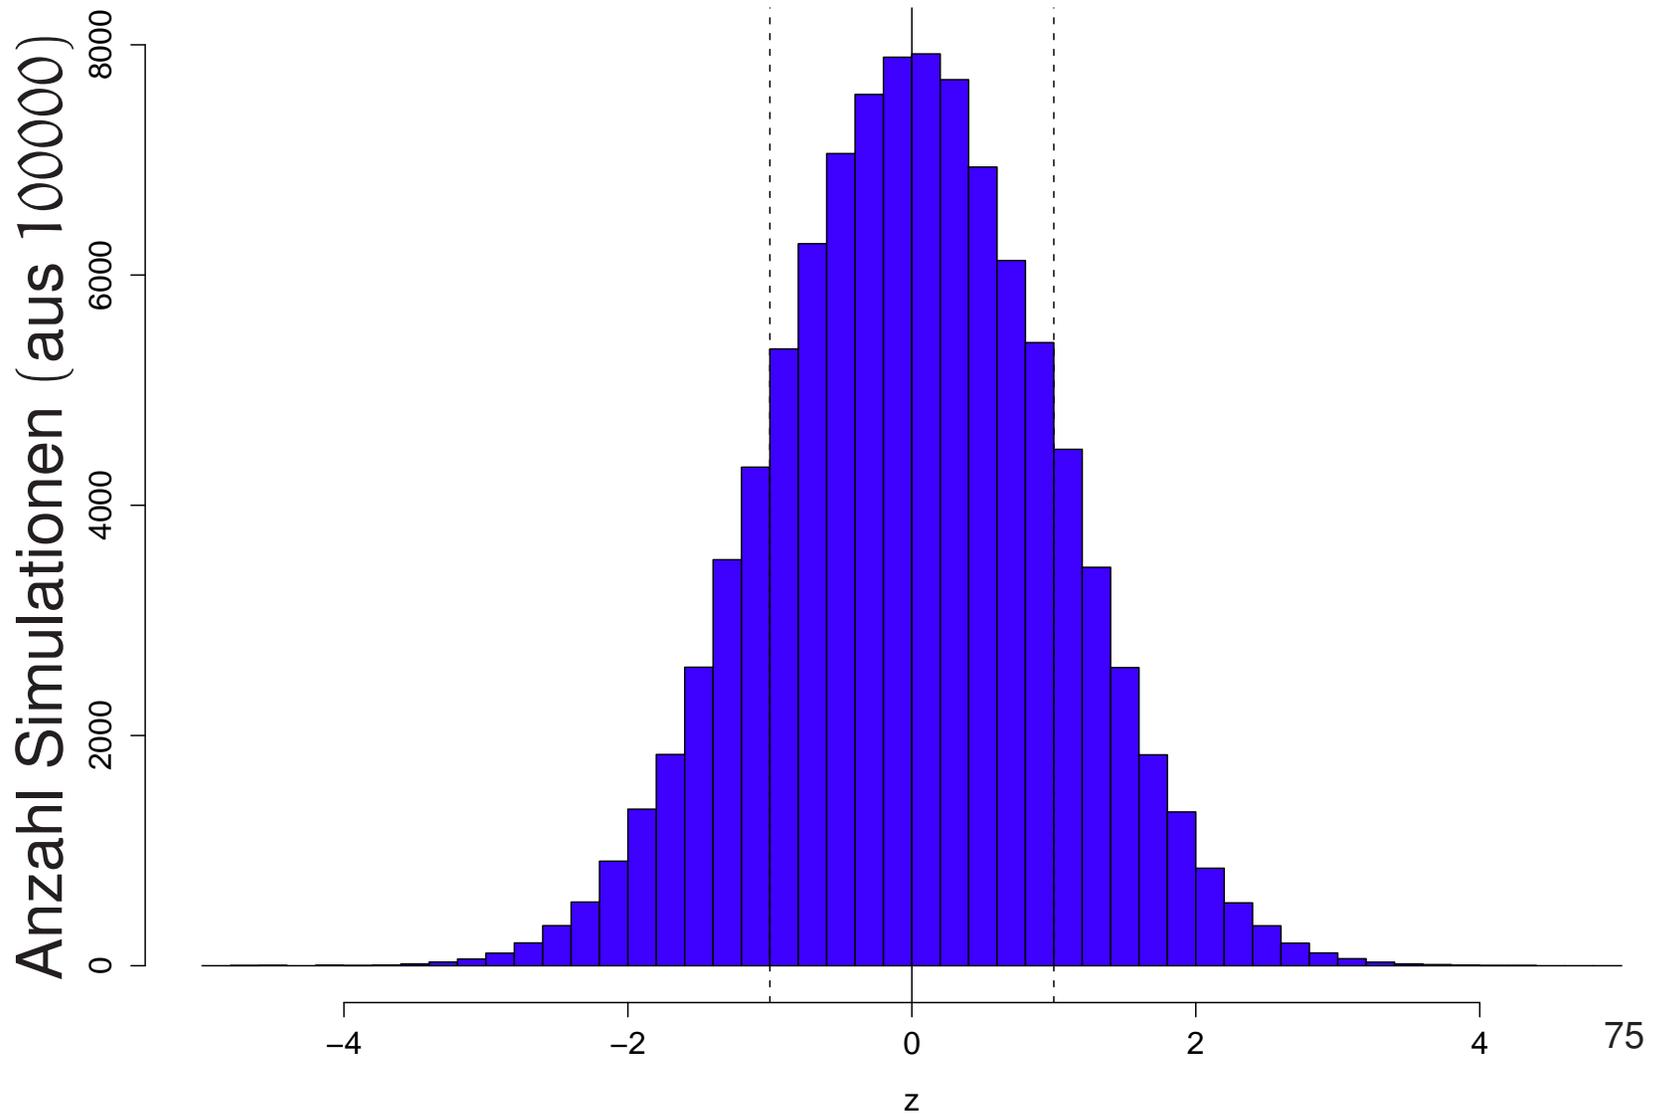


Standardisierung:

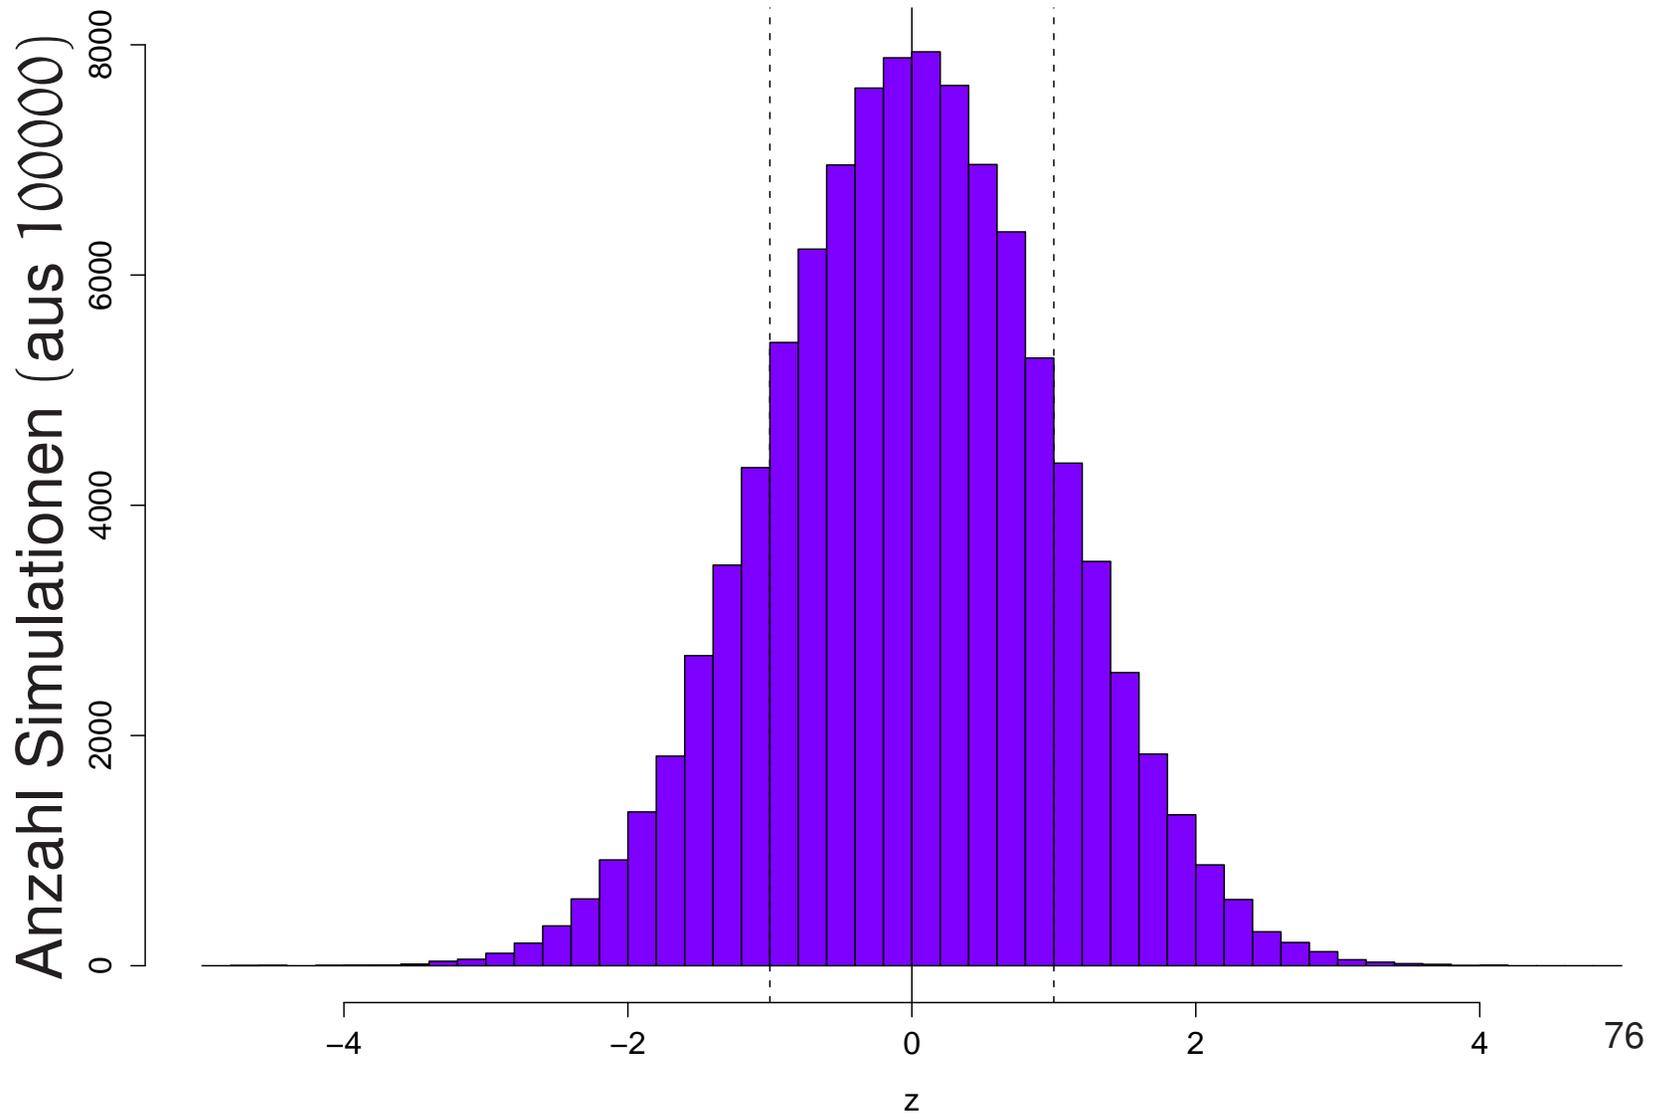
$$Z_n := (S_n - \mathbf{E}S_n) / \sigma_{S_n} \quad (n = 80)$$



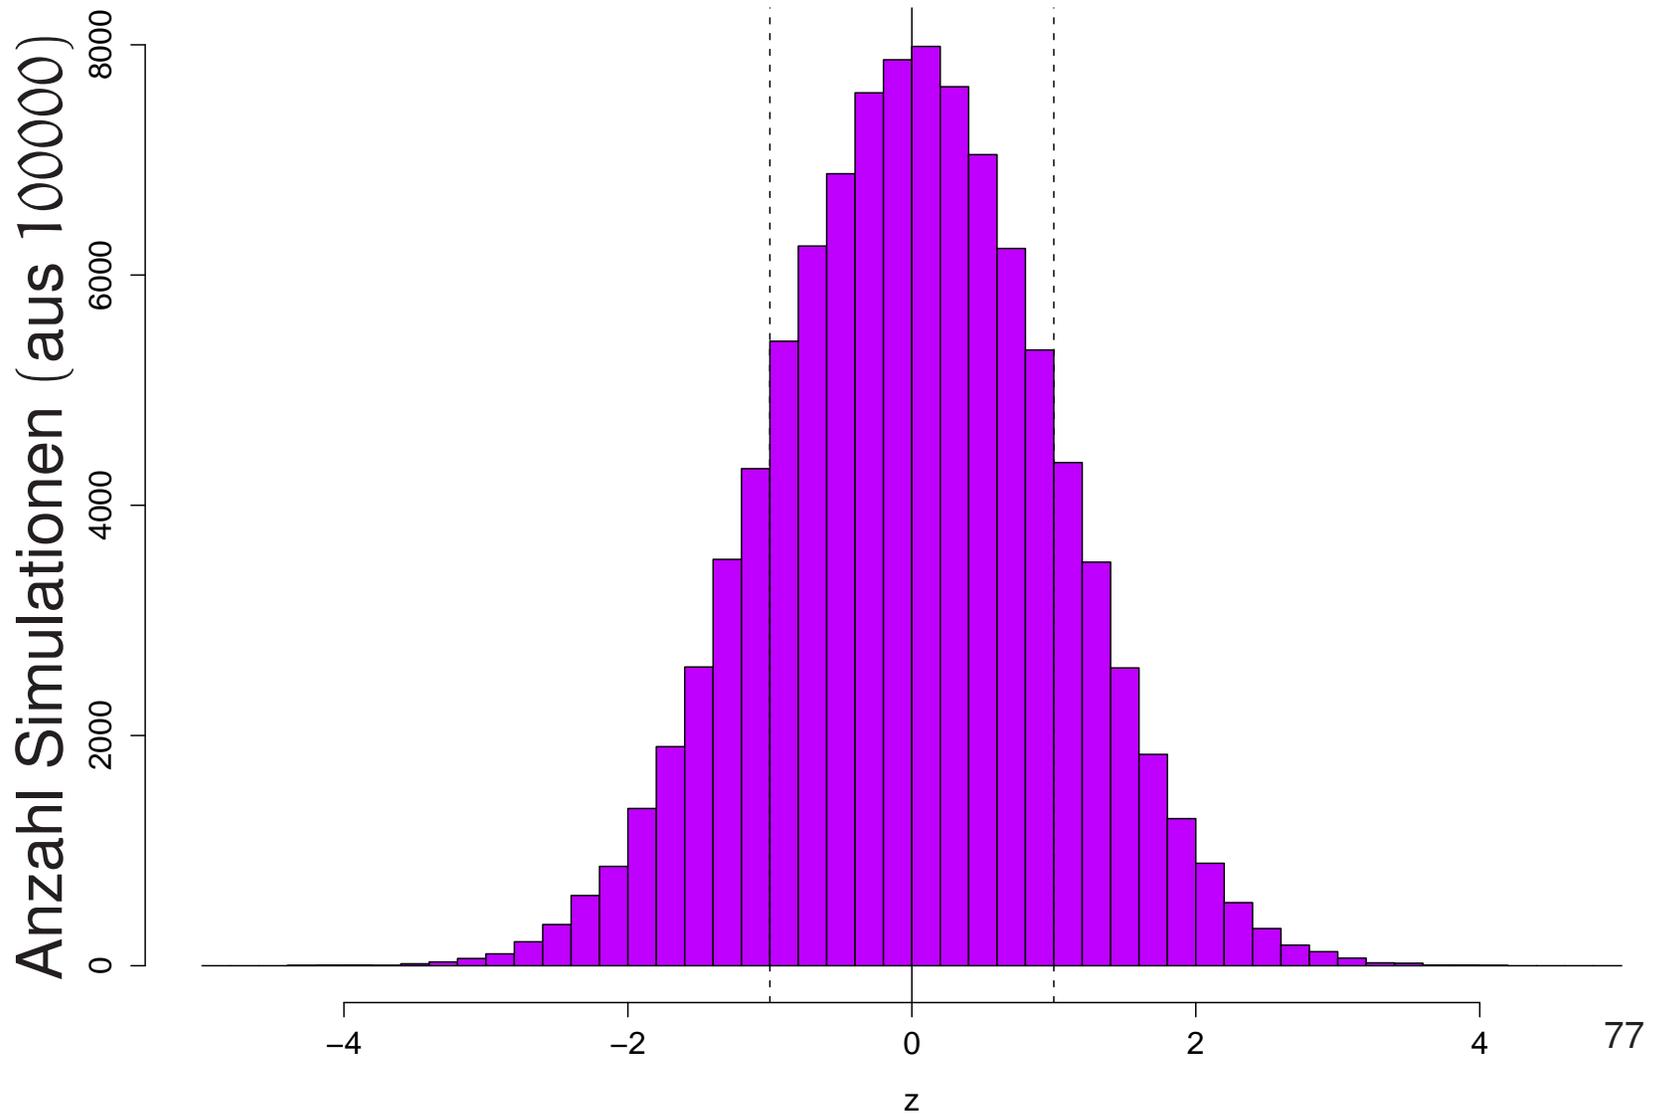
Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n}$ ($n = 85$)



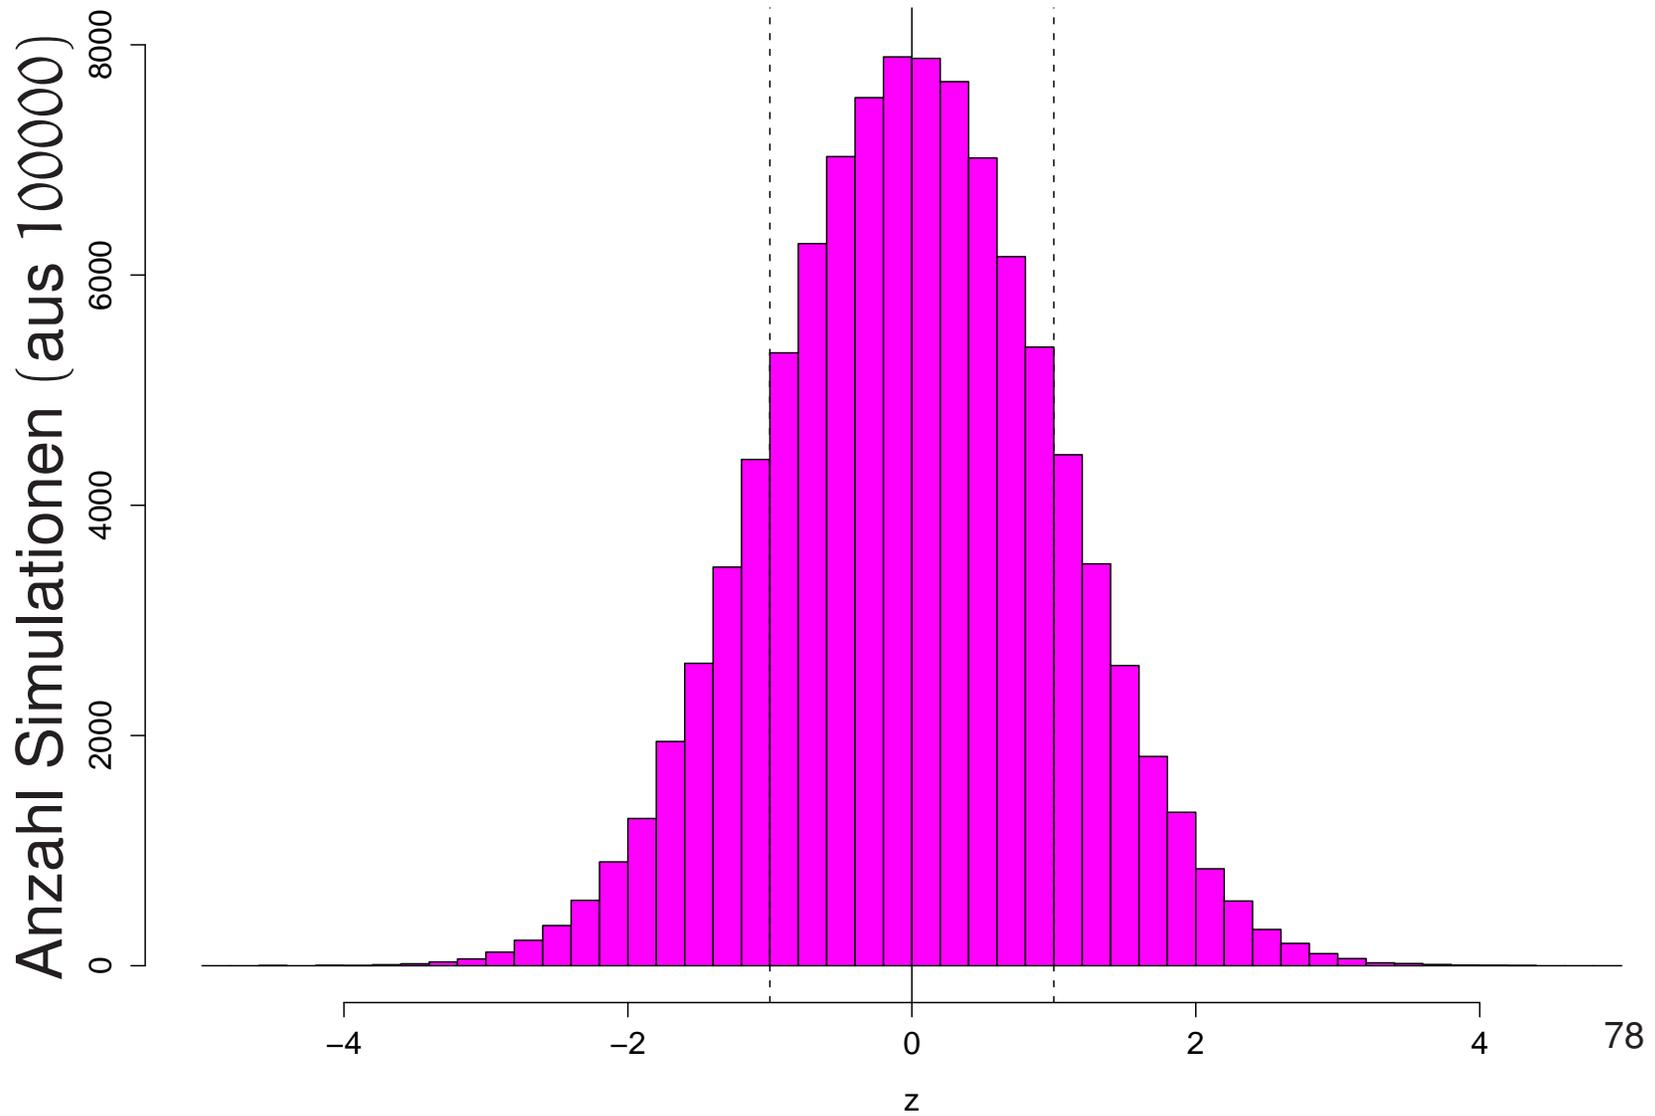
Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n}$ ($n = 90$)



Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n}$ ($n = 95$)



Standardisierung: $Z_n := (S_n - \mathbf{E}S_n)/\sigma_{S_n}$ ($n = 100$)



Die Verteilung von Z_n
scheint zu konvergieren.

Welche Form
hat die Grenzverteilung?

Die Verteilung von
 Z_{100}
ist glockenförmig.

Um welche Glockenkurve handelt es sich genau?

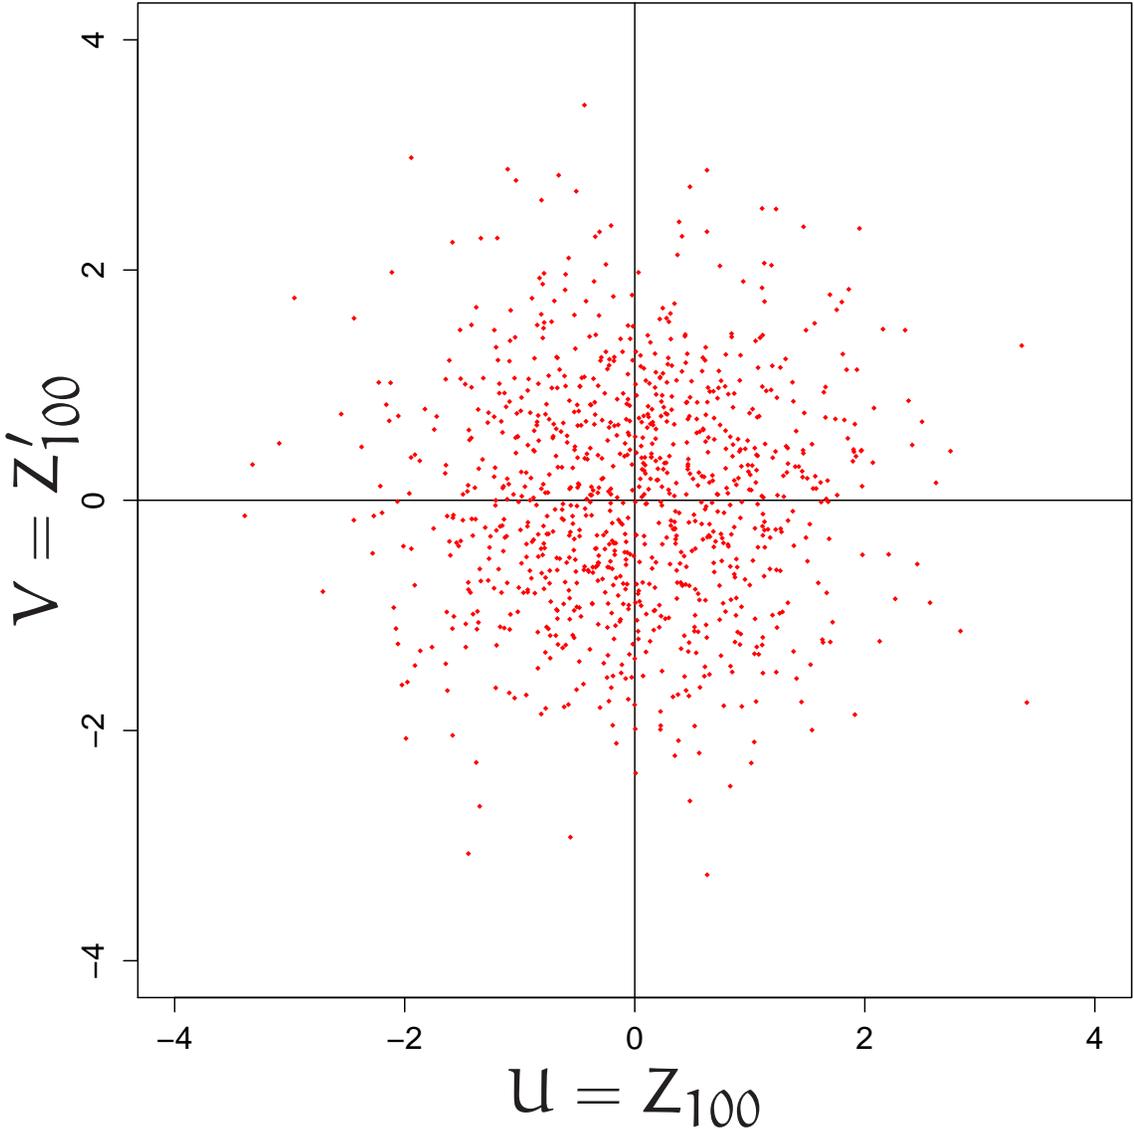
Glücklicher Einfall:

Nimm zwei unabhängige Kopien

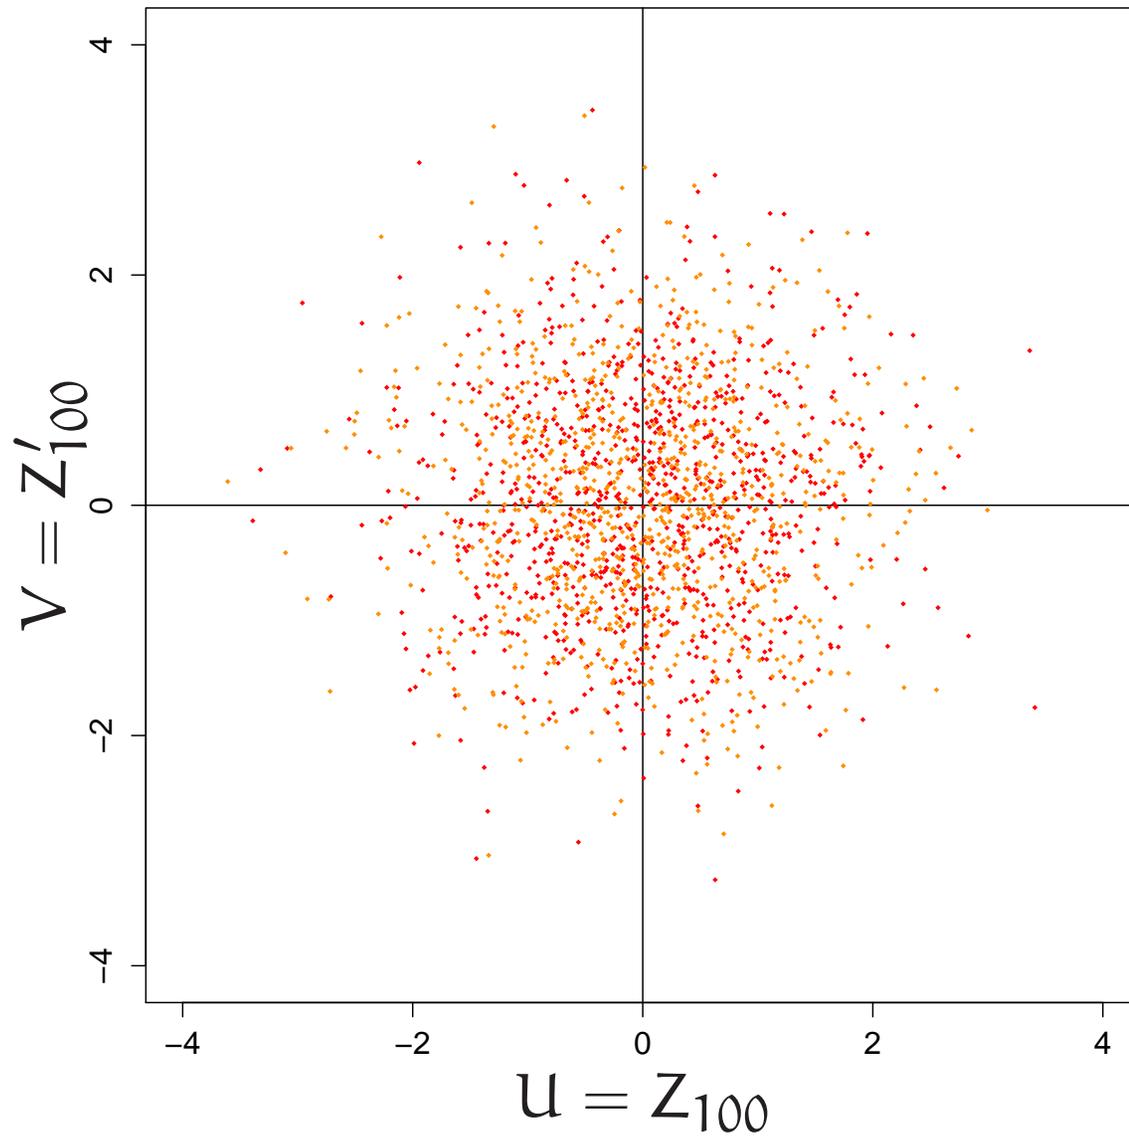
$$(U, V) := (Z_{100}, Z'_{100})$$

Wie sieht die gemeinsame Verteilung
von U und V aus?

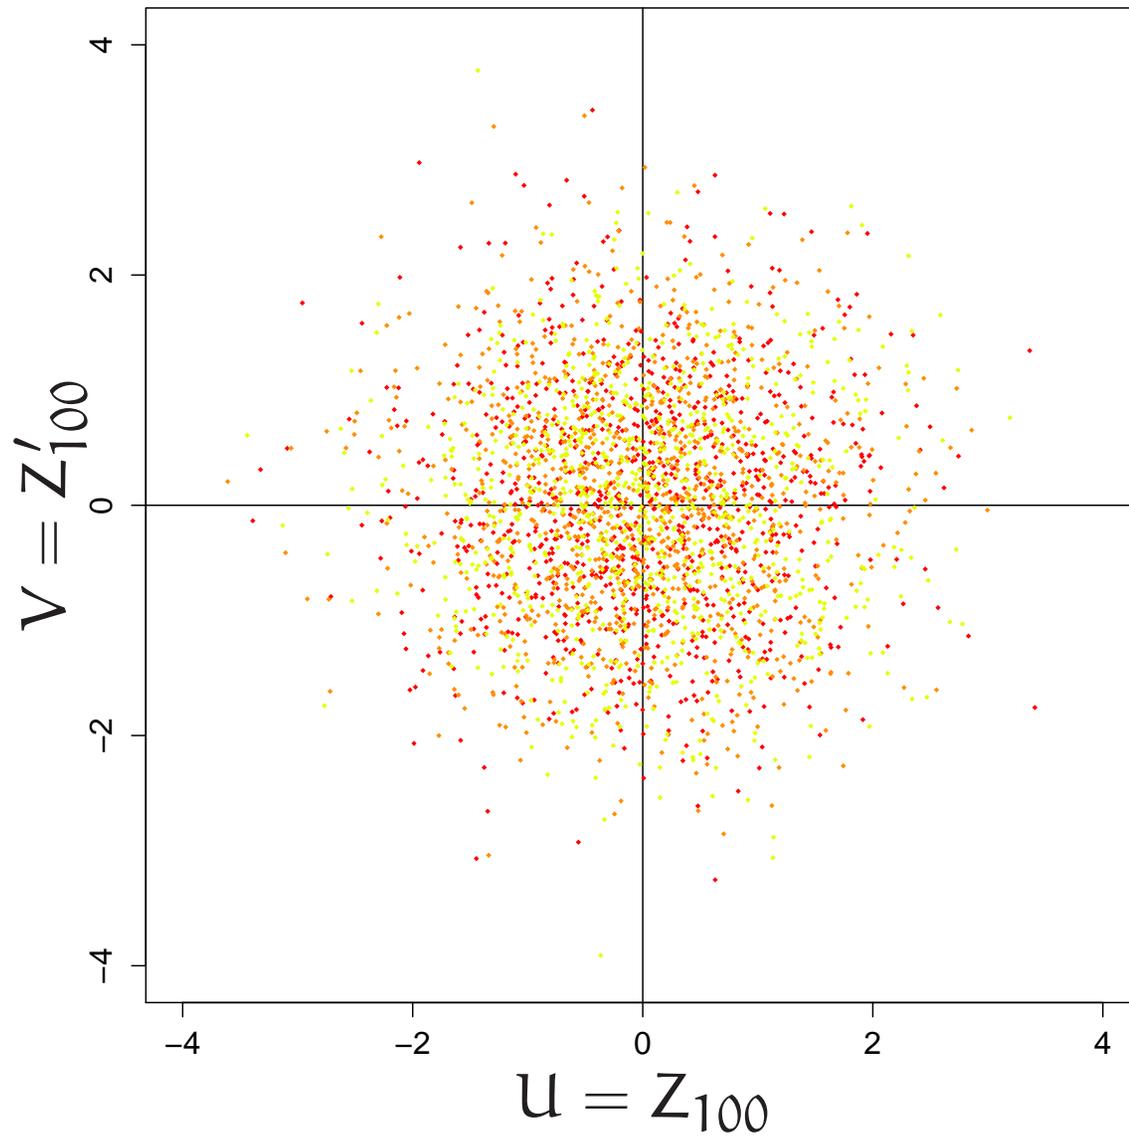
1000 Simulationen



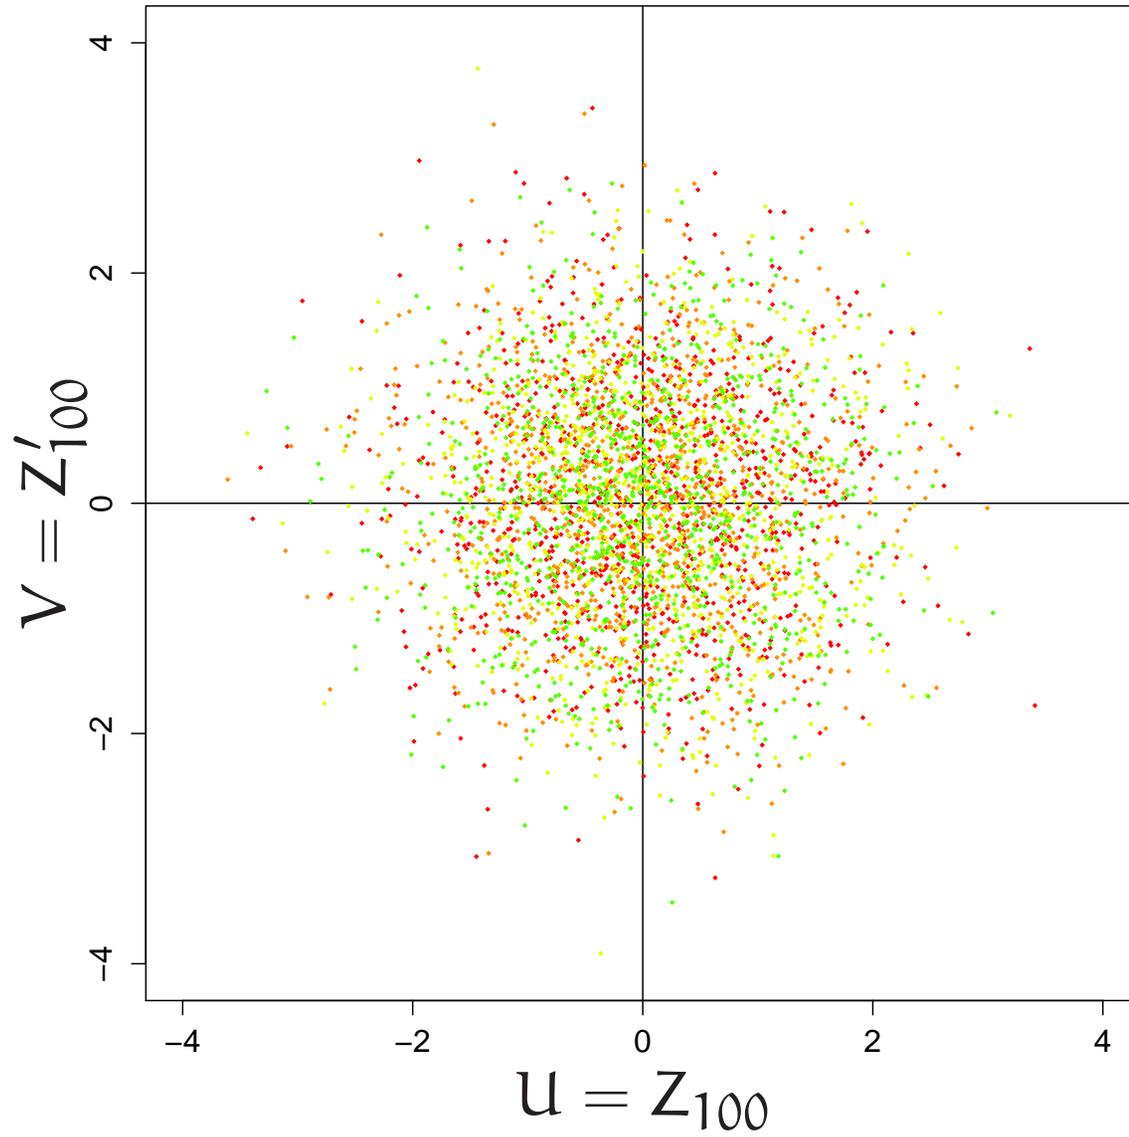
2000 Simulationen



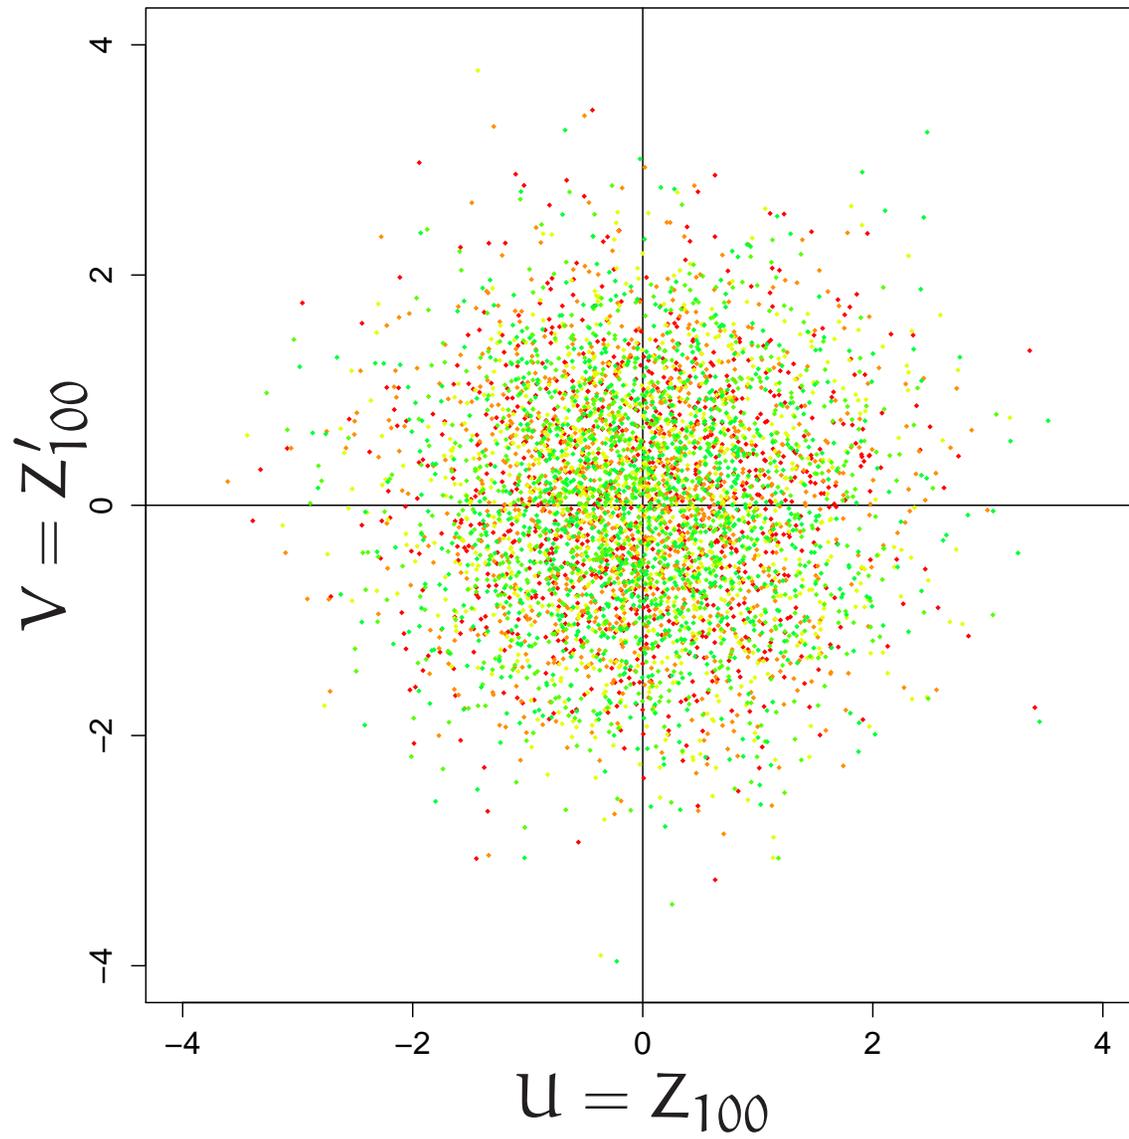
3000 Simulationen



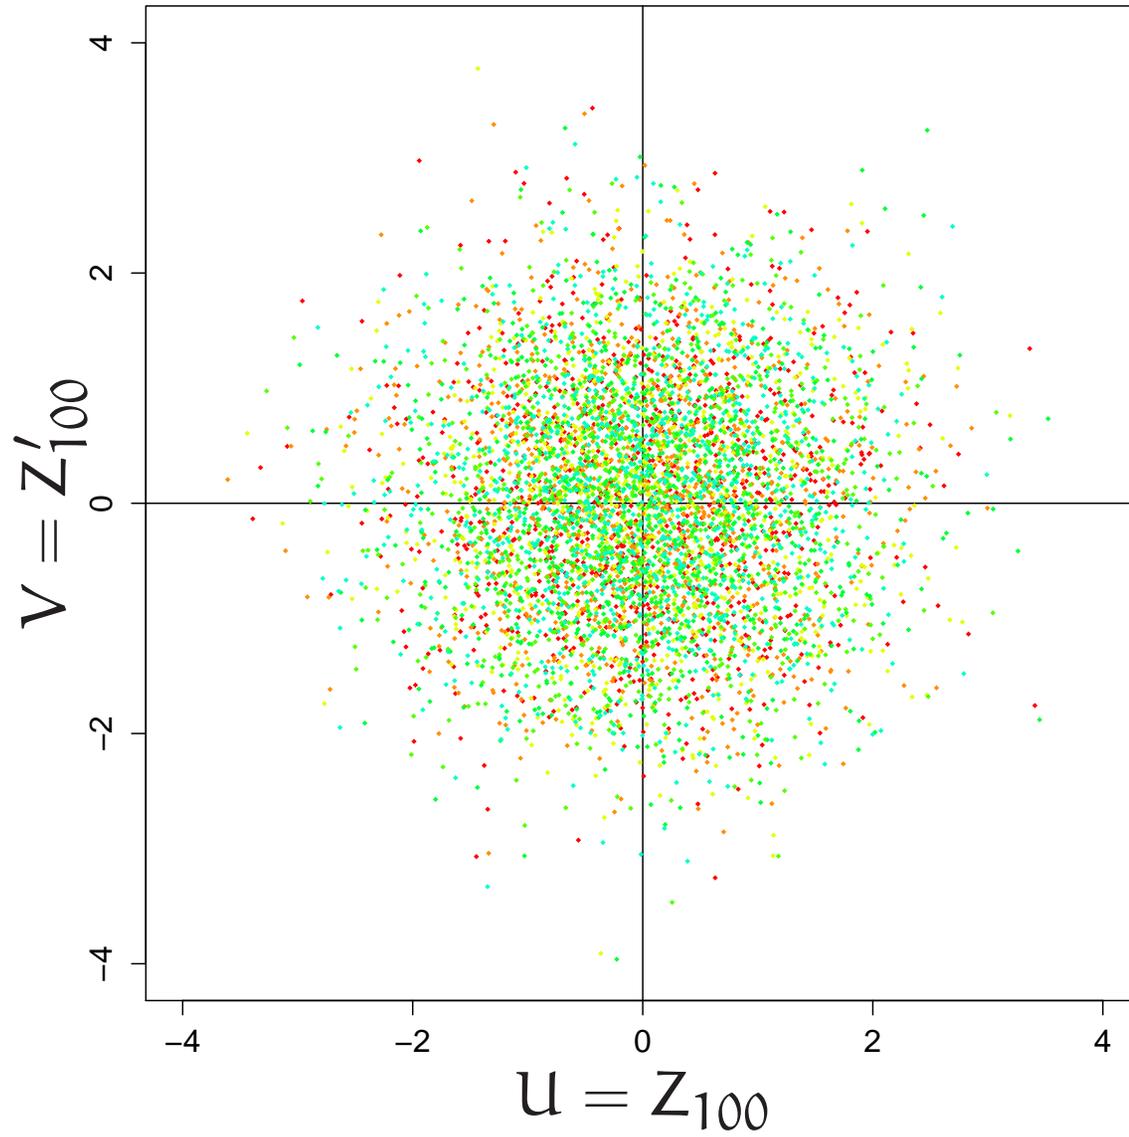
4000 Simulationen



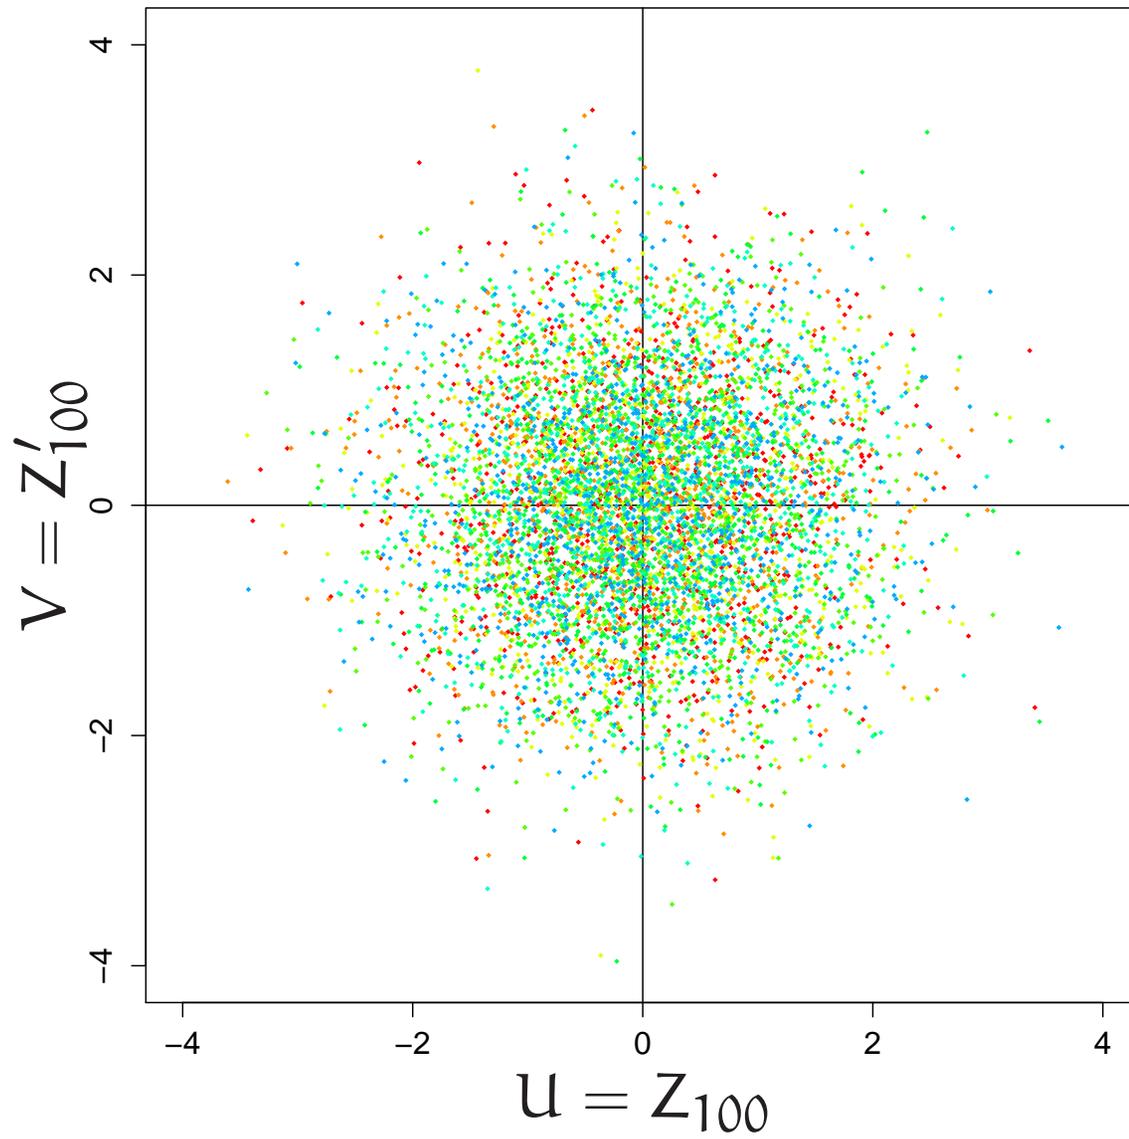
5000 Simulationen



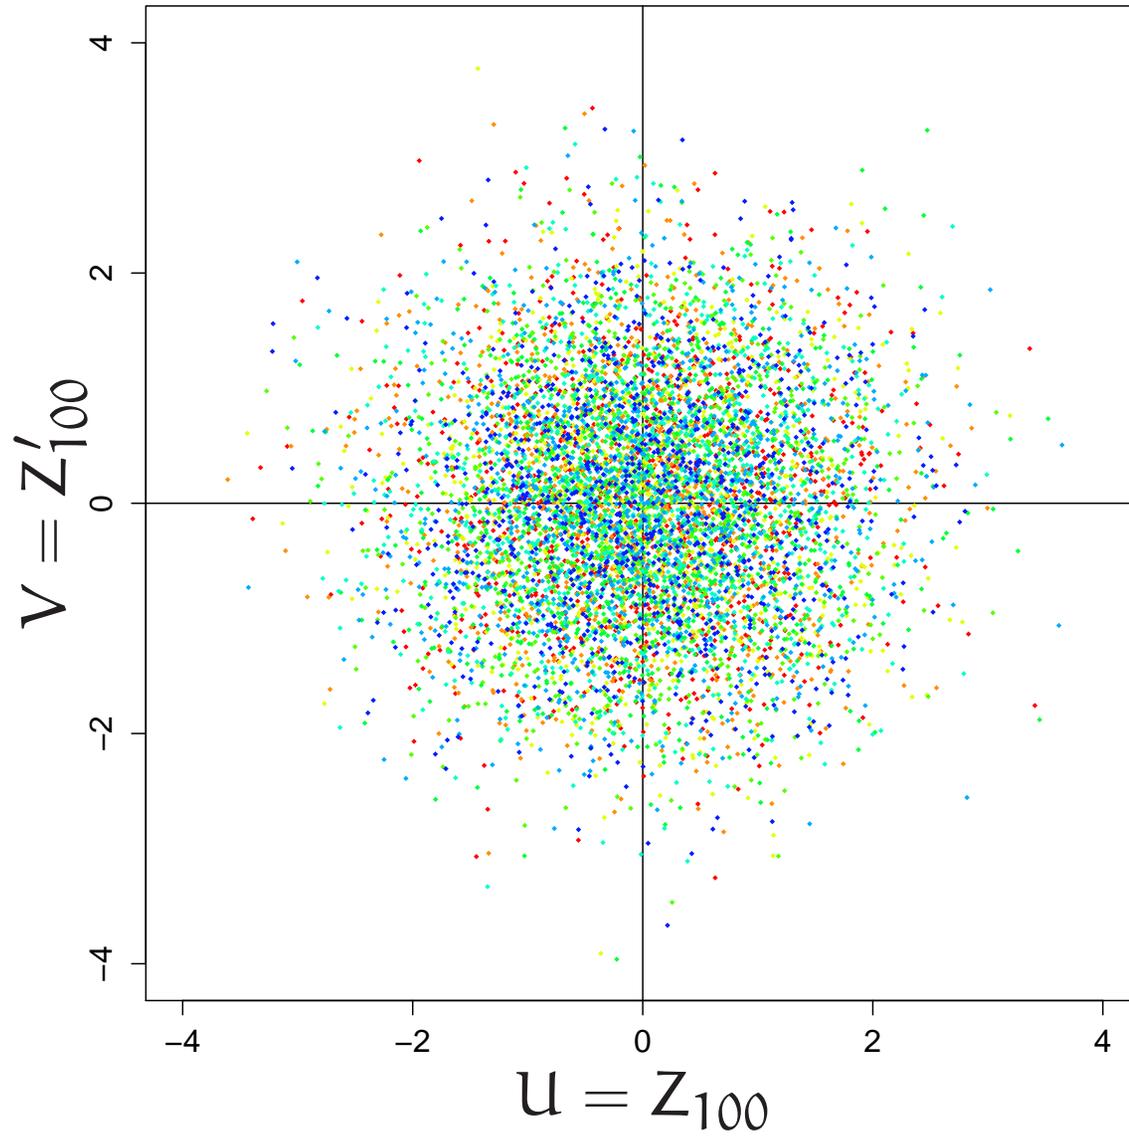
6000 Simulationen



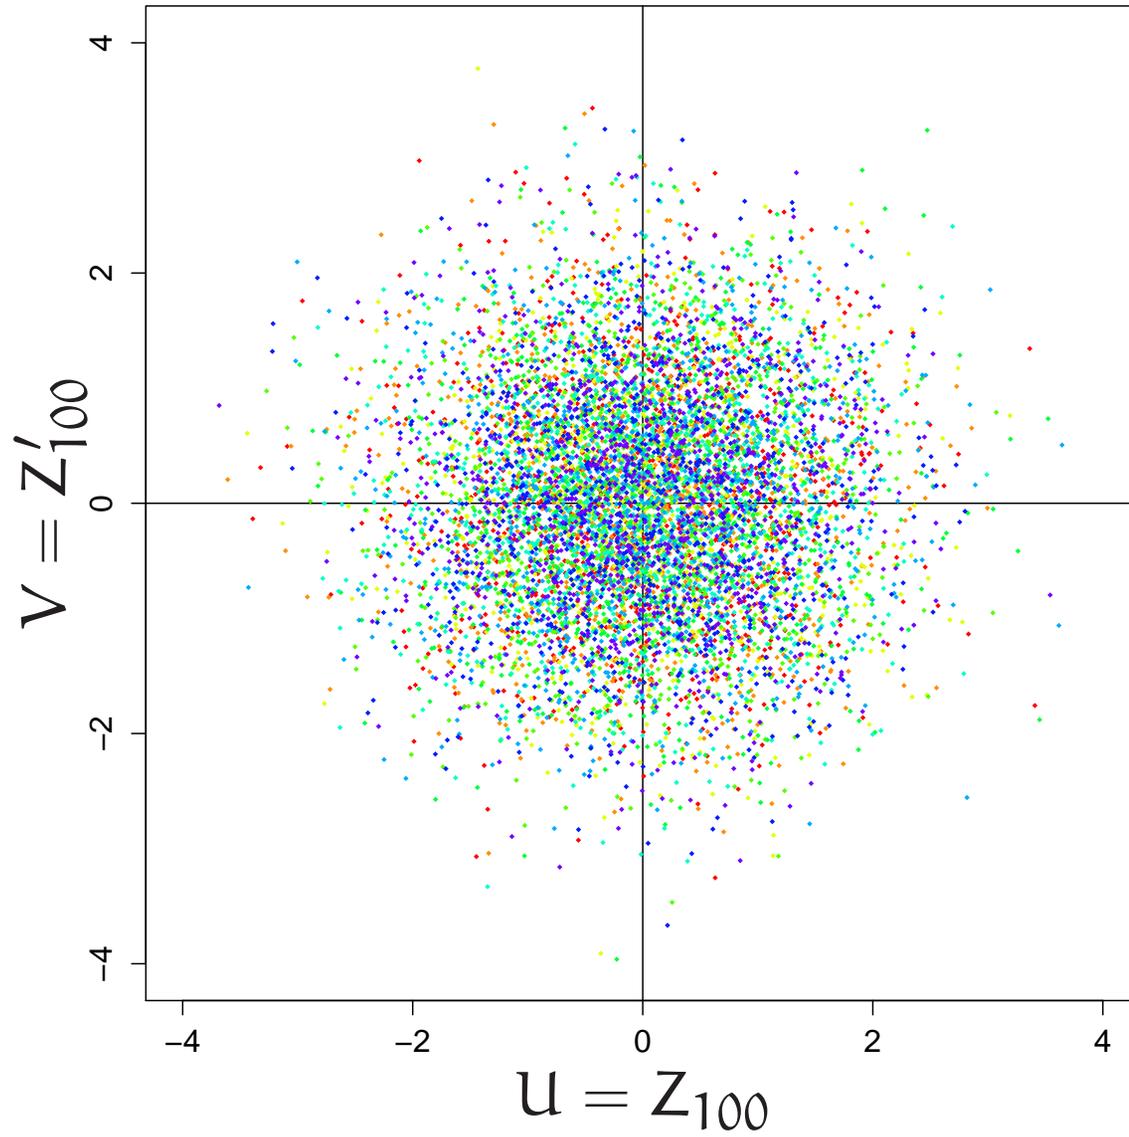
7000 Simulationen



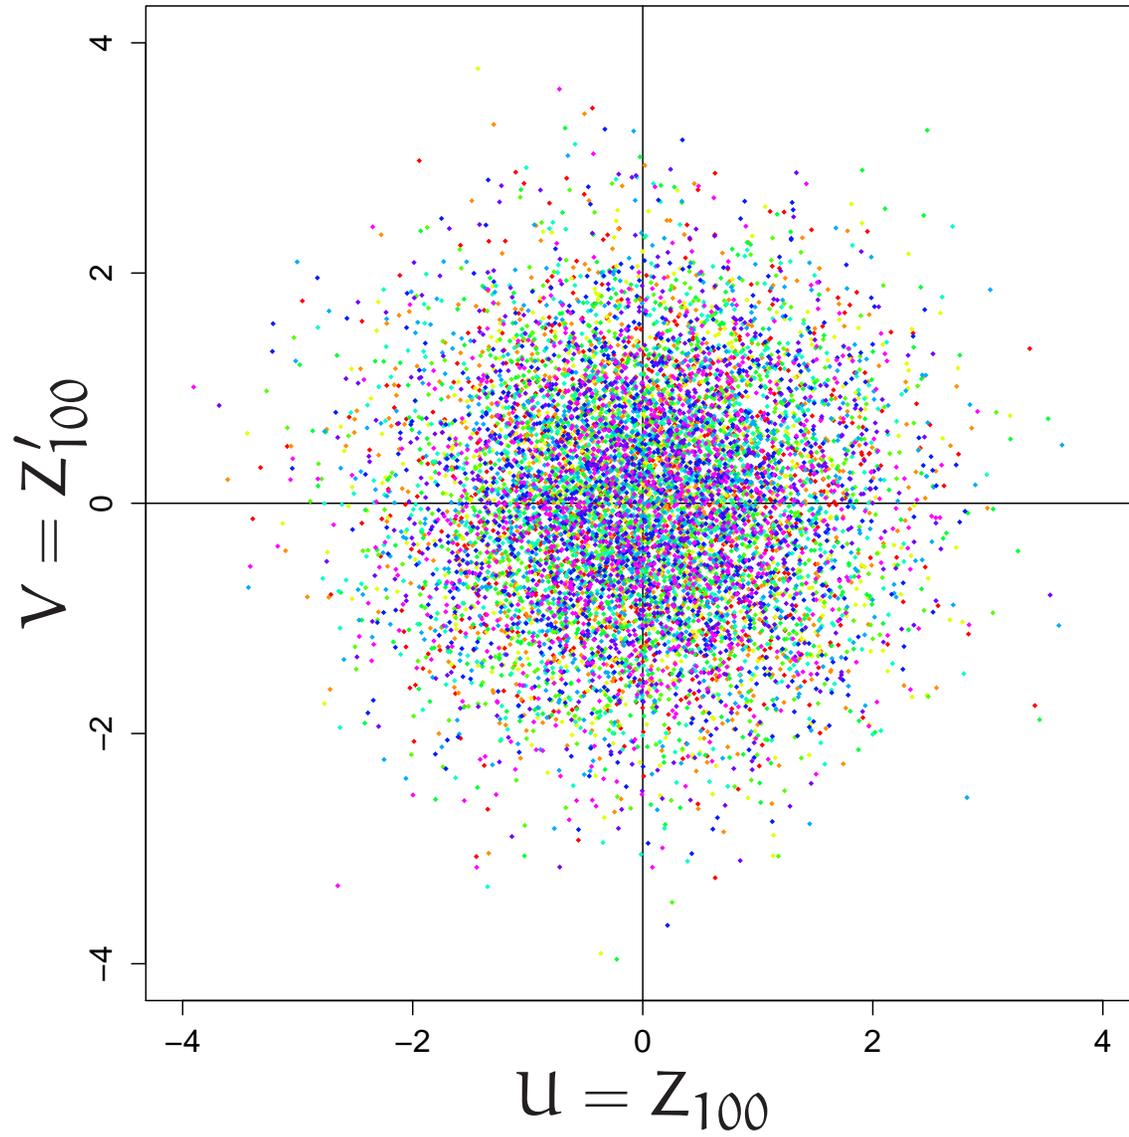
8000 Simulationen



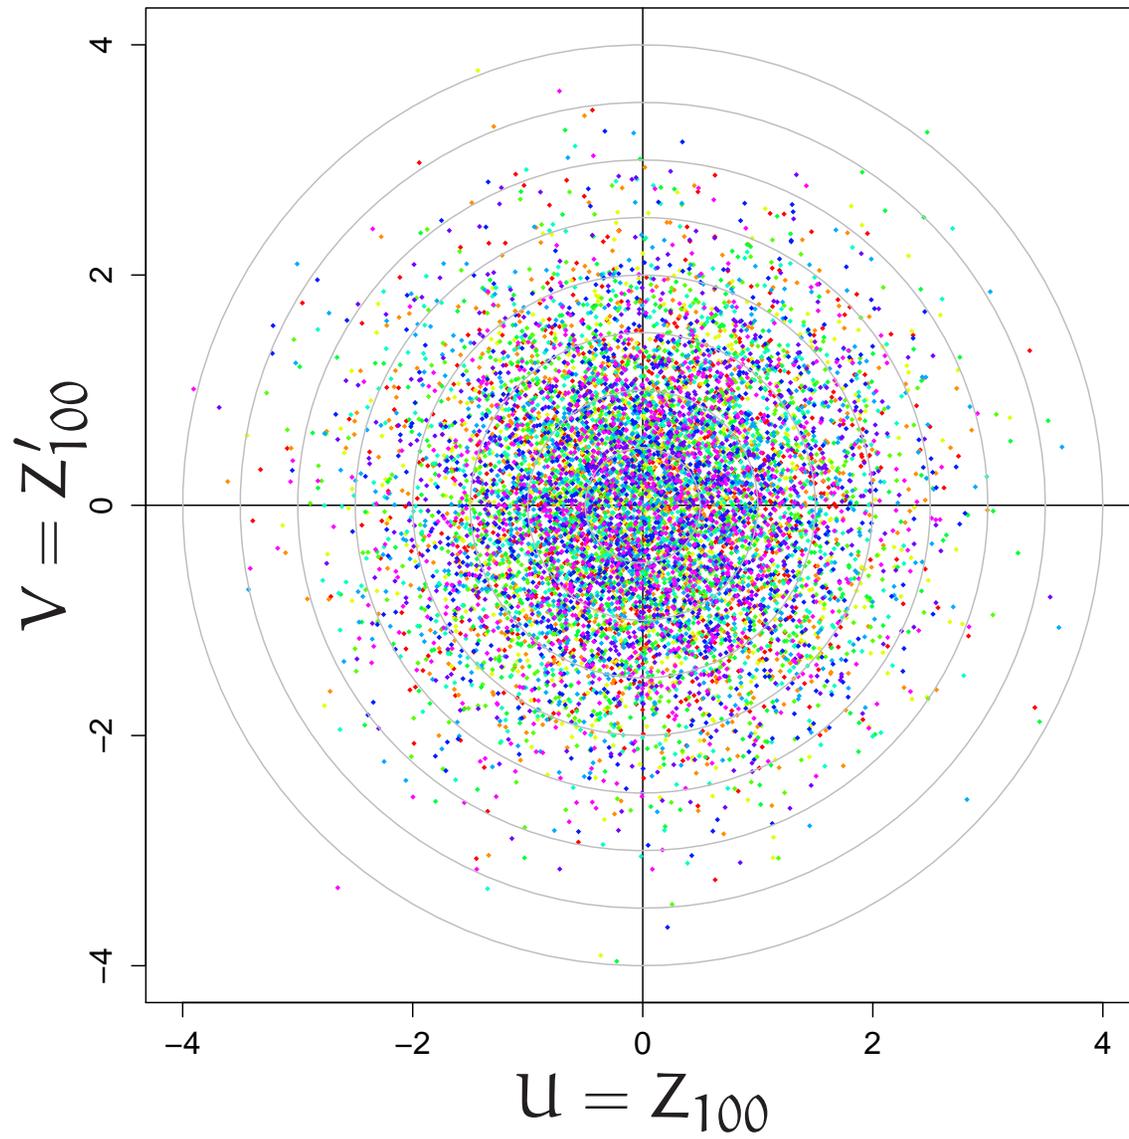
9000 Simulationen



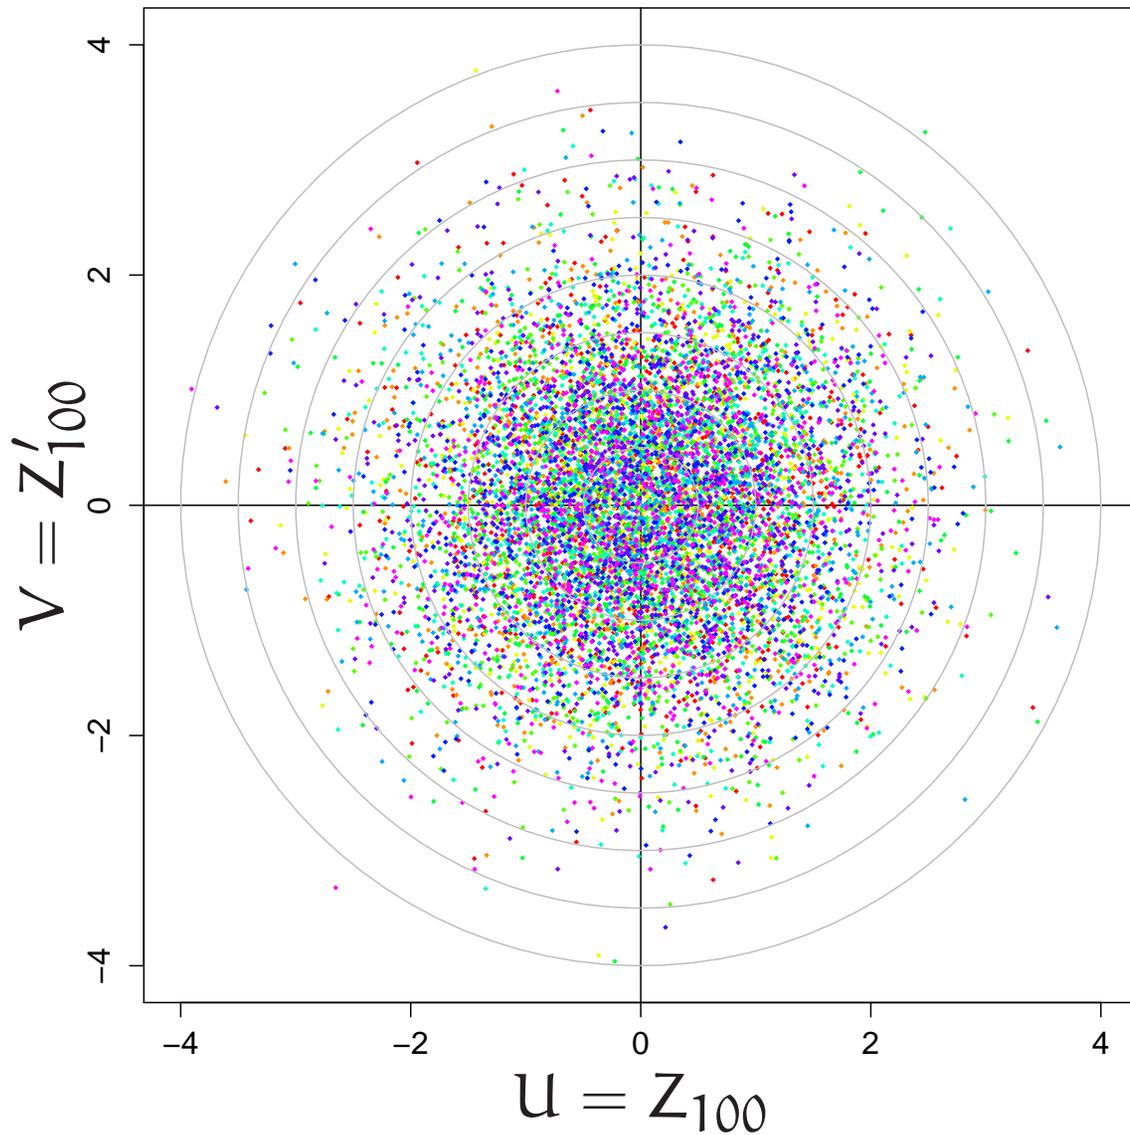
10000 Simulationen



10000 Simulationen



Die Verteilung von (U, V) ist annähernd rotationssymmetrisch!



5. Eine Charakterisierung der zweidimensionalen Standardnormalverteilung

Behauptung:

Aus “ U und V unabhängig und identisch verteilt’

und

“Verteilung von (U, V) rotationssymmetrisch”

folgt,

dass U und V normalverteilt sind:

$$f_U(x) = f_V(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-x^2/(2\sigma^2)}$$

Denn:

U, V unabhängig bedeutet:

$$f_{(U,V)}(a, b) = f_U(a)f_V(b)$$

$f_{(U,V)}$ *rotationssymmetrisch* heißt: es existiert ein g mit

$$f_{(U,V)}(a, b) = g(r) \quad r := \sqrt{a^2 + b^2}$$

Mit $f_U = f_V =: h$ folgt

$$h(a)h(b) = g(r)$$

$$h(a) h(b) = g(r), \quad r := \sqrt{a^2 + b^2}$$

Die zwei Paare (a, b) und $(0, \sqrt{a^2 + b^2})$ haben dasselbe r .

Also:

$$h(a) h(b) = h(0) h(\sqrt{a^2 + b^2})$$

Eine Lösung hiervon:

$$h(x) = e^{-x^2}$$

Denn

$$e^{-a^2} e^{-b^2} = 1 \cdot e^{-(a^2+b^2)}$$

$$h(a) h(b) = h(0) h(\sqrt{a^2 + b^2})$$

Wie sieht die allgemeine Lösung aus?

$$w(u) := h(\sqrt{u}), \quad u \geq 0, \text{ erfüllt}$$
$$w(a^2)w(b^2) = w(0)w(a^2 + b^2)$$

$$w(u)w(v) = k_0 w(u + v), \quad u, v \geq 0$$

hat als allgemeine Lösung

$$w(u) = k_0 e^{-k_1 u}$$

$$h(a) = w(a^2) = k_0 e^{-k_1 a^2}$$

FAZIT

Der Zentrale Grenzwertsatz

lässt sich erraten

(in konkreten Fällen,

mit etwas Glück).

Hier ist noch einmal die (im ZGS präzierte) Botschaft der Stunde:

**Summen (und Mittelwerte) von vielen unabhängigen,
identisch verteilten ZV mit endlicher Varianz
sind annähernd normalverteilt.**

Diese Aussage bleibt übrigens auch
unter schwächeren Bedingungen bestehen,
sowohl was die Unabhängigkeit,
als auch was die identische Verteiltheit betrifft.

Eine Botschaft zum Mitnehmen ins Leben
(salopp formuliert):

“Die Summe von vielen
annähernd unabhängigen Zufallsvariablen,
die nicht notwendig identisch verteilt, aber
ungefähr von derselben Größenordnung sind,
ist annähernd normalverteilt.”

6. Münzwurf und Zentraler Grenzwertsatz

Der Münzwurf passt in den Zentralen Grenzwertsatz:

Sei X_1, X_2, \dots , ein fortgesetzter p -Münzwurf. Dann ergibt sich aus dem Zentralen Grenzwertsatz der (alte)

Satz von de Moivre und Laplace:

Für Binomial- (n, p) -verteilte Zufallsvariable B_n (mit festem p)

gilt für alle $c < d \in \mathbb{R}$:

$$\mathbf{P} \left(\frac{B_n - np}{\sqrt{npq}} \in [c, d] \right) \xrightarrow{n \rightarrow \infty} \mathbf{P}(Z \in [c, d]).$$

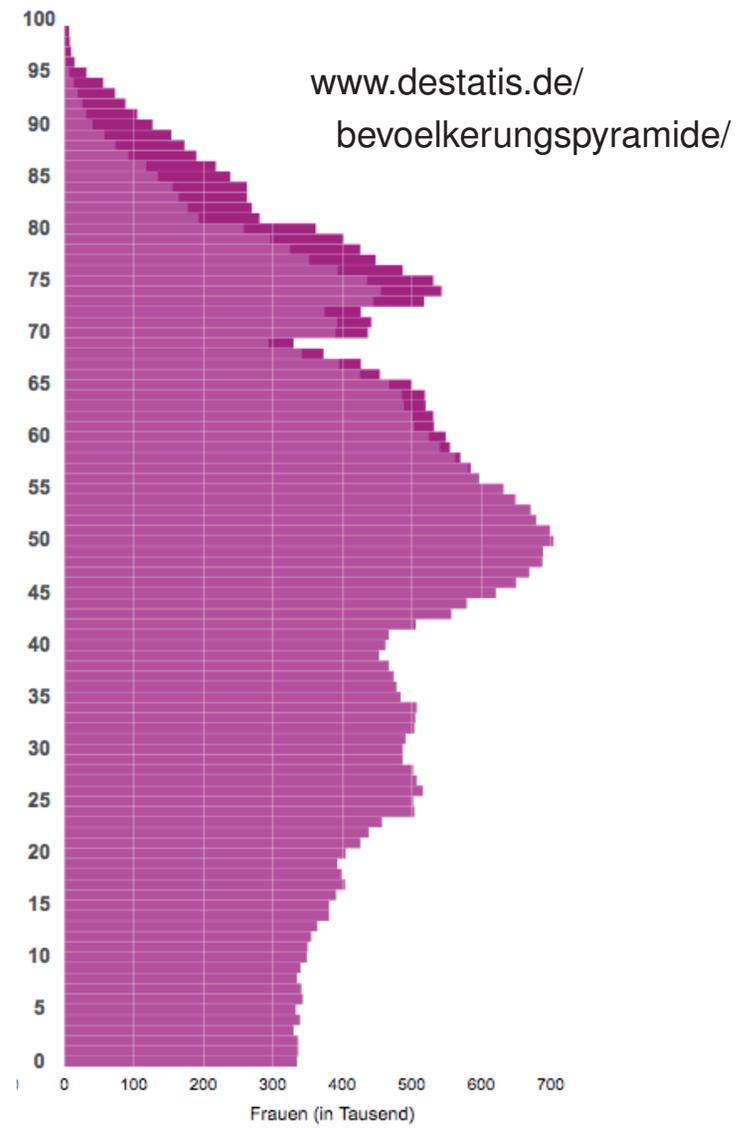
Dabei ist Z standard-normalverteilt.

7. Populationsmittelwert und Stichprobenmittelwert

Denken wir an eine Liste (eine “Population”)
von reellen Daten

$$w_1, \dots, w_g$$

z. B. die Lebensalter aller Frauen
in der deutschen Bevölkerung 2014



Angenommen man möchte den **Populationsmittelwert**

$$\mu := \frac{1}{g} \sum_{j=1}^g w_j.$$

schätzen,

und zwar aus den Werten einer
aus der Population gezogenen **Stichprobe**

$x_1, \dots, x_n.$

Als *Schätzwert* für μ bietet sich an:

$$\bar{x} := \frac{1}{n}(x_1 + \dots + x_n)$$

Wie zuverlässig ist diese Schätzung?

Goldene Idee der Statistik:

Man fasst x_1, \dots, x_n auf als Ergebnis eines rein zufälligen Ziehens aus der Population:

$$X_1 := w_{J_1}, X_2 := w_{J_2}, \dots$$

mit J_1, J_2, \dots rein zufällige Wahl aus $\{1, \dots, g\}$
("Ziehen mit Zurücklegen").

Wir setzen hier g als (sehr) groß gegenüber n voraus,
damit entstehen *auch*
beim n -maligen Ziehen *mit* Zurücklegen
Kollisionen nur mit (verschwindend) kleiner W'keit.

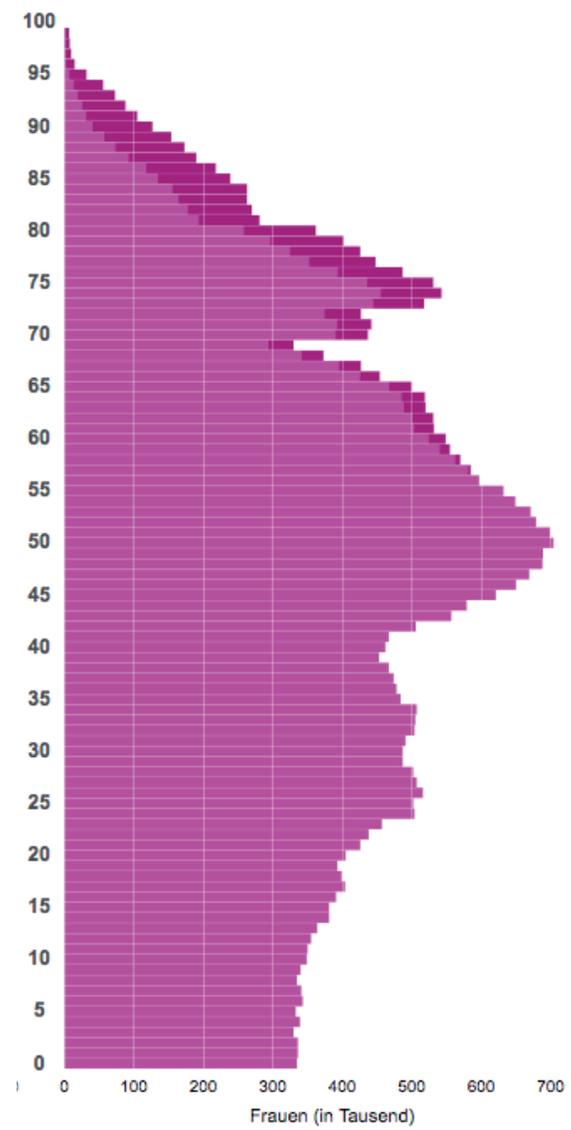
Das führt auf die Vorstellung:

x_1, \dots, x_n sind entstanden

durch n -maliges unabhängiges Ziehen X_1, \dots, X_n

aus der Verteilung ρ auf \mathbb{R}

mit $\rho([c, d]) := \frac{1}{g} \#\{i : w_i \in [c, d]\}$



$$m = \frac{1}{n}(x_1 + \dots + x_n)$$

fasst man also auf

als *eine* Realisierung (*einen* Ausgang)

der **Zufallsvariable**

$$M := \bar{X} := \frac{1}{n}(X_1 + \dots + X_n)$$

(Mittelwert der zufälligen Stichprobe (X_1, \dots, X_n))

Es gilt jedenfalls:

$$\mathbf{E}[M] = \mu$$

**Der Erwartungswert des Stichprobenmittelwertes
ist gleich dem Populationsmittelwert.**

8. Populationsvarianz und Varianz des Stichprobenmittelwertes

Der Populationsmittelwert war gleich $\mathbf{E}[X_1] = \mu$.

Wir haben

$$\mathbf{Var}[X_1] = \frac{1}{g} \sum_{j=1}^g (w_j - \mu)^2 =: \sigma^2$$

Diese Zahl σ^2 heißt auch die **Populationsvarianz**.

$$M = \frac{1}{n}(X_1 + \dots + X_n)$$

$$\mathbf{E}[M] = \mu$$

$$M = \frac{1}{n}(X_1 + \dots + X_n)$$

$$\mathbf{Var}[M] = ?$$

Wird mit Zurücklegen gezogen, dann sind die X_i unabhängig,
und es ergibt sich

$$\mathbf{Var}[M] = \frac{\sigma^2}{n}$$

Wird ohne Zurücklegen gezogen
und wäre die Populationsgröße g nicht sehr groß
gegenüber der Stichprobengröße n , dann hätte es Sinn,
die *Korrektur für endliche Populationen* zu berücksichtigen

(vgl. Aufgabe 23):

$$\mathbf{Var}[M] = \frac{\sigma^2}{n} \cdot \frac{g - n}{g - 1}$$

Wird ohne Zurücklegen gezogen
und wäre die Populationsgröße g nicht sehr groß
gegenüber der Stichprobengröße n , dann hätte es Sinn,
die *Korrektur für endliche Populationen* zu berücksichtigen

(vgl. Aufgabe 23):

$$\mathbf{Var}[M] = \frac{\sigma^2}{n} \cdot \frac{g - n}{g - 1}$$

Diese Korrektur werden wir
für den Rest dieser Vorlesung vernachlässigen (wir denken
an großes g , oder auch an ein
wiederholtes unabhängiges Ziehen aus einer Verteilung).

Dann gilt:

$$\mathbf{Var}[M] = \frac{\sigma^2}{n};$$

die Standardabweichung des Stichprobenmittelwertes M

ist also $\frac{\sigma}{\sqrt{n}}$.

9. Approximative Verteilung des Stichprobenmittelwertes

Wie ist (für nicht zu kleines n)
der Stichprobenmittelwert M verteilt?

Der Zentrale Grenzwertsatz gibt eine Antwort:

In der oben beschriebenen Situation gilt

M ist approximativ $N(\mu, \frac{\sigma^2}{n})$ -verteilt.

10. Die Stichprobenvarianz als Schätzung für die Populationsvarianz

Ein Problem in der Praxis: Im Allgem. kann man σ^2 nicht.

Auch σ^2 muss man dann schätzen.

Zwei Vorschläge für die

(aus der Stichprobe) **geschätzte** (Populations-) **Varianz**:

(i) die *Stichprobenvarianz*

$$\hat{\sigma}^2 := \frac{1}{n} \sum_{i=1}^n (x_i - m)^2.$$

(ii) die *modifizierte Stichprobenvarianz*

$$s^2 := \frac{1}{n-1} \sum_{i=1}^n (x_i - m)^2$$

Es gibt theoretische Begründung für beide Vorschläge
(vgl. Buch S. 124, S. 138).

Wir kommen darauf später zurück
und halten uns erst einmal an den Vorschlag (ii):

$$s^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - m)^2$$

Die Standardabweichung des Stichprobenmittelwertes \bar{X} ist

$$\frac{\sigma}{\sqrt{n}}.$$

Die geschätzte Standardabweichung
des Stichprobenmittelwertes \bar{X} ist

$$\boxed{s/\sqrt{n} =: f}$$

Diese Größe nennen wir auch den *Standardfehler*.

M ist approximativ $N(\mu, \frac{\sigma^2}{n})$ -verteilt.

Und (gut für die Praxis):

M ist approximativ $N(\mu, f^2)$ -verteilt.