

ランダム打ち切りを含む データによるハードディスクドライブの 信頼性の近似推定について

小 泉 大 城

概要

本稿では、ランダム打ち切りを含むデータを用いて、2パラメータワイブル分布の最尤推定問題を近似的に解くことで、デジタル機器の補助記憶装置として広く用いられてきたハードディスクドライブ (Hard Disk Drive, HDD) の稼働時間を主に信頼性工学の観点から考察を行った。パラメータ推定にあたっては、米国Backblaze社により公開されている2018年から2021年までの約18万件のHDDのデータを利用した。信頼性工学の観点からは、これらのデータはHDDの故障の有無に応じて、HDDに電源が初めて入ってから故障するまでの稼働時間としての完全データと、未故障状態における当座の稼働時間としての不完全データ、すなわち今回該当するランダム打ち切りデータの2種類に大別される。両種類のデータからワイブル分布の形状および尺度パラメータの最尤推定値を近似的に数値計算したうえで考察を行ったところ、以下のことが明らかになった。(1) 故障したのべ約6,000件の寿命の完全データのみから推定されたワイブル分布の形状パラメータは1より大きくなり、これは摩耗故障期であることを強く示唆する。(2) 完全データのみから推定された平均故障時間 (MTTF) は、おおむね1-4年程度。(3) ランダム打ち切りを含むデータ約18万件から推定された形状パラメータも9種類で1より大きくなり、故障しなかったHDDのデータを考慮してもやはり摩耗故障期であることを強く示唆する。(4) ランダム打ち切りを含むデータ全体に占める完全データの割合が15-25%程度のデータから近似最尤推定されたHDDの平均故障時

間 (MTTF) は, 5-8年程度. (5) HDD 業界で使われている寿命の指標としての年間故障率 (AFR) は, 本稿で推定された故障率関数による値とよく一致する.

1 はじめに

1. 1 研究背景

製品やシステムなどの設計にあたり, 確率モデルを用いた部品の信頼性の分析は, 品質管理や信頼性工学などの視点からさかんに研究されてきた分野のひとつである. こうした分析に使われる確率分布としては, ポアソン分布, 指数分布, 二重指数分布, 正規分布, 対数正規分布, ガンマ分布, ワイブル分布などが挙げられる [1,2,3]. 特にワイブル分布 [4,5,6] は, この分野でよく使われる連続型確率密度関数のひとつである. Mann [7] によると, ワイブル分布は, 1928年に Fisher と Tippett の極値分布に関する研究に関連して初めて取り扱われ, しばらくは Fisher-Tippett Type III という名前で知られていた. 1939年になってスウェーデンの Waloddi Weibull が同様の確率分布を導出 [4] し, 1951年に Weibull 自身がさらにいくつかの応用例を発表 [5] するなどの経緯から, 今日までワイブル分布と呼ばれている. 以後, 形状および尺度パラメータにより定義される2パラメータワイブル分布を基礎として, 統計学や信頼性工学などの分野にまたがり様々な研究成果が報告されており [8,9,10], 近年, 執筆者もいくつか報告を行った [11,12,13,14,15].

信頼性工学においては, 統計学における確率密度関数 (probability density function) の定義にもとづいて, 累積分布関数 (cumulative distribution function), 信頼度関数 (reliability function), 故障率関数 (hazard function), 平均故障時間 (mean time to failure), あるいは平均故障間隔 (mean time between failure) などが導出され, 分析対象の信頼性の指標として利用される. このうち, 故障率関数について, 縦軸に故障率関数, 横軸に時間を取ったプロットは, バスタブ型曲線 [3] としてよく知られている. バスタブ型曲線では,

部品の故障率が時間とともに3つのパターンに変化する様子が表現されており、第1のパターンとして、故障率が時間とともに単調減少する decreasing failure rate (DFR)、第2に故障率が時間に関して一定で推移する constant failure rate (CFR)、第3に故障率が時間とともに単調増加する increasing failure rate (IFR) がある。これら3つのパターンで表現されるバスタブ型曲線により、部品の稼働開始直後の初期故障の発生期に始まり、やがて安定的に稼働する偶発故障の発生期を経て、いつしか故障して稼働できなくなる摩耗故障の発生期に至るまで、部品の典型的なライフサイクルの統計モデル化が可能である。特に確率密度関数として2パラメータワイブル分布を定義すると、その故障率関数は形状パラメータが1未満の場合にDFR,1に等しい場合にCFR,1より大きい場合にIFRに対応するということから、この分野でワイブル分布が頻繁に利用される根拠のひとつとなっている。

つぎに、観測データについて、同じく信頼性工学の観点から考えてみる。ある部品が稼働を始めてから故障するまでの時間が観測されたとき、このデータは寿命の完全データ [1,2] と呼ばれる。部品がまだ故障せず、稼働している状態で観測を止めて時間を記録した場合、そのデータは不完全データの種類として、特に打ち切りデータ [1,2] と呼ばれる。さらにこの打ち切りに特に統一的な規則性がない場合に得られたデータをランダム打ち切りデータ [1,2] と呼ぶ。本稿で分析対象とするハードディスクドライブ (Hard Disk Drive, HDD) の寿命データについても、稼働を始めてから故障した時間としての完全データと、まだ故障していないが稼働を始めてからの経過時間としてのランダム打ち切りデータの集合となっている。

最後に2パラメータワイブル分布のパラメータ推定法について、信頼性工学の分野において、ワイブル確率紙 [2] は手軽にワイブル分布のパラメータ推定値を得られる手法のひとつとされてきた。これは、ワイブル分布の分布関数を対数変換すると直線になることを利用し、専用の図面に観測データをプロットしてから目盛を読むことで、形状および尺度パラメータの推定値を得る、というものである。この方法は、部品の寿命の完全データの数が少ない場合など

でも、現場で手軽にパラメータ推定を行うことができるという長所があるが、視覚的な手法であるため推定の基準が必ずしも明確でないという短所がある。一方で、ワイブル分布の2種のパラメータの最尤推定法については、McCool [9]やRockette [10]をはじめとした数多くの研究がある。また、打ち切りデータを含むワイブル分布の2種のパラメータの最尤推定法については、Cohen [8]により提案されている。その他、ワイブル分布の様々なパラメータ推定法の歴史や関係等については、Evansらによる解説 [16] が詳しい。

1. 2 研究目的

本稿では、米国Backblaze社が公開しているのべ約18万件のHDDの寿命データ [18] を対象に、HDDの型番ごとに2パラメータワイブル分布のパラメータを近似最尤推定し、寿命特性を分析することを目的とする。1. 1節で述べたように、このデータはHDDの寿命の完全データと、ランダム打ち切りデータの両方を含む。不完全データとしての打ち切りデータは、本来観測されるはずの完全データの下限を意味するが、完全データに加えてこれらの打ち切りデータも活用することで、より精確な推定結果を得られる可能性がある。さらに、HDDの型番ごとのデータ数（完全データとランダム打ち切りデータの総和）は、多くの型番（計11種の型番のうち9種）で1,000件を超えていることから、最尤推定法の有効性も期待される。

HDDの寿命特性としては、形状パラメータの最尤推定値にもとづく、1. 1節で述べたバスタブ曲線を利用した部品のライフサイクルの分析、および2つのパラメータの近似最尤推定量を代入することによる平均故障時間 (MTTF) や故障率関数の推定を行う。これらをHDDの型番別に、完全データのみの場合と、ランダム打ち切りを含むデータの場合で行い、推定結果を考察する。一方でHDD業界では、年間故障率 (Annual Failure Rate, AFR) がHDDの寿命の指標となっている。AFRは、型番ごとにHDDの故障発生回数を総稼働時間で割り、1年稼働した場合の故障率に換算するという単純な計算式によっているが、このAFRと本稿で得られる推定故障率とを比較することで、AFRの指

標としての妥当性についても考察する。

最後に本稿の構成を述べる。つぎの2章では、準備として、信頼性工学における2パラメータワイブル分布について基本的な定義を行う。3章では、2パラメータワイブル分布のパラメータの近似最尤推定法について整理する。4章では、HDDの寿命データの仕様を説明し、データ解析の手順を説明してから推定結果を述べる。5章で得られた結果にもとづく考察を行い、6章でまとめを行う。

2 準備

2.1 信頼性工学におけるワイブル分布

いま、 $T \geq 0$ を部品の寿命時間とし、これを連続型確率変数とする。 T の実現値を $t \geq 0$ とし、パラメータ $m, \lambda > 0$ をそれぞれ形状、尺度パラメータとする2パラメータワイブル分布 [3,6] の確率密度関数 $f(t)$ は、定義 2.1 で与えられる。

定義 2.1 (2パラメータワイブル分布の確率密度関数)。

$$f(t) = \frac{m}{\lambda} \left(\frac{t}{\lambda}\right)^{m-1} \exp\left[-\left(\frac{t}{\lambda}\right)^m\right]. \quad (1)$$

■

ワイブル累積分布関数 $F(t)$ は、 $f(x)$ を x に関して 0 から t まで積分した累積確率として定式化され、定義 2.2 で与えられる。

定義 2.2 (ワイブル累積分布関数)。

$$\begin{aligned} F(t) &= \int_0^t f(x) dx \\ &= 1 - \exp\left[-\left(\frac{t}{\lambda}\right)^m\right]. \end{aligned} \quad (2)$$

■

ワイブル信頼度関数 $R(t)$ は, $f(x)$ を x に関して t から $+\infty$ まで積分した累積確率として定式化され, 定義 2.3 で与えられる.

定義 2.3 (ワイブル信頼度関数).

$$\begin{aligned} R(t) &= \int_t^{+\infty} f(x)dx \\ &= 1 - F(t) \\ &= \exp\left[-\left(\frac{t}{\lambda}\right)^m\right]. \end{aligned} \quad (3)$$

■

ワイブル故障率関数 $h(t)$ は, 時刻 t における瞬間故障率を意味し, 定義 2.4 で与えられる.

定義 2.4 (ワイブル故障率関数).

$$\begin{aligned} h(t) &= \frac{f(t)}{R(t)} \\ &= \left(\frac{m}{\lambda^m}\right)t^{m-1}. \end{aligned} \quad (4)$$

■

ここで, 横軸に t , 縦軸にワイブル故障率関数 $h(t)$ を取りグラフを描くと, 1. 1 節で述べたバスタブ型曲線を表すことができる. さらに形状パラメータが $m < 1$ の場合は DFR, $m = 1$ の場合は CFR, $m > 1$ の場合は IFR に対応するのも同じく 1. 1 節で述べたとおりである.

平均故障時間 (Mean Time to Failure, MTTF) は, 定義 2.1 で定義した確率密度関数 $f(t)$ の期待値として, 定義 2.5 で与えられる.

定義 2.5 (ワイブル平均故障時間, MTTF).

$$E(T) = \int_0^{+\infty} t f(x)dt \quad (5)$$

$$= \lambda \Gamma\left(1 + \frac{1}{m}\right), \quad (6)$$

ただし、 $\Gamma(\cdot)$ は式(7)で定義されるガンマ関数である。

$$\Gamma(\alpha) = \int_0^{+\infty} x^{\alpha-1} \exp(-x) dx, \alpha > 0. \quad (7)$$

■

3 ワイブル分布のパラメータ推定

本章では、3.1節、3.2節でそれぞれ、完全データ、ランダム打ち切りを含むデータの場合の2パラメータワイブル分布のパラメータの近似最尤推定法を整理する。

3.1 完全データによるパラメータ推定

定義 2.1 の $f(t)$ のもとで長さ n の系列 $\{t_1, t_2, \dots, t_n\}$ を観測したとき、パラメータ m, λ による尤度関数 $L_1(m, \lambda)$ は、定義 3.1 で与えられる。

定義 3.1 (完全データによる尤度関数)。

$$\begin{aligned} L_1(m, \lambda) &= \prod_{i=1}^n f(t_i) \\ &= \prod_{i=1}^n \frac{m}{\lambda} \left(\frac{t_i}{\lambda}\right)^{m-1} \exp\left[-\left(\frac{t_i}{\lambda}\right)^m\right]. \end{aligned} \quad (8)$$

■

式(8)を最大化する m, λ をそれぞれ $\hat{m}_1, \hat{\lambda}_1$ とすると、これらは最尤推定量として定義 3.2 で与えられる。

定義 3.2 (完全データによる最尤推定量)。

$$\left\{ \begin{array}{l} \hat{m}_1 = \arg \max_m L_1(m, \lambda); \\ \hat{\lambda}_1 = \arg \max_\lambda L_1(m, \lambda). \end{array} \right. \quad (9)$$

■

最尤推定量が満たす極値条件より, $\hat{m}_1, \hat{\lambda}_1$ が満たす必要条件は, 補題 3.1 で与えられる [8].

補題 3.1 (完全データによる最尤推定量の必要条件 [8]).

$$\left\{ \begin{array}{l} \left[\frac{\sum_{i=1}^n (t_i)^{\hat{m}_1} \ln t_i}{\sum_{i=1}^n (t_i)^{\hat{m}_1}} - \frac{1}{\hat{m}_1} \right] - \frac{1}{n} \sum_{i=1}^n \ln t_i = 0; \\ \hat{\lambda}_1 = \left[\frac{\sum_{i=1}^n (t_i)^{\hat{m}_1}}{n} \right]^{\frac{1}{\hat{m}_1}}. \end{array} \right. \quad (10)$$

■

McCool [9] や Rockette [10] によれば, 式(10)を満たす $\hat{m}_1, \hat{\lambda}_1$ の組は, ただひとつ存在することが示されている. ただし, 本稿では数値計算の意味での近似最尤推定となる.

3. 2 ランダム打ち切りデータを含むデータによるパラメータ推定

いま, 長さ n の系列 $\{t_1, t_2, \dots, t_n\}$ を寿命時間に関する完全データ, 長さ r の系列 $\{u_{n+1}, u_{n+2}, \dots, u_{n+r}\}$ をランダム打ち切りデータとする. ここで, ランダム打ち切りをしなかったとしたら得られるはずの完全データを $\{t_{n+1}, t_{n+2}, \dots, t_{n+r}\}$ で表すと, ランダム打ち切りデータは観測されない完全データの下限を表すことから, $j=1, 2, \dots, r$ として $u_{n+j} < t_{n+j}$ が成り立つ. 以降ではこれらの u_{n+j} のことを単に u_j と表記する. この理由は, 今回のデータ解析において, n 個の完全データ, r 個のランダム打ち切りデータともに順序関係が存在せず, これらのインデックスがハードディスクドライブの各個体に固有のシリアル番号に対応する名義尺度であることによる. なお, シリアル番号を含むデータの詳しい仕様については 4. 1 節で述べる.

定義 2.1 の $f(t)$ および, 定義 2.3 の $R(t)$ もとで n 個の完全データ $\{t_1, t_2, \dots, t_n\}$, r 個のランダム打ち切りデータ $\{u_1, u_2, \dots, u_r\}$ を観測したとき, パラメータ m ,

λ による尤度関数 $L_2(m, \lambda)$ は, 定義 3.3 で与えられる.

定義 3.3 (ランダム打ち切りを含むデータによる尤度関数).

$$\begin{aligned}
 L_2(m, \lambda) &= \frac{(n+r)!}{r!} \prod_{i=1}^n f(t_i) \prod_{j=1}^r R(u_j) \\
 &= \frac{(n+r)!}{r!} \prod_{i=1}^n \frac{m}{\lambda} \left(\frac{t_i}{\lambda}\right)^{m-1} \exp\left[-\left(\frac{t_i}{\lambda}\right)^m\right] \prod_{j=1}^r \exp\left[-\left(\frac{u_j}{\lambda}\right)^m\right]. \quad (11)
 \end{aligned}$$

■

式(11)を最大化する m, λ をそれぞれ $\hat{m}_2, \hat{\lambda}_2$ とすると, これらは最尤推定量として定義 3.4 で与えられる.

定義 3.4 (ランダム打ち切りデータによる最尤推定量).

$$\left\{ \begin{array}{l} \hat{m}_2 = \arg \max_m L_2(m, \lambda); \\ \hat{\lambda}_2 = \arg \max_\lambda L_2(m, \lambda). \end{array} \right. \quad (12)$$

■

最尤推定量が満たす極値条件より, $\hat{m}_2, \hat{\lambda}_2$ が満たす必要条件は, 補題 3.2 で与えられる [8].

補題 3.2 (ランダム打ち切りデータによる最尤推定量の必要条件 [8]).

$$\left\{ \begin{array}{l} \left[\frac{\sum_{i=1}^n (t_i)^{\hat{m}_2} \ln t_i + \sum_{j=1}^r (u_j)^{\hat{m}_2} \ln u_j}{\sum_{i=1}^n (t_i)^{\hat{m}_2} + \sum_{j=1}^r (u_j)^{\hat{m}_2}} - \frac{1}{\hat{m}_2} \right] - \frac{1}{n} \sum_{i=1}^n \ln t_i = 0; \\ \hat{\lambda}_2 = \left[\frac{\sum_{i=1}^n (t_i)^{\hat{m}_2} + \sum_{j=1}^r (u_j)^{\hat{m}_2}}{n} \right]^{\frac{1}{\hat{m}_2}}. \end{array} \right. \quad (13)$$

■

式(13)の数値計算に関して, Harter [17] は, 定義 2.1 の 2 パラメータワイブル分布にさらに未知の位置パラメータを加えた 3 パラメータワイブル分布の最尤推定を扱い, 尤度関数のフィッシャー情報行列の正則性は, 以下の 3 つのうちの少なくともひとつが満たされることと同値であることを明らかにした. これらはすなわち, (1) 形状パラメータが 2 より大きい, (2) 位置パラメータが既知, (3) 下からの打ち切りデータが存在する, である. このうち (2) については, 3. 1 節で述べた 2 パラメータワイブル分布における完全データの最尤推定量の最適性を保証している. また, (3) については, 本稿で扱うランダム打ち切りデータが満たす条件であることから, 式(13)の最尤推定量の最適性を保証しているものと考えられる. したがって, 式(13)について数値計算により解を求めることは可能で, 近似最尤推定も可能であるということになる.

4 ランダム打ち切りを含む HDD の寿命データの解析

本章では, 4. 1 節でデータ仕様, 4. 2 節でデータ解析の手順を述べたうえで, 4. 3 節で完全データの解析結果を, 4. 4 節でランダム打ち切りを含むデータの解析結果を示す.

4. 1 データ仕様

本稿における解析対象のデータとして, 米国 Backblaze 社が公開しているハードディスクドライブ (HDD) の寿命データ [18] を利用した. HDD とは, 今日主流となっているノイマン型コンピュータにおける補助記憶装置の一種で, 磁性体が塗布された円盤を高速回転させながら磁気ヘッドを移動させることで, コンピュータ内部の情報の読み書きを行う仕組みをもった精密機器のことである. 近年はタブレット端末やスマートフォン端末などのモバイル機器の出現にともない, ソリッドステートドライブ (Solid State Drive, SSD) に取って代われつつあるが, 低価格でかつ記録可能な情報量が大容量であることか

ら、クラウドコンピューティング環境等におけるサーバ機器やパーソナルコンピュータ (PC) などの補助記憶装置として依然として欠かせないものとなっている。

今回対象としたのは、2018年1月1日から2021年12月31日までの4年間 (1,461日) にクラウド系の情報システムで実際に稼働したHDDの状態をS.M.A.R.T (Self-Monitoring Analysis and Reporting Technology) により記録した、のべ約18万件のデータである¹⁾。データ解析にあたり集計したのは、(1) 日付 [年月日], (2) シリアル番号, (3) 型番, (4) データ容量 [bytes], (5) 稼働時間 [hrs], (6) 状態 [正常:0 または異常:1] の6種類である。このうち、シリアル番号は個々のHDDに一意に設定されたいわゆるIDにあたる情報である。

表1に年ごとの日数、完全データの総数 (n)、ランダム打ち切りデータの総数 (r) の内訳を示す。これらの n と r は、3.2節で定義したものであるが、これらは今回集計した項目のうち、前述の「(2) シリアル番号」の総数に相当する。そのうち、「(6) 状態」が異常の場合の「(5) 稼働時間」が、個々の完全データ $t_i, i=1, 2, \dots, n$ となり、「(6) 状態」が正常の場合の「(5) 稼働時間」が、個々のランダム打ち切りデータ $r_j, j=1, 2, \dots, r$ となる。

表1：HDDの寿命データの仕様 [1/2]

| 年 | 自 | 至 | 日数 | n | r |
|------|--------|--------|-------|-------|---------|
| 2021 | 01月01日 | 12月31日 | 365 | 1,573 | 126,888 |
| 2020 | 01月01日 | 12月31日 | 366 | 1,369 | 23,200 |
| 2019 | 01月01日 | 12月31日 | 365 | 2,154 | 15,071 |
| 2018 | 01月01日 | 12月31日 | 365 | 1,255 | 8,652 |
| 小計 | | | 1,461 | 6,351 | 173,811 |

つぎに表2にHDDの型番ごとのサイズ、データ容量、完全データ (n)、ラ

1) 執筆者は、2013-2016年ののべ約9万件のデータも過去に分析した [14,15]。

ンダム打ち切りデータ (r) の内訳を示す. 表2では, 2018年からの4年間の集計データから完全データの総数 n が100以上となる計11種の型番を対象としている.

さらに, 表3に完全データについて, HDDの型番ごとの各年のデータ数の内訳を示す.

最後に, 表4にランダム打ち切りデータについて, HDDの型番ごとの各年のデータ数の内訳を示す. また, 本稿末尾にある付録Aの図2から図12に, 型番ごとの完全データの相対ヒストグラムを斜線で, ランダム打ち切りデータの相対ヒストグラムを灰色で示した.

表2: HDDの寿命データの仕様 [2/2]

| 型番 | サイズ | データ容量 | n | r |
|----------------------|------|----------|-------|---------|
| ST12000NM0007 | 3.5" | 12 [TB] | 1,937 | 38,313 |
| ST4000DM000 | 3.5" | 4 [TB] | 1,590 | 23,245 |
| ST8000NM0055 | 3.5" | 8 [TB] | 736 | 14,982 |
| ST8000DM002 | 3.5" | 8 [TB] | 446 | 10,065 |
| ST12000NM0008 | 3.5" | 12 [TB] | 373 | 20,528 |
| TOSHIBA MG07ACA14TA | 3.5" | 14 [TB] | 364 | 38,389 |
| TOSHIBA MQ01ABF050 | 2.5" | 500 [GB] | 297 | 1,656 |
| HGST HMS5C4040BLE640 | 3.5" | 4 [TB] | 184 | 14,660 |
| ST500LM012 HN | 2.5" | 500 [GB] | 150 | 609 |
| TOSHIBA MQ01ABF050M | 2.5" | 500 [GB] | 140 | 442 |
| HGST HUH721212ALN604 | 3.5" | 12 [TB] | 134 | 10,922 |
| 小計 | | | 6,351 | 173,811 |

4. 2 データ解析の手順

いま, $k=1,2$ とし, $k=1$ の場合を完全データによる推定, $k=2$ の場合をランダム打ち切りを含むデータによる推定とする. 表4に示したHDDの型番ごとに, 補題 3.1または補題 3.2にしたがい, 形状パラメータの近似最尤推定値 \hat{m}_k を数値計算により求め, つぎに尺度パラメータの近似最尤推定値 $\hat{\lambda}_k$ を計算す

る。

さらに平均故障時間 (MTTF) の推定値 $\hat{E}_k(T)$ を, $\hat{m}_k, \hat{\lambda}_k$ を代入することで計算する. この $\hat{E}_k(T)$ は, MTTF の定義 2.5 を使い, 定義 4.1 で与えられる.

定義 4.1 (MTTF の推定値).

$$\hat{E}_k(T) = \hat{\lambda}_k \Gamma \left(1 + \frac{1}{\hat{m}_k} \right), k = 1, 2. \quad (14)$$

■

なお, 寿命データの単位が時間 [hrs] であるため, 式(14)で求まる平均故障時間 $\hat{E}_k(T)$ の単位も同じく時間 [hrs] であることに注意されたい. また, 数値計算にあたっては, 統計ソフトウェア R [19] のバージョン 3.6.3 を用いた.

表 3 : HDD 寿命の完全データの内訳

| 型番 | 小計 | 2018 年 | 2019 年 | 2020 年 | 2021 年 |
|----------------------|-------|--------|--------|--------|--------|
| ST12000NM0007 | 1,937 | 295 | 1,155 | 337 | 150 |
| ST4000DM000 | 1,590 | 581 | 401 | 269 | 339 |
| ST8000NM0055 | 736 | 126 | 222 | 177 | 211 |
| ST8000DM002 | 446 | 92 | 124 | 91 | 139 |
| ST12000NM0008 | 373 | 0 | 9 | 147 | 217 |
| TOSHIBA MG07ACA14TA | 364 | 9 | 10 | 102 | 243 |
| TOSHIBA MQ01ABF050 | 297 | 50 | 80 | 96 | 71 |
| HGST HMS5C4040BLE640 | 184 | 54 | 57 | 34 | 39 |
| ST500LM012 HN | 150 | 41 | 43 | 34 | 32 |
| TOSHIBA MQ01ABF050M | 140 | 6 | 22 | 32 | 80 |
| HGST HUH721212ALN604 | 134 | 1 | 31 | 50 | 52 |
| 小計 | 6,351 | 1,255 | 2,153 | 1,364 | 1,574 |

表4：HDD 寿命のランダム打ち切りデータの内訳

| 型番 | 小計 | 2018年 | 2019年 | 2020年 | 2021年 |
|----------------------|---------|-------|--------|--------|---------|
| ST12000NM0007 | 38,313 | 1,067 | 14,120 | 21,802 | 1,324 |
| ST4000DM000 | 23,245 | 4,022 | 272 | 341 | 18,610 |
| ST8000NM0055 | 14,982 | 224 | 178 | 248 | 14,332 |
| ST8000DM002 | 10,065 | 124 | 91 | 134 | 9,716 |
| ST12000NM0008 | 20,528 | 0 | 109 | 218 | 20,201 |
| TOSHIBA MG07ACA14TA | 38,389 | 9 | 50 | 146 | 38,184 |
| TOSHIBA MQ01ABF050 | 451 | 0 | 98 | 72 | 281 |
| HGST HMS5C4040BLE640 | 14,660 | 1,854 | 34 | 69 | 12,703 |
| ST500LM012 HN | 609 | 121 | 34 | 32 | 422 |
| TOSHIBA MQ01ABF050M | 442 | 24 | 35 | 86 | 297 |
| HGST HUH721212ALN604 | 10,922 | 2 | 50 | 52 | 10,818 |
| 小計 | 173,811 | 8,652 | 15,071 | 23,200 | 126,888 |

4. 3 完全データの解析結果

表5に完全データを対象とした型番ごとの形状パラメータ \hat{m}_1 、尺度パラメータ $\hat{\lambda}_1$ 、および平均故障時間MTTFの推定値 $\hat{E}_1(T)$ を示す。

また、表5で得られたパラメータ推定値をもとに、HDDの型番ごとのワイブル分布確率密度関数のグラフを、本稿末尾にある付録Aの図2から図12の破線として示した。

表5：完全データの推定結果

| 型番 | \hat{m}_1 | $\hat{\lambda}_1$ | $\hat{E}_1(T)$ |
|---------------------|-------------|-------------------|----------------|
| ST12000NM0007 | 1.752 | 13,590 | 12,102 |
| ST4000DM000 | 3.882 | 39,523 | 35,763 |
| ST8000NM0055 | 2.081 | 24,856 | 22,016 |
| ST8000DM002 | 2.934 | 32,966 | 29,410 |
| ST12000NM0008 | 1.796 | 10,602 | 9,429 |
| TOSHIBA MG07ACA14TA | 1.046 | 7,525 | 7,390 |
| TOSHIBA MQ01ABF050 | 2.452 | 24,600 | 21,816 |

| | | | |
|----------------------|-------|--------|--------|
| HGST HMS5C4040BLE640 | 2.400 | 29,413 | 26,074 |
| ST500LM012 HN | 3.262 | 34,410 | 30,848 |
| TOSHIBA MQ01ABF050M | 2.604 | 27,772 | 24,668 |
| HGST HUH721212ALN604 | 1.306 | 12,510 | 11,544 |

4. 4 ランダム打ち切りを含むデータの解析結果

表6にランダム打ち切りを含むデータを対象とした形状パラメータ \hat{m}_2 、尺度パラメータ $\hat{\lambda}_2$ 、および平均故障時間MTTFの推定値 $\hat{E}_2(T)$ を示す。

また、表6で得られたパラメータ推定値をもとに、HDDの型番ごとのワイブル分布確率密度関数のグラフを、本稿末尾にある付録Aの図2から図12に実線で示した。

表6：ランダム打ち切りを含むデータの推定結果

| 型番 | \hat{m}_2 | $\hat{\lambda}_2$ | $\hat{E}_2(T)$ |
|----------------------|-------------|-------------------|----------------|
| ST12000NM0007 | 1.287 | 197,500 | 182,771 |
| ST4000DM000 | 2.321 | 165,236 | 146,401 |
| ST8000NM0055 | 1.329 | 373,954 | 343,888 |
| ST8000DM002 | 1.842 | 250,001 | 222,093 |
| ST12000NM0008 | 1.289 | 347,594 | 321,589 |
| TOSHIBA MG07ACA14TA | 0.973 | 1,252,238 | 1,267,318 |
| TOSHIBA MQ01ABF050 | 1.674 | 53,649 | 47,920 |
| HGST HMS5C4040BLE640 | 1.440 | 940,888 | 853,922 |
| ST500LM012 HN | 2.355 | 80,148 | 71,027 |
| TOSHIBA MQ01ABF050M | 2.491 | 51,824 | 45,978 |
| HGST HUH721212ALN604 | 0.863 | 3,940,342 | 4,247,180 |

5 考察

本章では、5. 1節において完全データの推定結果の考察を行い、つづく5. 2節においてランダム打ち切りを含むデータの推定結果の考察を行う。

5. 1 完全データの推定結果の考察

5. 1. 1 形状パラメータについて

表5の形状パラメータの推定値 \hat{m}_1 について、11種類のHDDの型番すべてで $\hat{m}_1 > 1$ となり、定義2.4の故障率関数が描くバスタブ曲線については、IFR、すなわち摩耗故障期であることを強く示唆する結果となった。完全データはシリアル番号のHDDが故障した時点における稼働時間であることから、今回分析したすべての型番のHDDが、本稿の分析が想定している部品のライフサイクルの中で、もっとも故障が発生しやすい時期であることを意味している。なお、 \hat{m}_1 が最小であったのは、型番：TOSHIBA MG07ACA14TAで $\hat{m}_1 = 1.046$ 、最大となったのは、型番：ST4000DM000で $\hat{m}_1 = 3.882$ となった。

5. 1. 2 尺度パラメータについて

表5の尺度パラメータの推定値 $\hat{\lambda}_1$ は、どれも $\hat{E}_1(T)$ の値の1割増程度の値となった。この理由についてはつぎの5. 1. 3節で考察するが、ほぼ似たような値であれば、平均故障時間を意味する $\hat{E}_1(T)$ のほうを理解しやすいので、詳細は5. 1. 3節で詳しく考察することとし、ここでは1点のみ、表5で $\hat{m}_1 = 1.046 \div 1$ となったTOSHIBA MG07ACA14TAについてのみ考察する。

1. 1節で述べたとおり、信頼性工学のバスタブ曲線において、 $\hat{m}_1 = 1$ はCFR、つまり部品が安定的に稼働する偶発故障期を意味する。この場合、時間を問わず故障率は一定であり、定義2.4の右辺に $m = 1$ を代入して得られる故障率関数 $h(t)$ は、

$$h(t) = \frac{1}{\lambda},$$

となる。ここで、TOSHIBA MG07ACA14TAについては表5より、 $\hat{\lambda}_1 = 7.525$ であることから、このHDDは7,525 [hrs] に1回故障すると推定される。これよりこの型番の平均故障間隔 (Mean Time between Failure, MTBF) [1,2]の推定値は、7,525 [hrs] になる。これは日数になおすと約313日で、連続稼働の条件下では、1年もたずに修理交換が必要、ということになる。ただし、

これは完全データのみによる推定結果からの考察である。ランダム打ち切りを含んだデータによる推定結果については5. 2. 2節で考察する。

5. 1. 3 平均故障時間について

今回扱ったHDDでは、表2で示したデータ容量が12-14 [TB] のものは比較的大容量であるが、表5の型番で見ると、上から1番目のST12000NM0007が $\hat{E}_1(T)=12,102$ [hrs]、5番目のST12000NM0008のそれが9,429 [hrs]、6番目のTOSHIBA MG07ACA14TAのそれが7,390 [hrs]、11番目のHGST HUH721212ALN604のそれが11,544 [hrs]と、総じて早期の故障傾向を読み取ることができる。これらを年に換算するとそれぞれ、1.38, 1.07, 0.84, 1.32年にあたる。

一方、ノート型PC等によく使われている2.5インチのHDDは、表5では上から7番目のTOSHIBA MQ01ABF050, 9番目のST500LM012 HN, 10番目のTOSHIBA MQ01ABF050Mの3種類であり、これらのデータ容量はいずれも500 [GB] と小さめであるが、これらはいずれも平均故障時間が20,000 [hrs] 以上となっており、年換算すると約2.5年以上となっており、3.5インチの12 [TB] のものより長く稼働していた。残りの4-8 [TB] のデータ容量のものは、22,000から35,000 [hrs] 程度、つまり2.5から4.1年程度稼働したあとに故障しており、これらの型番は、2.5インチのHDDと同等かそれ以上の信頼性があると考えてよさそうである。表5の最右列の平均故障時間の推定値 $\hat{E}_1(T)$ について、型番ごとの大小関係を見ると、おおむね \hat{m}_1 や $\hat{\lambda}_1$ のそれと一致していた。まず、 \hat{m}_1 については、形状パラメータの推定値が小さい型番のものは比較的早く故障し、大きい型番のものはある程度の時間が経過してから故障しているという傾向があることがわかる。つぎに $\hat{\lambda}_1$ についても、 $k=1, \hat{m}_1 > 1$ の条件下では、定義4.1の \hat{E}_k の右辺が、

$$\hat{E}_1(T) = \hat{\lambda}_1 \Gamma \left(1 + \frac{1}{\hat{m}_1} \right),$$

となっていることから、完全データについては型番ごとの $\hat{\lambda}_1$ と $\hat{E}_1(T)$ は正比

例の関係にあり，両者の大小関係は当然ながら一致する。

5. 2 ランダム打ち切りを含むデータの推定結果の考察

5. 2. 1 形状パラメータについて

表6の形状パラメータの推定値 \hat{m}_2 について，すべての型番において表5にある \hat{m}_1 の値よりも小さくなった。そこで，表7に \hat{m}_1 ， \hat{m}_2 の値を転記し， \hat{m}_2/\hat{m}_1 の値を計算して最右列に整理したところ，すべての型番でこの比は1未満の値となった。これは，ランダム打ち切りデータ u_j が故障していない状態の稼働時間であり，真の寿命時間 t_j の下界を表している以上，当然の結果であるが， $\hat{m}_2 \leq 1$ となったのは，TOSHIBA MG07ACA14TA ($\hat{m}_2=0.973$)とHGST HUH721212ALN604 ($\hat{m}_2=0.863$)の2種類のみであった。これらのうち前者については，完全データのみからの推定値 $\hat{m}_1=1.046$ に比べて93%の大きさとどまったのに対し，後者については $\hat{m}_1=1.306$ に比べて約3分の2の大きさとなった。

これらのつぎに小さな形状パラメータが得られたのは，ST12000NM0007 ($\hat{m}_2=1.287$)とST12000NM0008 ($\hat{m}_2=1.289$)で， \hat{m}_1 に比べると \hat{m}_2 の値は7割程度の大きさになり，これらはいずれもデータ容量が12 [GB]の大容量HDDであった。また，データ容量が8 [GB]であるST8000NM0055も $\hat{m}_2=1.329$ となり，完全データのみの $\hat{m}_1=2.081$ に比べると64%程度の大きさの推定値が得られた。表7の \hat{m}_2/\hat{m}_1 の値の説明変数として，ランダム打ち切りデータの総数 r と完全データの総数 n の和に対する r 比 $r/(n+r)$ が有効となりうるのか，両者の相関係数を計算してみたが，その値は0.405にとどまった。この要因としては，型番ごとにHDDの特性が違ふと考えられることや， n と r の比も型番ごとにまちまちであること，さらに完全データとランダム打ち切りデータの間には単なるデータ数という量のみでは把握できない，質の相違が存在している可能性が考えられる。

表 7：型番ごとの \hat{m}_2/\hat{m}_1 の値

| 型番 | \hat{m}_1 | \hat{m}_2 | \hat{m}_2/\hat{m}_1 |
|----------------------|-------------|-------------|-----------------------|
| ST12000NM0007 | 1.752 | 1.287 | 0.735 |
| ST4000DM000 | 3.882 | 2.321 | 0.598 |
| ST8000NM0055 | 2.081 | 1.329 | 0.639 |
| ST8000DM002 | 2.934 | 1.842 | 0.628 |
| ST12000NM0008 | 1.796 | 1.289 | 0.718 |
| TOSHIBA MG07ACA14TA | 1.046 | 0.973 | 0.930 |
| TOSHIBA MQ01ABF050 | 2.452 | 1.674 | 0.683 |
| HGST HMS5C4040BLE640 | 2.400 | 1.440 | 0.600 |
| ST500LM012 HN | 3.262 | 2.355 | 0.722 |
| TOSHIBA MQ01ABF050M | 2.604 | 2.491 | 0.957 |
| HGST HUH721212ALN604 | 1.306 | 0.863 | 0.661 |

5. 2. 2 尺度パラメータについて

5. 1. 2 節と同様に、表 6 の中で形状パラメータが、 $\hat{m}_2 \doteq 1$ と見なしうる型番を見てみると、上から、ST12000NM0007 ($\hat{m}_2=1.287$)、ST8000NM0055 ($\hat{m}_2=1.329$)、ST12000NM0008 ($\hat{m}_2=1.289$)、TOSHIBA MG07ACA14TA ($\hat{m}_2=0.973$)、HGST HMS5C4040BLE640 ($\hat{m}_2=1.440$)、HGST HUH721212ALN604 ($\hat{m}_2=0.863$) などが挙げられる。これらの HDD は、1. 1 節で述べた故障率関数のバスタブ曲線における CFR、つまり偶発故障期とみなせる。このように $\hat{m}_2 \doteq 1$ の場合は、5. 1. 2 節で述べたように、尺度パラメータの推定値 $\hat{\lambda}_2$ の値がそのまま平均故障間隔 (MTBF) の推定値となる。そこで、あらためてこれを整理すると、表 8 のようになり、これらの MTBF の推定値を年換算すると、上からそれぞれ、31, 59, 5,197, 148, 620 [yrs] となり、かなり大きい値となった。これらの型番については、定義 24 で述べた故障率関数 $h(t)$ を利用して、業界で利用されている年間故障率 AFR (Annual Failure Rate) との比較が可能であるが、これについては 5. 2. 4 節で考察する。

表 8 : 偶発故障期の型番ごとの MTBF の推定値

| 型番 | \hat{m}_2 | MTBF [hrs] |
|----------------------|-------------|------------|
| ST12000NM0007 | 1.287 | 197,500 |
| ST8000NM0055 | 1.329 | 373,954 |
| ST12000NM0008 | 1.289 | 347,594 |
| TOSHIBA MG07ACA14TA | 0.973 | 1,252,238 |
| HGST HMS5C4040BLE640 | 1.440 | 940,888 |
| HGST HUH721212ALN604 | 0.863 | 3,940,342 |

5. 2. 3 平均故障時間について

表 6 の最右列の平均故障時間 $\hat{E}_2(T)$ について、表 5 で得られた $\hat{E}_1(T)$ と比べると、これらはすべての型番について $\hat{E}_2(T)$ のほうが大きくなった。 $\hat{E}_2(T)$ の値が特に大きくなった上位 5 つの型番は、HGST HUH721212ALN604 と TOSHIBA MG07ACA14TA、HGST HMS5C4040BLE640、ST8000NM0055、ST12000NM0008 など、これらの平均故障時間を年に換算するとそれぞれ、484 年、144 年、97 年、39 年、37 年という非現実的な値となった。これらに共通していえるのは、データ数全体に占める完全データ比 $r/(n+r)$ が 5% 未満ということである。表 6 で $\hat{E}_2(T)$ が小さくなったものとしては、TOSHIBA MQ01ABF050M の 45,978 [hrs]、TOSHIBA MQ01ABF050 の 47,920 [hrs] など、これは年換算するとそれぞれ 5.25、5.47 年である。今回得られたデータの推定では少なくとも 5 年以上稼働する、ということになる。

表 9 の最右列に、表 7 と同様に、型番ごとの平均故障時間についての比 $\hat{E}_2(T)/\hat{E}_1(T)$ を計算して整理した。これらの比により、完全データのみによって推定された $\hat{E}_1(T)$ に比べて、ランダム打ち切りデータも併用して推定された $\hat{E}_2(T)$ がどれくらい大きくなったかがわかる。表 9 で特筆すべきは、最下行の HGST HUH721212ALN604 の比率 367.91 と、上から 5 番目の TOSHIBA MG07ACA14TA の比率 171.49 であろう。これら 2 種の型番の HDD は、完全データのみによる平均故障時間の推定値は 1 万時間程度かそれ以下であったものが、ランダム打ち切りデータも併用して推定した結果、その推定値は 100 万

時間のオーダーになった。これらはそれぞれ、データ容量が12,14 [TB] の大容量のHDDであり、ランダム打ち切りデータを考慮した結果、信頼性が特に高く推定されたことになる。

つぎに5. 1. 1節と同様に、型番ごとの $\hat{E}_2(T)/\hat{E}_1(T)$ の系列と、 $n/(n+r)$ の系列との相関係数を計算したところ、 -0.431 となった。やはり前者を後者で線形的に説明するのは難しそうである。しかし、図1に示すように、縦軸に前者、横軸に後者を取った散布図を描いてみると、横軸の値 $n/(n+r)$ 、つまりデータ全体に占める完全データの割合が極めて小さい場合は縦軸の $\hat{E}_2(T)/\hat{E}_1(T)$ は極めて大きくなり（図1の左上の点）、そこから横軸が増えるにつれて縦軸の値は急激に、かつほぼ単調に減少していることがわかる。表6または9において、 $\hat{E}_2(T)$ の値が小さかったTOSHIBA MQ01ABF050M, TOSHIBA MQ01ABF050, ST500LM012 HN などであるが、これらの平均故障時間を年換算するとおおむね5-8年程度で現実的な値と考えられる。これらの型番は、図1右下の横軸の範囲0.15～0.25に位置する3点と対応し、このときの縦軸の範囲は、1.86～2.30であった。

表9：型番ごとの $\hat{E}_2(T)/\hat{E}_1(T)$ の値

| 型番 | $\hat{E}_1(T)$ | $\hat{E}_2(T)$ | $\hat{E}_2(T)/\hat{E}_1(T)$ |
|----------------------|----------------|----------------|-----------------------------|
| ST12000NM0007 | 12,102 | 182,771 | 15.10 |
| ST4000DM000 | 35,763 | 146,401 | 4.09 |
| ST8000NM0055 | 22,016 | 343,888 | 15.62 |
| ST8000DM002 | 29,410 | 222,093 | 7.55 |
| ST12000NM0008 | 9,429 | 321,589 | 34.11 |
| TOSHIBA MG07ACA14TA | 7,390 | 1,267,318 | 171.49 |
| TOSHIBA MQ01ABF050 | 21,816 | 47,920 | 2.20 |
| HGST HMS5C4040BLE640 | 26,074 | 853,922 | 32.75 |
| ST500LM012 HN | 30,848 | 71,027 | 2.30 |
| TOSHIBA MQ01ABF050M | 24,668 | 45,978 | 1.86 |
| HGST HUH721212ALN604 | 11,544 | 4,247,180 | 367.91 |




図 1 : $\hat{E}_2(T)/\hat{E}_1(T)$ と $n/(n+r)$ の散布図

5. 2. 4 年間故障率 (AFR) と故障率関数との比較について

1. 2 節で述べたように、HDD 業界では、製品の寿命の指標として年間故障率 (Annual Failure Rate, AFR) が頻繁に使われている。これは、型番ごとに HDD の故障発生回数を総稼働時間で割り、1 年稼働した場合の故障率に換算して求められている。この計算はノンパラメトリックな手法で手軽な四則演算ではあるものの、本稿で扱ったようなパラメトリックなワイブル分布とは異なる。そこで本章の最後に両者の比較考察を行ってみたい。

5. 1. 2 節で述べたように、形状パラメータ $m=1$ の場合の故障率関数 $h(t)$ は、

$$h(t) = \frac{1}{\lambda},$$

与えられる。本稿では時間データの単位はすべて [hrs] であることから、1 年を時間換算して $t=24 \times 365=8760$ [hrs] とし、 $h(8760)$ を計算すると、2 パラメータワイブル分布による年間故障率を得ることができる。一方、HDD 業界のいわゆる AFR については、主な HDD 型番についての故障回数と総稼働

時間等を米国 Backblaze 社が年ごとに公開していることから、本稿のデータと同じ 2018-2021 年の 4 年間について執筆者が計算した。これらをまとめて表 10 に示す。

表 10：偶発故障期の型番ごとの故障率指標の比較 [単位：%]

| 型番 | $h(8760)$ | AFR |
|----------------------|-----------|-------|
| ST12000NM0007 | 4.435 | 2.126 |
| ST8000NM0055 | 2.342 | 1.366 |
| ST12000NM0008 | 2.520 | 1.056 |
| TOSHIBA MG07ACA14TA | 0.700 | 0.800 |
| HGST HMS5C4040BLE640 | 0.931 | 0.332 |
| HGST HUH721212ALN604 | 0.222 | 0.451 |

表 10 の両者の系列の相関係数は 0.942 となり、よく一致しているといえそうである。ただし、ここで偶発故障期であるとした型番について、表 8 の \hat{m}_2 の推定値を見ると、実際には完全に $m=1$ となっているわけではない。そこで、両者の差分 $\hat{m}_2 - 1$ と、 $h(8760)/AFR$ の値を表 11 に示す。

表 11：形状母数の推定誤差と故障率指標の比

| 型番 | $\hat{m}_2 - 1$ | $h(8760)/AFR$ |
|----------------------|-----------------|---------------|
| ST12000NM0007 | 0.287 | 2.085 |
| ST8000NM0055 | 0.329 | 1.714 |
| ST12000NM0008 | 0.289 | 2.385 |
| TOSHIBA MG07ACA14TA | -0.027 | 0.874 |
| HGST HMS5C4040BLE640 | 0.440 | 2.800 |
| HGST HUH721212ALN604 | -0.137 | 0.493 |

表 11 の 2 種類の系列の相関係数は 0.903 となり、本稿で推定した \hat{m}_2 の値が 1 からその差分が大きくなる（または小さくなる）ほど、 $h(8760)/AFR$ の値も大きくなる（小さくなる）ことがわかる。さらに $\hat{m}_2 - 1$ を説明変数 x 、 $h(8760)/$

AFRを被説明変数 y とした最小二乗法による単回帰式は、 $y=3.749x+0.988$ となり、この回帰式に $x=0$ を代入したときには $y=0.988$ となる。つまり、本稿の形状パラメータの推定値がちょうど $\hat{m}_2=1$ となったとき、 $h(8760)$ とAFRの値はほぼ一致するものと思われる。以上の点から、HDD業界で使われている寿命の指標AFRは、本稿の2パラメータワイブル分布およびランダム打ち切りデータによる推定故障率関数から計算された年間故障率とよく一致することが確かめられた。

6 おわりに

本稿では、米国Backblaze社が公開しているハードディスクドライブ (HDD) の寿命データを使って、2パラメータワイブル分布の形状および尺度パラメータを数値計算し、HDDの信頼性の近似最尤推定を試みた。2018-2021年までの4ヵ年、のべ18万件のランダム打ち切りを含んだ計11種類の型番のHDD寿命を分析したところ、以下のことが明らかになった。(1) 11種類すべての型番のHDDについて、故障したのべ約6,000件の寿命の完全データのみから推定されたワイブル分布の形状パラメータは1より大きくなり、これはIncreasing Failure Rate (IFR) の摩耗故障期であることを強く示唆する。(2) 11種の型番について、完全データのみから推定された平均故障時間 (MTTF) は、おおむね1年から4年の間である。(3) ランダム打ち切りを含むデータ約18万件から推定された形状パラメータも9種類で1より大きくなり、故障しなかったHDDのデータを考慮してもやはり摩耗故障期であることを強く示唆する。(4) ランダム打ち切りを含むデータ全体に占める完全データの割合が15-25%程度のデータから推定されたHDDの平均故障時間 (MTTF) はおおむね5-8年程度。(5) HDD業界で使われている寿命の指標としての年間故障率 (AFR) は、本稿で推定された故障率関数による値とよく一致する。

今後の課題としては、2022年以降のデータを用いた新たなデータ解析のほか、ワイブル分布の形状パラメータの推定値が1ではない場合の故障率の分析、

ワイブル分布のパラメータに回帰モデルを取り入れた分析, 本稿で扱った点推定を一般化した区間推定によるデータ解析, あるいは本稿で仮定したランダム打ち切りデータによる統計モデル以外のアプローチによるパラメータ推定などが挙げられる.

参考文献

- [1] Jerald F. Lawless, *Statistical Models and Methods for Lifetime Data*, John Wiley & Sons, 1982.
- [2] Wayne B. Nelson 著, 柴田義貞, 藤野和建, 鎌倉稔成訳, 「寿命データの解析」, 日科技連, 1988年.
- [3] Michael S. Hamada, Alyson G. Wilson, C. Shane Reese, and Harry F. Martz, *Bayesian Reliability*, Springer, 2008.
- [4] Waloddi Weibull, "A Statistical Theory of the Strength of Materials," *Ingeniörsvetenskapsakademiens handlingar*, nr. 151, 1939.
- [5] Waloddi Weibull, "A Statistical Distribution Function of Wide Applicability," *Journal of Applied Mechanics*, vol. 18, issue 3, pp. 293-297, Sep. 1951.
- [6] Norman L. Johnson, Samuel Kotz, and N. Balakrishnan, *Continuous Univariate Distributions Volume 1 (Second Edition)*, John Wiley & Sons, 1994.
- [7] Nancy R. Mann, "Point and Interval Estimation Procedures for the Two-Parameter Weibull and Extreme-Value Distributions," *Technometrics*, vol. 10, no. 2, May. 1968.
- [8] A. Clifford Cohen, "Maximum likelihood estimation in the Weibull distribution based on complete and on censored samples," *Technometrics*, vol.7, no.4, pp. 579-588, Nov. 1965.
- [9] John I. McCool, "Inference on Weibull Percentiles and Shape Parameter from Maximum Likelihood Estimates," *IEEE Transactions on Reliability*, vol. R-19, no. 1, pp. 2-9, Feb. 1970.

- [10] Howard Rockette, Charles Antle, and Lawrence A. Klimko, "Maximum Likelihood Estimation with the Weibull Model," *Journal of the American Statistical Association*, vol. 69, no. 345, pp. 246-249, Mar. 1974.
- [11] 小泉大城, 松嶋敏泰, "ある非定常なワイブル分布に従う時系列のベイズ最適な予測に関する一考察," *電子情報通信学会技術研究報告 (信学技報)*, vol. 115, no. 137, pp. 95-100, 2015年 7月.
- [12] 小泉大城, "尺度パラメータが非定常なワイブル分布の応用について," *電子情報通信学会 2016年総合大会講演論文集*, p. 50, 2016年 3月.
- [13] Daiki Koizumi, "On the Weibull Distribution with Nonstationary Scale Parameter," *Proceeding of the International Society for Bayesian Analysis (ISBA) 2016 World Meeting*, p. 323, Jun. 2016.
- [14] 小泉大城, "ワイブル分布によるハードディスクドライブの寿命時間の最尤推定について," *情報処理学会研究報告 (数理モデル化と問題解決)*, vol. 2017-MPS-114, no. 3, pp. 1-4, 2017年 7月.
- [15] Daiki Koizumi, "On the Maximum Likelihood Estimation of Weibull Distribution with Lifetime Data of Hard Disk Drives," *Proceedings of the 2017 International Conference on Parallel and Distributed Processing Techniques and Applications (PDPTA'17)*, pp. 314-320, Jul. 2017.
- [16] James W. Evans, David E. Kretschmann, and David W. Green, "Procedures for Estimation of Weibull Parameters," *General Technocal Report FPL-GTR-264*, Madison, WI: U.S. Department of Agriculture, Forest Service, Forest Products Laboratory, 2019.
- [17] H. Leon Harter and Albert H. Moore, "Asymptotic Variances and Covariances of Maximum-Likelihood Estimators, from Censored Samples, of the Parameters of Weibull and Gamma Populations," *the Annals of Mathematical Statistics*, vol. 38, no. 2, pp. 557-570, Apl, 1967.
- [18] Backblaze, *Hard Drive Data and Stats* [Online]. Available: <https://www.backblaze.com/b2/hard-drive-test-data.html> (参照 : 2022年 7月 5日).

[19] The R Foundation, The R Project for Statistical Computing [Online]. Available: <http://www.r-project.org/> (参照：2022年7月5日).

付録 A HDD の型番ごとの寿命データの 相対ヒストグラムと推定確率密度関数のグラフ

以下、図2から図12までのグラフは、表2に示した11種類のHDDの型番ごとに、(1)ランダム打ち切りデータの相対ヒストグラム、(2)完全データの相対ヒストグラム、(3)ランダム打ち切りを含むデータから推定されたワイブル分布の確率密度関数、(4)完全データから推定されたワイブル分布の確率密度関数を可視化したものである。

いずれのグラフも横軸に時間 (Lifetime) [単位: hrs], 縦軸に相対度数または確率密度を取っており, 凡例は, 上記 (1) が灰色の棒 (Randomly Censored), (2) が斜線の棒 (Complete), (3) が実線 (p.d.f. (Randomly Censored)), (4) が破線 (p.d.f. (complete)) となっている。




図2：ST12000NM007の相対ヒストグラムと推定確率密度関数




図 3 : ST4000DM000の相対ヒストグラムと推定確率密度関数

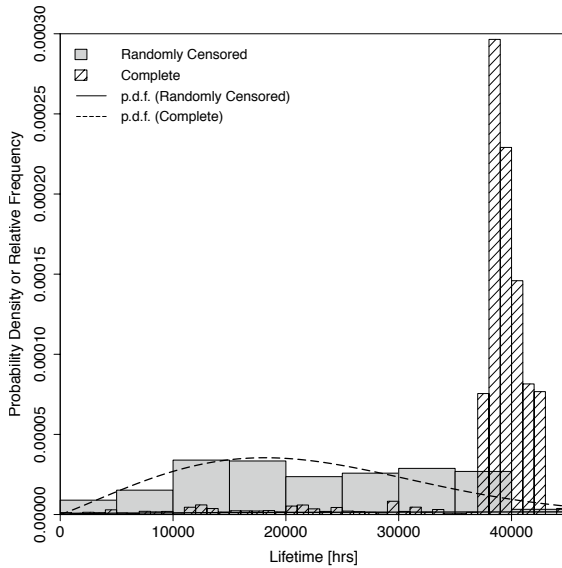


図 4 : ST8000NM0055の相対ヒストグラムと推定確率密度関数




図 5 : ST8000DM002の相対ヒストグラムと推定確率密度関数

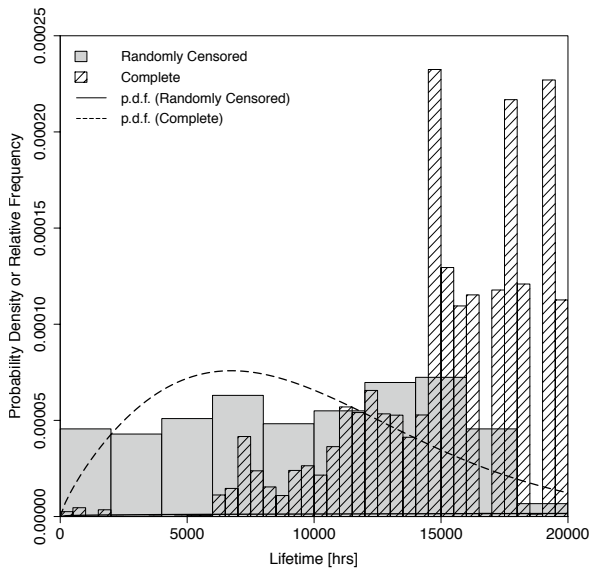


図 6 : ST12000NM0008の相対ヒストグラムと推定確率密度関数




図 7 : TOSHIBA MG07ACA14TAの相対ヒストグラムと推定確率密度関数




図 8 : TOSHIBA MQ01ABF050の相対ヒストグラムと推定確率密度関数




図 9 : HGST HMS5C4040BLE640 の相対ヒストグラムと推定確率密度関数




図 10 : ST500LM012 HN の相対ヒストグラムと推定確率密度関数




図 11 : TOSHIBA MQ01ABF050M の相対ヒストグラムと推定確率密度関数

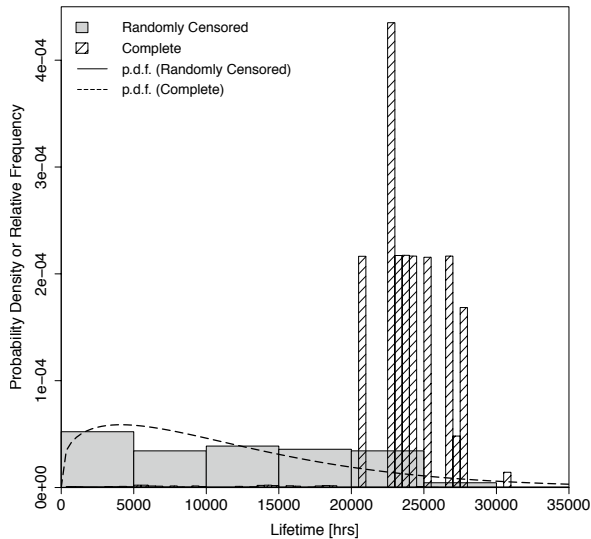


図 12 : HGST HUH721212ALN604 の相対ヒストグラムと推定確率密度関数