

生起回数が負の二項分布に従う事象のシミュレーション

Hirotsugu Seike

2026 年 1 月 1 日

1 導入

負の二項分布は、偶然が起きる「環境」のバラつきを考慮した事象の発生回数に従う分布である。例えば、1 日の間にパソコン上で発生するエラー数、日毎の SNS 投稿数・感染数・事故の件数などのモデル化に用いられる。ここでは、事象の生起回数 N を確率変数として考え、 N がパラメータ α, p ($\alpha > 0, 0 < p < 1$) の負の二項分布に従うことを $N \sim \text{NB}(\alpha, p)$ で表す。

上記を表現するため、ある一定期間内での事象の平均生起回数 Λ が形状母数 α 、尺度母数 $1/\beta (> 0)$ のガンマ分布に従うと仮定し、事象の生起パターンがポアソン分布と同様であると仮定する。言い換えれば、次式が成立する。

$$P(N = n) = \int_0^\infty \frac{\lambda^n \exp(-\lambda)}{n!} \cdot \frac{\beta^\alpha}{\Gamma(\alpha)} \cdot \lambda^{\alpha-1} \cdot e^{-\beta\lambda} d\lambda, \quad (1)$$

$$= \frac{\beta^\alpha}{n! \Gamma(\alpha)} \int_0^\infty \lambda^{n+\alpha-1} \cdot e^{-(\beta+1)\lambda} d\lambda, \quad (2)$$

$$= \frac{\beta^\alpha}{n! \Gamma(\alpha)} \cdot \frac{\Gamma(n+\alpha)}{(\beta+1)^{n+\alpha}}. \quad (3)$$

ここで、 $p = \beta/(\beta+1)$ と定義すれば、次式が得られる。

$$P(N = n) = \frac{\Gamma(n+\alpha)}{\Gamma(n+1)\Gamma(\alpha)} \cdot \left(\frac{\beta}{\beta+1}\right)^\alpha \cdot \left(\frac{1}{\beta+1}\right), \quad (4)$$

$$= {}_{n+\alpha-1}C_{\alpha-1} \cdot p^\alpha \cdot (1-p)^n. \quad (5)$$

2 シミュレーション

生起回数が負の二項分布に従う事象の離散時間シミュレーションは、例えば図 1 のようにして実施できる。固定のタイムフレーム T 毎に、平均生起回数 Λ をガンマ分布に従う確率変数として抽出し、時間 T が経過するまで、平均 $1/\Lambda$ の指数分布に従う事象を発生させている。

```
import numpy as np
from collections import Counter
import math

# =====
# シミュレーション本体
# =====

def simulate_one_trial(alpha, beta, T):
```

```

"""
試行分のイベント生成1
alpha, beta: Gamma(alpha, beta) の shape, rate
T: タイムフレーム
Lambda: Tあたりの平均事象数
"""
# Lambda ~ (あたりの平均事象数) Gamma T
Lambda = np.random.gamma(shape=alpha, scale=1.0 / beta)

# 単位時間あたりの rate
rate = Lambda / T

t = 0.0
event_times = []

while True:
    # 平均 T / Lambda の指数分布
    t += np.random.exponential(scale=1.0 / rate)

    if t > T:
        break

    event_times.append(t)

return Lambda, event_times

# =====
# 負の二項分布 (理論値) : PMF
#  $N(T) \sim NB(\alpha, p)$ ,  $p = \text{beta} / (\text{beta} + 1)$ 
# =====

def negbin_pmf(n, alpha, beta):
    p = beta / (beta + 1.0)
    return (
        math.gamma(n + alpha)
        / (math.gamma(alpha) * math.factorial(n))
        * (p ** alpha)
        * ((1 - p) ** n)
    )

# =====
# 検証用コード
# =====

if __name__ == "__main__":
    # パラメータ
    alpha = 3.0
    beta = 2.0
    T = 4.0

    n_trials = 20000

    counts = []
    lambdas = []

    for _ in range(n_trials):

```

```

        lam, events = simulate_one_trial(alpha, beta, T)
        lambdas.append(lam)
        counts.append(len(events))

counts = np.array(counts)

# ---- 基本統計量 ----
print("=== Basic statistics ===")
print("Mean count: ", counts.mean())
print("Variance count: ", counts.var())
print("Mean lambda: ", np.mean(lambdas))
print()

# 理論値
theo_mean = alpha / beta
theo_var = theo_mean + (theo_mean ** 2) / alpha

print("=== Theoretical (Negative Binomial) ===")
print("Theoretical mean: ", theo_mean)
print("Theoretical var: ", theo_var)
print()

# ---- 分布比較 (最初の数点) ----
print("=== Empirical vs Theoretical PMF ===")
freq = Counter(counts)
max_k = 8

for k in range(max_k + 1):
    emp = freq[k] / n_trials
    theo = negbin_pmf(k, alpha, beta)
    print(f"k={k:2d} empirical={emp:.4f} theoretical={theo:.4f}")

```

図 1: Simulation code for events whose counts follow a negative binomial distribution.

参考文献

付録 A 特になし