

Kanazawa University,
Faculty of Economics and Management

Discussion Paper Series

No. 057

3次スプライン関数によるヒストグラム平滑化とその漸近的性質

～Boneva, Kendall and Stefanov型とLii and Rosenblatt型モデルの理論的同等性～

Saito MISAKI
Masahiko SAGAE

saito_misaki@stu.kanazawa-u.ac.jp
sagae.masahiko@gmail.com

22 December 2020



金沢大学経済学経営学系
〒920-1192 金沢市角間町

Faculty of Economics and Management,
Kanazawa University

Kakumamachi, Kanazawa-shi, Ishikawa, 920-1192, Japan

<http://econ.w3.knazawa-u.ac.jp/DP/>

3次スプライン関数によるヒストグラム平滑化とその漸近的性質
～Boneva, Kendall and Stefanov 型と Lii and Rosenblatt 型モデルの理論的同等性～

金沢大学大学院 人間社会環境研究科 齊藤実祥
金沢大学 人間社会研究域 経済学経営学系 寒河江雅彦

要旨

ヒストグラムはデータの構造を把握するための最も簡単な統計量としてよく知られている。他方で、欠点として不連続であることが指摘される。この問題の解消のため、スプライン平滑化を考える。ヒストグラムのスプライン平滑化に関して、Boneva, Kendall and Stefanov(1971)(以下, BKS)が Histospline を提案し、Schoenberg(1972)が定式化した。しかしながら、BKS と Schoenberg はモデルの提案に留まり、理論的性質については言及していない。他方で、Lii and Rosenblatt(1974)は BKS と Schoenberg と異なる3次スプライン平滑化によるヒストグラムを提案し、その漸近的性質を導出した。その中で、漸近積分分散が $O\left(\frac{1}{nh}\right)$ 、漸近積分二乗バイアスが $O(h^6)$ となることと、漸近正規性が成り立つことを示している。しかしながら、L&R は BKS と Schoenberg との差異については言及していない。また、推定量の明示的な表現まで導いていない。本研究では、BKS+Schoenberg と L&R の2つの問題について同等性を示し、推定量について正確な漸近表現を導く。有限標本時の特性に関しては、ISE の標本平均と標準偏差について数値実験を行い、ヒストグラムとヒストスプラインの推定精度について比較する。

以上2つの未解決な問題に関して議論する。最初に BKS+Schoenberg と L&R の推定量が同等であることを示した。次に、推定量の AMISE は分散項が $\frac{5\sqrt{3}+3}{10} \frac{1}{nh}$ 、二乗バイアス項が $\frac{R(f''')}{30420} h^6$ と表されることを示した。ヒストグラムの AMISE と比較すると、分散は大きい一方で、二乗バイアスが小さいことが明らかになった。更に、ヒストスプライン推定量の平均積分誤差の上限と、漸近正規性を証明した。

数値実験の結果、ヒストグラムと比較してヒストスプラインの方が標本サイズに関わらず ISE 値が小さかった。一方で、ISE 標準偏差については、どの標本サイズでもヒストグラムの方が小さく、大標本特性を裏付ける結果となった。この結果から、ヒストスプラインは分散が大きくなるが、バイアスを減少させる効果の方が大きく、全体の推定精度としては改良されることが理論と数値実験で明らかになった。

キーワード

ヒストグラム, 平滑化, スプライン

Asymptotic Properties of A Histogram Smoothing by A Cubic Spline Function
~The Theoretical Equivalence between Boneva, Kendall and Stefanov Type and Lii and Rosenblatt Type
Models~

SAITO Misaki
SAGAE Masahiko

ABSTRACT

Histograms are discontinuous between adjacent bins. we consider a histogram smoothing by a cubic spline function. Boneva, Kendall and Stefanov (1971) (BKS) proposed Histospline and Schoenberg (1972) formulated it. However, they did not show asymptotic properties of histograms smoothing estimate by spline functions. As related research, Lii and Rosenblatt (1974)(L&R) set different conditions from BKS's to apply a cubic function for smoothing a histogram and derived asymptotic properties for it. In the paper, they showed that the asymptotic integrated variance(AIV) and the asymptotic integrated squared bias(AISB) for estimate are $O(1/nh)$ and $O(h^6)$, respectively. However, they did not mention a theoretical equivalence to the proposal by BKS. In addition, they did not show an explicit AIV and AISB. Therefore, we will show whether there is a theoretical equivalence between BKS and L&R models. We will also derive an explicit AIV and AISB of the estimate in BKS and L&R models. To examine characteristics of histograms and histograms smoothing by cubic spline functions in finite samples, we will perform numerical calculation of sample means and standard deviations of ISE.

As a result, we revealed that BKS and L&R models have the same equation and the AMISE of the estimate has $\frac{5\sqrt{3}+3}{10} \frac{1}{nh}$ for AIV and $\frac{R(f''')}{30420} h^6$ for AISB. It shows that the histospline have larger AIV and smaller AISB than them of histograms. We also showed the explicit mean and variance related to the asymptotic normality of the estimate.

Results of numerical calculation showed ISE of the histospline were smaller, but the standard deviation of ISE were larger than histograms. In other words, we can enjoy a significant decrease in the bias of a histogram smoothing while its variance increase. Therefore, a whole ISE of a histogram smoothing estimate is improved.

KEYWORDS

Histograms, Smoothing, Spline functions

1. 研究背景と目的

ノンパラメトリック推定法の代表的なものに、ヒストグラムが挙げられる。ここで「ヒストグラム」とは、ヒストグラム型密度関数を指し、以降は単に「ヒストグラム」と呼ぶことにする。ヒストグラム型密度関数とは、各分割区間(以降、ビンと呼ぶ)に入る度数データに比例した高さを持つ連続分布のことである。

ヒストグラムは、ビンごとに区分的定数関数である。そのため、隣接ビンの間では不連続となる。この不連続性の問題に対して、Scott(1985)が各ビンの中点を直線で結んだものを推定量とする Frequency Polygon(以降、FP と呼ぶ)を提案した。その中で、FP がヒストグラムの推定精度を改良できることを示している。FP の関連研究として、Minnotte(1996)が各ビンの中点を節点とし、その高さを各ビンの面積相等性¹⁾を満たすように決定する Bias-Optimized Frequency Polygon(以降、BFP と呼ぶ)を提案している。また、Jones, Samiuddin, Al-Harbey and Maatouk(1998)がビンの端点を節点とし、隣接ビンの高さの中点を節点の高さとする Edge Frequency Polygon(以降、EFP と呼ぶ)がある。FP, BFP, EFP とともに隣接ビン同士を一次関数で接続することによってヒストグラムの不連続性を解消する手法である。

ここで、2次以上の滑らかな曲線で隣接ビン間を接続するために、ヒストグラムを3次スプライン関数によって平滑化することが考えられる。スプライン関数とは、多項式を何らかの連続条件を満たすように接続する区分的多項式であり、点同士を滑らかな曲線で繋ぐことができる。スプライン関数は Schoenberg(1946)の提案以降、盛んに研究が行われており、その数学的な性質が明らかとなっている。ヒストグラムのスプライン平滑化に関しては、Boneva, Kendall and Stefanov(1971)(以下、BKS と略す)が Histospline を提唱し、Schoenberg(1972)が定式化した。しかしながら、BKS と Schoenberg はモデルの提案に留まり、理論的性質については導出していない。一方、Lii and Rosenblatt(1974)(以下、L&R と略す)が BKS と Schoenberg とは異なるアプローチでヒストグラムをスプライン平滑化し、その漸近的性質について導出した。その中で、スプライン平滑化したヒストグラムは漸近的にバイアス $O(h^3)$ 、分散 $O(1/nh)$ であることが示された。しかしながら、L&R は BKS+Schoenberg との差異もしくは同等性については明示していない。また、平均積分二乗誤差(以下、MISE と呼ぶ)について、定数項を含む明示的な表現までは導いていない。

以上より、本稿では上記の BKS+Schoenberg と L&R の2つのヒストグラムのスプライン平滑化は同等であることを示し、ヒストスプライン推定量の漸近表現を陽な形で導く。加えて、その漸近正規性を示す。また、有限標本におけるヒストグラムとヒストスプラインの推定精度を比較するため、数値実験を行う。

2. BKS+Schoenberg と L&R の設定の違いについて

2.1. Boneva, Kendall and Stefanov+ Schoenberg の設定

まず、BKS+Schoenberg によるヒストグラムの3次スプライン平滑化の定式化について説明する。スプライン関数はヒストグラムの累積分布関数の推定量としている。サンプル数 n 、区間 $[0,1]$ で等間隔の節点 $x_j(j = 0, 1, \dots, N)$ を決め、度数 $v_j \in [x_{j-1}, x_j)(j = 1, 2, \dots, N)$ のヒストグラムの面積 $s_j = \frac{v_j}{n} (j = 1, 2, \dots, N)$ を得る。ヒストグラムについて累積経験分布関数 $G_j(j = 0, 1, \dots, N)$ は以下の通りに与えられる。

$$\begin{cases} G_0 = 0, \\ G_i = \sum_{j=1}^i s_j (i = 1, 2, \dots, N). \end{cases} \quad (2.1)$$

このとき

$$S(x_j) = G_j \quad (j = 0, 1, \dots, N),$$

を満たす3次スプライン関数 $S(x)$ が存在する。 $S_{BKS}(x)$ は以下の制約条件のもとで決定される。

1. 面積相等性： $\int_{x_{j-1}}^{x_j} \hat{f}(x) dx = S_{BKS}(x_j) - S_{BKS}(x_{j-1}) = G_j - G_{j-1} = s_j$
2. 1次導関数の連続性： $S'_{BKS}(x_j -) = S'_{BKS}(x_j +)$
3. 2次導関数の連続性： $S''_{BKS}(x_j -) = S''_{BKS}(x_j +)$
4. 端条件： $S'_{BKS}(x_0) = S'_{BKS}(x_N) = 0$

ただし、 $\hat{f}(x)$ はスプライン平滑化したヒストグラムの密度推定量、 $S'(x_j)$ は節点 x_j における $S(x)$ の1次微係数、 $S''(x_j)$ は節点 x_j における $S(x)$ の2次微係数、 $S'(x_j -)$ は、節点 x_j における $S'(x)$ の左方微分係数、 $S'(x_j +)$ は右方微分係数である。

ここで、まず $S_{BKS}(x)$ について、以下のように決定される。

$$\begin{aligned} S_{BKS}(x) = m_{j-1} \frac{(x_j - x)^2 (x - x_{j-1})}{h^2} - m_j \frac{(x - x_{j-1})^2 (x_j - x)}{h^2} + G_{j-1} \frac{(x_j - x)^2 [2(x - x_{j-1}) + h]}{h^3} \\ + G_j \frac{(x - x_{j-1})^2 [2(x_j - x) + h]}{h^3}, \end{aligned} \quad (2.2)$$

ただし、 m_j ($j = 0, 1, \dots, N$)は節点 x_j における $S(x)$ の1次微係数(= $S'(x_j)$)、 $h = x_j - x_{j-1}$ (=ヒストグラムのビン幅)である。

(2.2)式の微分によってスプライン平滑化したヒストグラムの密度推定量 $\hat{f}(x)$ は得られ、ビン B_j 、 $x \in [x_{j-1}, x_j]$ において次の表現を得る：

$$\hat{f}_j(x) = m_{j-1} \frac{(x_j - x)(2x_{j-1} + x_j - 3x)}{h^2} - m_j \frac{(x - x_{j-1})(2x_j + x_{j-1} - 3x)}{h^2} + \frac{6s_j}{h^3} (x_j - x)(x - x_{j-1}). \quad (2.3)$$

ただし、 $\hat{f}_j(x)$ は $x \in B_j$ を意味する。：

(2.3)式で m_j は未知であるため、 $\hat{f}_j(x)$ の導関数の連続性 $S''_{BKS}(x_j -) = S''_{BKS}(x_j +)$ から、

$$\frac{1}{6} m_{j-1} + \frac{2}{3} m_j + \frac{1}{6} m_{j+1} = \frac{s_j + s_{j+1}}{2h} = \frac{v_j + v_{j+1}}{2nh} \quad (j = 1, 2, \dots, N-1), \quad (2.4)$$

を m_j について解く。

m_j について解いた $\hat{f}_j(x)$ の表現は

$$\begin{aligned} \hat{f}_j(x) = \frac{1}{h^3} \{-2h(x_j - x) + 3(x_j - x)^2\} \sum_{k=1}^{N-1} w_{j-1,k} \left(\frac{s_k + s_{k+1}}{2} \right) \\ + \frac{1}{h^3} \{h^2 - 4(x_j - x) + 3(x_j - x)^2\} \sum_{l=1}^{N-1} w_{j,l} \left(\frac{s_l + s_{l+1}}{2} \right) - \frac{6}{h^3} \{-h(x_j - x) + (x_j - x)^2\} s_j, \end{aligned} \quad (2.5)$$

ただし, $w_{j,l}$ は重み $\sum_{l=1}^{N-1} w_{j,l} = 1$ で,

$$w_{j,l} = \frac{3}{\sqrt{3}} (\sqrt{3} - 2)^{|j-l|},$$

である。 $w_{j,l}$ の導出法については文献(4)を参照のこと。

2.2. Lii and Rosenblatt の設定

L&R によるヒストグラムの 3 次スプライン平滑化の定式化について説明する。L&R は、ヒストグラムの累積分布関数の推定量として 3 次スプライン関数を使用する仮定で制約条件を決定している。2.1 節と同じく、サンプル数 n , 区間 $[0,1]$ で、等間隔の節点 $x_j (j = 0, 1, \dots, N)$ はビンの端点とする。3 次スプライン関数 $S(x)$ の 2 次導関数 $S''(x)$ は線分となることから、以下の $S''(x)$ の連続性をまず制約条件として設定する。

$$S''_{LR}(x) = M_{j-1} \frac{x_j - x}{h} + M_j \frac{x - x_{j-1}}{h}, \quad (2.6)$$

ただし, M_j は節点 x_j における $S(x)$ の 2 次微係数である。 x_j におけるヒストグラムの累積分布関数の高さを G_j とし, (2.6) 式を 2 回積分して, 条件 $S(x_{j-1}) = G_{j-1}$, $S(x_j) = G_j$ より積分定数を求めることで,

$$S_{LR}(x) = M_{j-1} \left\{ \frac{(x_j - x)^3}{6h} - \frac{x_j - x}{6} h \right\} + M_j \left\{ \frac{(x - x_{j-1})^3}{6h} - \frac{x - x_{j-1}}{6} h \right\} + G_{j-1} \frac{x_j - x}{h} + G_j \frac{x - x_{j-1}}{h}, \quad (2.7)$$

を得る。また, 条件 $S_{LR}(x_{j-1}) = G_{j-1}$, $S_{LR}(x_j) = G_j$ より面積相等性の条件が満たされる。

$S_{LR}(x)$ の微分は,

$$S'_{LR}(x) = -M_{j-1} \frac{(x - x_j)^2}{2h} + M_j \frac{(x - x_{j-1})^2}{2h} - \frac{h}{6} (M_j - M_{j-1}) + \frac{S_j}{h}, \quad (2.8)$$

となり, これがスプライン平滑化したヒストグラムの密度推定量となる。節点 x_j における $S'_{LR}(x)$ の左方微分係数及び右方微分係数はそれぞれ次のようになる。

$$\begin{cases} S'_{LR}(x_j -) = \frac{h}{6} M_{j-1} + \frac{h}{3} M_j + \frac{G_j - G_{j-1}}{h}, \\ S'_{LR}(x_j +) = \frac{h}{6} M_j + \frac{h}{3} M_{j+1} + \frac{G_{j+1} - G_j}{h}. \end{cases} \quad (2.9)$$

点 x_j での一次連続性を満たすには, (2.9) 式が等しくなる必要があるため, 度数 $v_j \in [x_{j-1}, x_j)$, ($j = 1, 2, \dots, N$) とすると,

$$\frac{1}{6} M_{j-1} + \frac{2}{3} M_j + \frac{1}{6} M_{j+1} = \frac{v_{j+1} - v_j}{nh^2}, \quad (2.10)$$

となる。この制約条件により得られる方程式には未知の M_j が含まれており, この M_j について解く問題となる。しかしながら, $N-1$ 個の方程式よりも $N+1$ 個の未知数の方が多く, 更に 2 つの制約条件が必要であるため, 端条件として $M_0 = M_N = 0$ を設定する。これにより, M_0, \dots, M_N について解くことが可能となり, 目的の推定量を得る。

L&R は上記の設定で, $S'_{LR}(x)$ のバイアスの主要項を導出しており,

$$\text{Bias}\{S'_{LR}(x)\} = \frac{f'''(x)}{4!} h^3 \{(1-r)^4 - r^4 - (1-r)^2 + r^2\}, \quad (2.11)$$

ただし、 $r = (x - x_{j-1})/h$ である。また、 $S'_{LR}(x)$ の分散の主要項について以下のように導出している。

$$\text{Var}\{S'_{LR}(x)\} = \frac{f(x)}{nh} A(r), \quad (2.12)$$

ただし、 $A(r)$ は $\sigma = \sqrt{3} - 2$ とし、以下の通りである。

$$\begin{aligned} A(r) = & 1 - \frac{3(1-\sigma)}{2+\sigma} \left(2r^2 - 2r + \frac{1}{3} \right) \\ & + \frac{9}{4} \left(\frac{1-\sigma}{2+\sigma} \right)^2 \left[\left(2r^2 - 2r + \frac{1}{3} \right)^2 + \left[\left(r^2 - \frac{1}{3} \right) + \sigma \left(\frac{1}{3} - (1-r)^2 \right) \right]^2 \frac{1}{1-\sigma^2} \right. \\ & \left. + \left[\left(r^2 - \frac{1}{3} \right) + \frac{1}{\sigma} \left(\frac{1}{3} - (1-r)^2 \right) \right]^2 \frac{\sigma^2}{1-\sigma^2} \right]. \end{aligned} \quad (2.13)$$

更に、 $S'_{LR}(x)$ の漸近正規性が成り立つことについて、リアプノフの条件を満たすことから中心極限定理を証明している。しかしながら、その平均と分散の明示的な表現については示していない。

表1は上記で述べたBKS+SchoenbergとL&Rの制約条件等を整理したものを示す。表中の記号について、節点 x_j ($j = 0, 1, \dots, N$)、節点 x_j でのヒストグラムの累積分布関数の値 G_j 、スプライン関数による累積経験分布関数の推定量 $S(x)$ 、スプライン関数の1次導関数による密度関数の推定量 $S'(x)$ 、スプライン関数の2次導関数 $S''(x)$ 、節点 x_j における $S'(x)$ の左方微分係数 $S'(x_j -)$ 、右方微分係数 $S'(x_j +)$ である。

表1 BKS+Schoenberg と Lii and Rosenblatt の制約条件

	スプライン関数の次数	スプライン表現	スプライン関数内の微係数	節点箇所	面積相等性 $S(x_j) = G_j$	連続性条件	未知の係数を解くための制約条件	端条件
BKS, Schoenberg	3(累積分布関数)	3次スプライン	$S'(x_j)$	ビンの端点	○	$S(x_j -) = S(x_j +)$ $S'(x_j -) = S'(x_j +)$	S'' の連続性 $S''(x_j -) = S''(x_j +)$	$S'(x_0) = S'(x_N)$ $= 0$
Lii and Rosenblatt	3(累積分布関数)	3次スプライン	$S''(x_j)$	ビンの端点	○	$S(x_j -) = S(x_j +)$ $S''(x_j -) = S''(x_j +)$	S' の連続性 $S'(x_j -) = S'(x_j +)$	$S''(x_0) = S''(x_N)$ $= 0$

3. 定理

スプライン平滑化したヒストグラム密度推定量の大標本特性は、次の2つの条件

1. ビン幅 h について、 $n \rightarrow \infty$ のとき、 $h \rightarrow 0$ かつ $nh \rightarrow \infty$
2. 関数 $f(x)$ は絶対連続関数で、導関数の二階積分が可能

を満たすとき、以下の通りである。

BKS+Schoenberg が提案したヒストスプラインと、L&R が提案した3次スプライン平滑化によるヒストグラムについて次の定理が成り立つ。

定理 1. BKS+Schoenberg と L&R の同等性

BKS+Schoenberg の設定における推定量：

$$S'_{BKS}(x) = m_{j-1} \frac{(x_j - x)(2x_{j-1} + x_j - 3x)}{h^2} - m_j \frac{(x - x_{j-1})(2x_j + x_{j-1} - 3x)}{h^2} + \frac{6s_j}{h^3} (x_j - x)(x - x_{j-1}),$$

および、L&R の設定における推定量：

$$S'_{LR}(x) = -M_{j-1} \frac{(x - x_j)^2}{2h} + M_j \frac{(x - x_{j-1})^2}{2h} - \frac{h}{6} (M_j - M_{j-1}) + \frac{S_j}{h},$$

が方程式として同等である。

定理 1 で同等性が示されたため、BKS+Schoenberg と L&R の推定量では同じ AMISE を得る。ヒストスプライン推定量の明示的な AMISE は次の通りである。

定理 2. ヒストスプラインの AMISE

ヒストスプライン推定量 $\hat{f}(x)$ の漸近的な MISE(AMISE)は、

$$\begin{aligned} \text{AMISE}(\hat{f}(x)) &= \text{AIV}(\hat{f}(x)) + \text{AISB}(\hat{f}(x)) \\ &= \left(\frac{5\sqrt{3} + 3}{10} \right) \frac{1}{nh} + \frac{R(f''')}{30240} h^6, \end{aligned}$$

ただし、AIV は漸近積分分散、AISB は漸近積分二乗バイアスを表し、 $R(f''') = \int f'''(x)^2 dx$ である。

最小 AMISE*は

$$\text{AMISE}^* = \frac{35\sqrt{3} + 21}{60} \left(\frac{R(f''')}{2520\sqrt{3} + 1512} \right)^{\frac{1}{7}} n^{-\frac{6}{7}},$$

であり、このときの最適ビン幅 h^* は

$$h^* = \left(\frac{2520\sqrt{3} + 1512}{R(f''')} \right)^{\frac{1}{7}} n^{-\frac{1}{7}},$$

である。

AMISE($\hat{f}(x)$)をヒストグラムの $\text{AMISE}_{\text{hist}}(\hat{f}(x)) = \frac{1}{nh} + \frac{R(f')}{12} h^2$ と比較すると、分散項は大きくなる

一方で二乗バイアス項が小さくなる。これは、ビン幅についての条件： $n \rightarrow \infty$ のとき、 $h \rightarrow 0$ かつ

$nh \rightarrow \infty$ からも明らかな通り、分散とバイアスがトレードオフの関係にあるからである。

ヒストスプライン推定量の平均積分誤差(以下、MSEと呼ぶ)の上限について次の通りである。

系 1. ヒストスプライン推定量の MSE の上限

$x \in [x_{j-1}, x_j]$, $0 \leq |x_j - x| \leq h$ とすると、ヒストスプライン推定量の MSE の上限は、

$$\text{MSE}\{S'_{BKS}(x)\} \leq \sqrt{nh} \frac{f'''(x)}{2} h^3 + \left(\frac{16\sqrt{3}}{9} + \frac{9}{4} \right) \frac{1}{nh} f(x).$$

BKS+Schoenberg によるヒストスプラインと、L&R による 3 次スプライン平滑化によるヒストグラムについて次の補助定理が成り立つ。

補助定理. ヒストスプラインと L&R による推定量の同等性

ヒストスプライン推定量：

$$S'_{BKS}(x) = m_{j-1} \frac{(x_j - x)(2x_{j-1} + x_j - 3x)}{h^2} - m_j \frac{(x - x_{j-1})(2x_j + x_{j-1} - 3x)}{h^2} + \frac{6s_j}{h^3} (x_j - x)(x - x_{j-1}),$$

および、L&R による漸近正規性の証明における推定量(文献(4), p.229)：

$$S'_{LR}(x) = \frac{1}{h} (G_j - G_{j-1}) + \sum_{i=0}^N \frac{3a_{j,i}}{h^2} [G_{i+1} - 2G_i + G_{i-1}],$$

について、 $S'_{BKS}(x) = S'_{LR}(x)$ が成り立つ。ただし、

$$a_{j,i} = \left\{ \frac{(x - x_{j-1})^2}{2h} - \frac{h}{6} \right\} A_{j,i}^{-1} + \left\{ \frac{h}{6} - \frac{(x_j - x)^2}{2h} \right\} A_{j-1,i}^{-1}, \quad (3.1)$$

であり、 $A_{j,i}^{-1}$, ($i = 0, \dots, N$)は(2.4), (2.10)式の m_j および M_j の係数についての逆行列 A^{-1} の(j, i)要素である。 $A_{j,i}^{-1}$ の導出については文献(4)を参照のこと。

以上の補助定理より、スプライン平滑化によるヒストグラムの漸近正規性の成立については、L&R(1974)で示された Theorem 4.に準ずる。従って、ヒストスプラインの漸近正規性について定数項を含む明示的な表現は次の通りである。

系 2. 各ビンにおけるヒストスプラインの漸近正規性

$h \propto O(n^{-\alpha})$, $x \in B_j$ に対して、

$\alpha = \frac{1}{7}$ のとき

$$\sqrt{nh}\{\hat{f}_j(x) - f(x)\} \xrightarrow{d} N\left(\sqrt{nh} \frac{f'''(x)}{6} h^3 \left(r^3 - \frac{3}{2}r^2 + \frac{1}{2}r\right), \frac{5\sqrt{3} + 3}{10} f(\xi_j)\right)$$

$\alpha > \frac{1}{7}$ のとき

$$\sqrt{nh}\{\hat{f}_j(x) - f(x)\} \xrightarrow{d} N\left(0, \frac{5\sqrt{3}+3}{10}f(\xi_j)\right),$$

が漸近的に成り立つ。ただし、 $r = \frac{1}{h}(x_j - x)$, $f(\xi_j), \xi_j \in B_j$ は $p_j = \int_{B_j} f(t)dt = hf(\xi_j)$ を満たす点である。

4. 定理と系の証明

4.1. 定理 1. BKS+Schoenberg と L&R の同等性の証明

BKS+Schoenberg と L&R の同等性について以下に示す。BKS+Schoenberg の設定による密度推定量は、

$$S'_{BKS}(x) = m_{j-1} \frac{(x_j - x)(2x_{j-1} + x_j - 3x)}{h^2} - m_j \frac{(x - x_{j-1})(2x_j + x_{j-1} - 3x)}{h^2} + \frac{6s_j}{h^3}(x_j - x)(x - x_{j-1}). \quad (4.1)$$

$S'_{BKS}(x)$ を微分して、

$$S''_{BKS}(x) = m_{j-1} \frac{(6x - 4x_j - 2x_{j-1})}{h^2} - m_j \frac{(-6x + 2x_j + 4x_{j-1})}{h^2} + \frac{6s_j}{h^3}(-2x + x_j + x_{j-1}). \quad (4.2)$$

M_j を節点 x_j における $S_{BKS}(x)$ の 2 次微係数とし、 $S''_{BKS}(x)$ に x_j と x_{j-1} をそれぞれ代入して、

$$\begin{cases} S''_{BKS}(x_j) = m_{j-1} \frac{(2x_j - 2x_{j-1})}{h^2} - m_j \frac{(-4x_j + 4x_{j-1})}{h^2} + \frac{6s_j}{h^3}(-x_j + x_{j-1}) = M_j, & (4.3) \end{cases}$$

$$\begin{cases} S''_{BKS}(x_{j-1}) = m_{j-1} \frac{(-4x_j + 4x_{j-1})}{h^2} - m_j \frac{(2x_j - 2x_{j-1})}{h^2} + \frac{6s_j}{h^3}(x_j - x_{j-1}) = M_{j-1}, & (4.4) \end{cases}$$

(4.3)-(4.4) より、

$$m_{j-1} \frac{(6x_j - 6x_{j-1})}{h^2} - m_j \frac{(-6x_j + 6x_{j-1})}{h^2} + \frac{6s_j}{h^3}(-2x_j + 2x_{j-1}) = M_j - M_{j-1}. \quad (4.5)$$

(4.3)+(4.4) より、

$$m_{j-1} \frac{(-2x_j + 2x_{j-1})}{h^2} - m_j \frac{(-2x_j + 2x_{j-1})}{h^2} = M_j + M_{j-1}. \quad (4.6)$$

(4.6)式で項を入れ替えて、

$$m_{j-1} = (M_j + M_{j-1}) \frac{h^2}{-2(x_j - x_{j-1})} + m_j. \quad (4.7)$$

(4.7)式を(4.5)式に代入して m_j について解くと、

$$m_j = \frac{s_j}{h} + (2M_j + M_{j-1}) \frac{h^2}{6(x_j - x_{j-1})}. \quad (4.8)$$

(4.8)式を(4.7)式に代入して、

$$m_{j-1} = \frac{S_j}{h} + (M_j + 2M_{j-1}) \frac{h^2}{-6(x_j - x_{j-1})}. \quad (4.9)$$

(4.8)式と(4.9)式を密度推定量(4.1)式に代入して,

$$\begin{aligned} S'_{BKS}(x) &= (M_j + 2M_{j-1}) \frac{h^2}{-6(x_j - x_{j-1})} \frac{(x_j - x)(2x_{j-1} + x_j - 3x)}{h^2} + \frac{S_j}{h} \frac{(x_j - x)(2x_{j-1} + x_j - 3x)}{h^2} \\ &\quad - (2M_j + M_{j-1}) \frac{h^2}{6(x_j - x_{j-1})} \frac{(x - x_{j-1})(2x_j + x_{j-1} - 3x)}{h^2} - \frac{S_j}{h} \frac{(x - x_{j-1})(2x_j + x_{j-1} - 3x)}{h^2} \\ &\quad + \frac{6S_j}{h^3} (x_j - x)(x - x_{j-1}), \end{aligned} \quad (4.10)$$

整理すると,

$$S'_{BKS}(x) = -M_{j-1} \frac{(x - x_j)^2}{2h} + M_j \frac{(x - x_{j-1})^2}{2h} - \frac{h}{6} (M_j - M_{j-1}) + \frac{S_j}{h},$$

これは, L&R の設定における密度推定量(2.6)式と一致するため, $S'_{BKS}(x) = S'_{LR}(x)$ である。以上で定理 1 は証明された。

4.2. 定理 2. AMISE($\hat{f}(x)$)の証明

定理 2 の証明について, MISE の定義は以下の通りである。

$$\begin{aligned} \text{MISE} &:= E[\text{ISE}] \\ &= E \left\{ \int [\hat{f}(t) - f(t)]^2 dx \right\} = \int E[\hat{f}(t) - f(t)]^2 dx \\ &= \text{IV}[\hat{f}(t)] + \text{ISB}[\hat{f}(t)], \end{aligned}$$

ただし, IV と ISB は次のように定義される。

$$\begin{aligned} \text{IV}[\hat{f}(t)] &= \int \text{Var}[\hat{f}(t)] dt, \\ \text{ISB}[\hat{f}(t)] &= \int \text{Bias}[\hat{f}(t)]^2 dt. \end{aligned}$$

MISE は分散項 IV と二乗バイアス項 ISB に分解でき, MISE の値が 0 に近いほど推定量と真の密度との誤差が小さいことを意味する。

AMISE($\hat{f}(x)$)は漸近積分分散 AIV($\hat{f}(x)$)と漸近積分二乗バイアス AISB($\hat{f}(x)$), それぞれについて導出する。

まず漸近積分二乗バイアスについて示す。ヒストスプライン推定量は, (2.5)式より,

$$\begin{aligned} \hat{f}_j(x) &= \frac{1}{h^3} \left\{ -2h(x_j - x) + 3(x_j - x)^2 \right\} \sum_{k=1}^{N-1} w_{j-1,k} \left(\frac{S_k + S_{k+1}}{2} \right) \\ &\quad + \frac{1}{h^3} \left\{ h^2 - 4(x_j - x) + 3(x_j - x)^2 \right\} \sum_{l=1}^{N-1} w_{j,l} \left(\frac{S_l + S_{l+1}}{2} \right) - \frac{6}{h^3} \left\{ -h(x_j - x) + (x_j - x)^2 \right\} S_j, \end{aligned}$$

ただし, $w_{j,l}$ は重み $\sum_{l=1}^{N-1} w_{j,l} = 1$ で,

$$w_{j,l} = \frac{3}{\sqrt{3}} (\sqrt{3} - 2)^{|j-l|},$$

である。(2.5)式について期待値を取ると, $S_j = \frac{v_j}{n}$ より,

$$E[\hat{f}_j(x)] = \frac{1}{2n} C_{1j}(x) \sum_{k=1}^{N-1} w_{j-1,k} (E[v_k] + E[v_{k+1}]) - \frac{1}{2n} C_{2j}(x) \sum_{l=1}^{N-1} w_{j,l} (E[v_l] + E[v_{l+1}]) + \frac{1}{n} C_{3j}(x) E[v_j], \quad (4.11)$$

ただし,

$$C_{1j}(x) = \frac{1}{h^3} \{-2h(x_j - x) + 3(x_j - x)^2\},$$

$$C_{2j}(x) = \frac{1}{h^3} \{-2h(x - x_{j-1}) + 3(x - x_{j-1})^2\},$$

$$C_{3j}(x) = \frac{6}{h^3} (x_j - x)(x - x_{j-1}).$$

$v_j \sim B(n, p_k)$ で, $p_k = \int_{B_j} f(t) dt$ とすると, (4.11)式は

$$\begin{aligned} E[\hat{f}_j(x)] &= \frac{1}{2n} C_{1j}(x) \sum_{k=1}^{N-1} w_{j-1,k} (np_k + np_{k+1}) - \frac{1}{2n} C_{2j}(x) \sum_{l=1}^{N-1} w_{j,l} (np_l + np_{l+1}) + \frac{1}{n} C_{3j}(x) np_j \\ &= C_{1j}(x) \sum_{k=1}^{N-1} w_{j-1,k} \frac{1}{2} \left(\int_{B_k} f(t) dt + \int_{B_{k+1}} f(t) dt \right) - C_{2j}(x) \sum_{l=1}^{N-1} w_{j,l} \frac{1}{2} \left(\int_{B_l} f(t) dt + \int_{B_{l+1}} f(t) dt \right) \\ &\quad + C_{3j}(x) \int_{B_j} f(t) dt. \end{aligned} \quad (4.12)$$

ここで, $f(t)$ は未知のため, テイラー級数により近似すると,

$$\begin{aligned} E[\hat{f}_j(x)] &= C_{1j}(x) \sum_{k=1}^{N-1} w_{j-1,k} \left\{ hf(x) + hf'(x)(x_k - x) + \frac{f''(x)}{2} h \left(x_k^2 - 2x_k x + \frac{h^2}{3} + x^2 \right) \right. \\ &\quad \left. + \frac{f'''(x)}{6} h (x_k^3 + x_k h^2 - (3x_k^2 + h^2)x + 3x_k x^2 - x^3) \right\} \\ &\quad - C_{2j}(x) \sum_{l=1}^{N-1} w_{j,l} \left\{ hf(x) + hf'(x)(x_l - x) + \frac{f''(x)}{2} h \left(x_l^2 - 2x_l x + \frac{h^2}{3} + x^2 \right) \right. \\ &\quad \left. + \frac{f'''(x)}{6} h (x_l^3 + x_l h^2 - (3x_l^2 + h^2)x + 3x_l x^2 - x^3) \right\} \\ &\quad + C_{3j}(x) \left[hf(x) + hf'(x) \left(x_j - \frac{h}{2} - x \right) + \frac{f''(x)}{2} h \left(x_j^2 - x_j h + \frac{h^2}{3} + (-2x_j + h)x + x^2 \right) \right. \\ &\quad \left. + \frac{f'''(x)}{6} h \left\{ x_j^3 - \frac{3}{2} x_j^2 h + x_j h^2 - \frac{h^3}{4} + (-3x_j^2 + 3x_j h - h^2)x - \frac{3}{2} (-2x_j + h)x^2 - x^3 \right\} \right]. \end{aligned} \quad (4.13)$$

(4.13)式について, $x_0 = 0$, $x_j = x_0 + jh = jh$ とし, $\sum_{l=1}^{N-1} w_{j,l} l = j$, $\sum_{l=1}^{N-1} w_{j,l} l^2 = j^2 - \frac{1}{3}$, $\sum_{l=1}^{N-1} w_{j,l} l^3 = j^3 - j$ であることを利用して整理すると,

$$E[\hat{f}_j(x)] = f(x) + \frac{f'''(x)}{6} \left\{ \left(j^3 h^3 - \frac{3}{2} j^2 h^3 + \frac{1}{2} j h^3 \right) + \left(-3j^2 h^2 + 3jh^2 - \frac{1}{2} h^2 \right) x + \left(3jh - \frac{3}{2} h \right) x^2 - x^3 \right\}. \quad (4.14)$$

したがって, $\hat{f}_j(x)$ のバイアスは,

$$\begin{aligned}
\text{Bias}(\widehat{f}_j(x)) &= E[\widehat{f}_j(x)] - f(x) \\
&= \frac{f'''(x)}{6} \left\{ \left(j^3 h^3 - \frac{3}{2} j^2 h^3 + \frac{1}{2} j h^3 \right) + \left(-3j^2 h^2 + 3j h^2 - \frac{1}{2} h^2 \right) x + \left(3j h - \frac{3}{2} h \right) x^2 - x^3 \right\},
\end{aligned} \tag{4.15}$$

となる。このことから、ビン B_j における漸近積分二乗バイアス(AISB)は、

$$\begin{aligned}
\text{AISB}_j &= \int_{x_{j-h}}^{x_j} \frac{f'''(x)^2}{36} \left\{ \left(j^3 h^3 - \frac{3}{2} j^2 h^3 + \frac{1}{2} j h^3 \right) + \left(-3j^2 h^2 + 3j h^2 - \frac{1}{2} h^2 \right) x + \left(3j h - \frac{3}{2} h \right) x^2 - x^3 \right\}^2 dx \\
&= \frac{1}{30240} f'''(x)^2 h^7.
\end{aligned} \tag{4.16}$$

以上より、全体での AISB は、リーマン積分近似 $\sum_k f'''(\xi_k)^2 h = [\int f'''(x)^2 dx + o(1)]$ を用いて、

$$\text{AISB} = \frac{R(f''')}{30240} h^6, \tag{4.17}$$

ただし、 $R(f''') = \int f'''(x)^2 dx$ である。

続いて、分散について、

$$\begin{aligned}
\text{Var}(\widehat{f}_j(x)) &= \text{Var}\left(\frac{1}{2n} \sum_{k=1}^{N-1} w_{j-1,k}(v_k + v_{k+1})\right) + \text{Var}\left(\frac{1}{2n} \sum_{l=1}^{N-1} w_{j,l}(v_l + v_{l+1})\right) + \text{Var}\left(C_{3j}(x) \frac{v_j}{n}\right) \\
&\quad + 2\text{Cov}\left(\frac{1}{2n} \sum_{k=1}^{N-1} w_{j-1,k}(v_k + v_{k+1}), \frac{1}{2n} \sum_{l=1}^{N-1} w_{j,l}(v_l + v_{l+1})\right) \\
&\quad + 2\text{Cov}\left(\frac{1}{2n} \sum_{k=1}^{N-1} w_{j-1,k}(v_k + v_{k+1}), C_{3j}(x) \frac{v_j}{n}\right) + 2\text{Cov}\left(\frac{1}{2n} \sum_{l=1}^{N-1} w_{j,l}(v_l + v_{l+1}), C_{3j}(x) \frac{v_j}{n}\right).
\end{aligned} \tag{4.18}$$

第1項は、

$$\begin{aligned}
&\text{Var}\left(\frac{1}{2n} \sum_{k=1}^{N-1} w_{j-1,k}(v_k + v_{k+1})\right) \\
&= \frac{1}{4n^2} C_{1j}(x)^2 \left\{ \text{Var}\left(\sum_{k=1}^{N-1} w_{j-1,k} v_k\right) + \text{Var}\left(\sum_{k=1}^{N-1} w_{j-1,k} v_{k+1}\right) \right. \\
&\quad \left. + 2\text{Cov}\left(\sum_{k=1}^{N-1} w_{j-1,k} v_k, \sum_{k=1}^{N-1} w_{j-1,k} v_{k+1}\right) \right\} = 2\sqrt{3} \frac{h}{n} C_{1j}(x)^2 f(x),
\end{aligned}$$

ここで、 $\text{Var}(\cdot)$ を積分したものを $\text{AIVar}(\cdot)$ とすると、

$$\text{AIVar}\left(\frac{1}{2n} \sum_{k=1}^{N-1} w_{j-1,k}(v_k + v_{k+1})\right) = \frac{\sqrt{3}}{15} \frac{1}{nh} f(x) h. \tag{4.19}$$

第2項も第1項と同様に、

$$\begin{aligned}
&\text{Var}\left(\frac{1}{2n} \sum_{l=1}^{N-1} w_{j,l}(v_l + v_{l+1})\right) \\
&= \frac{1}{4n^2} C_{2j}(x)^2 \left\{ \text{Var}\left(\sum_{l=1}^{N-1} w_{j,l} v_l\right) + \text{Var}\left(\sum_{l=1}^{N-1} w_{j,l} v_{l+1}\right) + 2\text{Cov}\left(\sum_{l=1}^{N-1} w_{j,l} v_l, \sum_{l=1}^{N-1} w_{j,l} v_{l+1}\right) \right\} \\
&= 2\sqrt{3} \frac{h}{n} C_{2j}(x)^2 f(x),
\end{aligned}$$

積分して,

$$\text{AIVar}\left(\frac{1}{2n}\sum_{l=1}^{N-1}w_{j,l}(v_l+v_{l+1})\right)=\frac{\sqrt{3}}{15}\frac{1}{nh}f(x)h. \quad (4.20)$$

第3項は,

$$\text{Var}\left(C_{3j}(x)\frac{v_j}{n}\right)=\frac{1}{n^2}C_{3j}(x)^2\text{Var}(v_j)=\frac{h}{n}C_{3j}(x)^2f(x),$$

積分して,

$$\text{AIVar}\left(C_{3j}(x)\frac{v_j}{n}\right)=\frac{6}{5}\frac{1}{nh}f(x)h. \quad (4.21)$$

第4項は,

$$2\text{Cov}\left(\frac{1}{2n}\sum_{k=1}^{N-1}w_{j-1,k}(v_k+v_{k+1}), \frac{1}{2n}\sum_{l=1}^{N-1}w_{j,l}(v_l+v_{l+1})\right)=(5\sqrt{3}-9)\frac{h}{n}C_{1j}(x)C_{2j}(x)f(x)+O\left(\frac{h^2}{n}\right),$$

ここで, $\text{Cov}(\cdot)$ を積分したものを $\text{AICov}(\cdot)$ とすると,

$$2\text{AICov}\left(\frac{1}{2n}\sum_{k=1}^{N-1}w_{j-1,k}(v_k+v_{k+1}), \frac{1}{2n}\sum_{l=1}^{N-1}w_{j,l}(v_l+v_{l+1})\right)=\left(\frac{5\sqrt{3}-9}{30}\right)\frac{1}{nh}f(x)h. \quad (4.22)$$

第5項は,

$$2\text{Cov}\left(\frac{1}{2n}\sum_{k=1}^{N-1}w_{j-1,k}(v_k+v_{k+1}), C_{3j}(x)\frac{v_j}{n}\right)=(3-\sqrt{3})\frac{h}{n}C_{1j}(x)C_{3j}(x)f(x)+O\left(\frac{h^2}{n}\right),$$

積分して,

$$2\text{AICov}\left(\frac{1}{2n}\sum_{k=1}^{N-1}w_{j-1,k}(v_k+v_{k+1}), C_{3j}(x)\frac{v_j}{n}\right)=\left(\frac{\sqrt{3}-3}{10}\right)\frac{1}{nh}f(x)h. \quad (4.23)$$

第6項も第5項と同様に,

$$2\text{Cov}\left(\frac{1}{2n}\sum_{l=1}^{N-1}w_{j,l}(v_l+v_{l+1}), C_{3j}(x)\frac{v_j}{n}\right)=(3-\sqrt{3})\frac{h}{n}C_{2j}(x)C_{3j}(x)f(x),$$

積分して,

$$2\text{AICov}\left(\frac{1}{2n}\sum_{l=1}^{N-1}w_{j,l}(v_l+v_{l+1}), C_{3j}(x)\frac{v_j}{n}\right)=\left(\frac{\sqrt{3}-3}{10}\right)\frac{1}{nh}f(x)h. \quad (4.24)$$

したがって, (4.19)~(4.24)式より, ビン B_j における漸近積分分散は,

$$\text{AIV}_j=\left(\frac{\sqrt{3}}{15}+\frac{\sqrt{3}}{15}+\frac{6}{5}+\frac{5\sqrt{3}-9}{30}+\frac{\sqrt{3}-3}{10}+\frac{\sqrt{3}-3}{10}\right)\frac{1}{nh}f(x)h=\left(\frac{5\sqrt{3}+3}{10}\right)\frac{1}{nh}f(x)h. \quad (4.25)$$

以上より, 全体での AIV はリーマン積分近似 $\sum_k f(\xi_k)h = [\int f(x)dx + o(1)]$ より,

$$\text{AIV}=\left(\frac{5\sqrt{3}+3}{10}\right)\frac{1}{nh}. \quad (4.26)$$

まとめると, $\hat{f}(x)$ の AMISE は

$$\begin{aligned} \text{AMISE}(\hat{f}(x)) &= \text{AIV}(\hat{f}(x)) + \text{AISB}(\hat{f}(x)) \\ &= \left(\frac{5\sqrt{3}+3}{10}\right)\frac{1}{nh} + \frac{R(f''')}{30240}h^6, \end{aligned} \quad (4.27)$$

となる。以上より、定理 2 は証明された。

4.3. 系 1. ヒストスプライン推定量の MSE の上限の証明

ヒストスプライン推定量の MSE の上限の導出について示す。まず、ヒストスプライン推定量のバイアスは(4.15)式から、

$$\begin{aligned} \text{Bias}(S'_{BKS}(x)) &= \sqrt{nh} \frac{f'''(x)}{6} \left\{ \left(x_j^3 - \frac{3}{2}x_j^2h + \frac{1}{2}x_jh^2 \right) + \left(-3x_j^2 + 3x_jh - \frac{1}{2}h^2 \right)x + \left(3x_j - \frac{3}{2}h \right)x^2 - x^3 \right\} \\ &= \sqrt{nh} \frac{f'''(x)}{6} \left\{ (x_j - x)^3 - \frac{3}{2}h(x_j - x)^2 + \frac{1}{2}h^2(x_j - x) \right\}, \end{aligned}$$

ここで、 $0 \leq |x_j - x| \leq h$ より、

$$\text{Bias}(S'_{BKS}(x)) \leq \sqrt{nh} \frac{f'''(x)}{6} \left(h^3 + \frac{3}{2}h^3 + \frac{1}{2}h^3 \right) = \sqrt{nh} \frac{f'''(x)}{2} h^3. \quad (4.28)$$

続いて、分散について(4.19)～(4.24)式の導出において、 $0 \leq |x_j - x| \leq h$ より、 $C_{1j}(x)$ 、 $C_{2j}(x)$ 、 $C_{3j}(x)$ の絶対値に関して上限を求めると、

$$\begin{cases} |C_{1j}(x)| \leq \frac{1}{h} \\ |C_{2j}(x)| \leq \frac{1}{3h} \\ |C_{3j}(x)| \leq \frac{3}{2h} \end{cases} \quad (4.29)$$

であることから、

$$\text{Var}(S'_{BKS}(x)) \leq \left(\sqrt{3} + \frac{1}{3\sqrt{3}} + \frac{9}{4} + \frac{5\sqrt{3}-9}{3} + \frac{3(3-\sqrt{3})}{2} - \frac{3-\sqrt{3}}{2} \right) \frac{1}{nh} f(x) = \left(\frac{16\sqrt{3}}{9} + \frac{9}{4} \right) \frac{1}{nh} f(x). \quad (4.30)$$

以上より系 1.が示された。

4.4. 補助定理. ヒストスプラインと L&R による推定量の同等性の証明

ヒストスプラインの漸近正規性の証明に関する補助定理として、ヒストスプライン推定量と L&R による推定量が同等であることを示す。

(2.5)式からヒストスプライン推定量：

$$S'_{BKS}(x) = m_{j-1} \frac{(x_j - x)(2x_{j-1} + x_j - 3x)}{h^2} - m_j \frac{(x - x_{j-1})(2x_j + x_{j-1} - 3x)}{h^2} + \frac{6s_j}{h^3} (x_j - x)(x - x_{j-1}).$$

(2.4)式を書き換えると、

$$m_j = \sum_{i=0}^N A_{j,i}^{-1} d_i, \quad (4.31)$$

ただし、 d_i は(2.4)式の右辺を変形したものに対応し、

$$\begin{cases} d_i = \frac{3}{2h}(G_{i+1} - G_{i-1}), & (j = 1, \dots, N-1), \\ d_0 = \frac{3}{2h}(G_1 - G_0), \\ d_N = \frac{3}{2h}(G_N - G_{N-1}), \end{cases} \quad (4.32)$$

である。そのため、(4.31)式は以下のように表される。

$$m_j = \frac{3}{2h} \sum_{i=0}^N A_{j,i}^{-1} (G_{i+1} - G_{i-1}). \quad (4.33)$$

ここで、表記の簡便化のため、

$$b_{j,i} = \left\{ \frac{3(x - x_{j-1})^2}{h^2} - \frac{2(x - x_{j-1})}{h} \right\} A_{j,i}^{-1} + \left\{ \frac{3(x_j - x)^2}{h^2} - \frac{2(x_j - x)}{h} \right\} A_{j-1,i}^{-1}, \quad (4.34)$$

とする。(4.33)、(4.34)式を用いて(2.5)式を書き換えると、

$$\begin{aligned} S'_{BKS}(x) &= \frac{6}{h^3} (G_j - G_{j-1})(x_j - x)(x - x_{j-1}) + \frac{3}{2h} \sum_{i=0}^N b_{j,i} [(G_{i+1} - G_i) + (G_i - G_{i-1})] \\ &= \frac{1}{h} (G_j - G_{j-1}) + \frac{1}{h} (G_j - G_{j-1}) \left[-\frac{6(x - x_{j-1})^2}{h^2} + \frac{6(x - x_{j-1}) - h}{h} \right] \\ &\quad + \frac{3}{h^2} \sum_{i=0}^N \left[\left\{ \frac{3(x - x_{j-1})^2}{2h} - (x - x_{j-1}) \right\} A_{j,i}^{-1} + \left\{ \frac{3(x_j - x)^2}{2h} - (x_j - x) \right\} A_{j-1,i}^{-1} \right] [G_{i+1} - 2G_i + G_{i-1}] \\ &\quad + \left\{ \frac{9(x - x_{j-1})^2}{h^3} - \frac{6(x - x_{j-1})}{h^2} \right\} \sum_{i=0}^N A_{j,i}^{-1} (G_i - G_{i-1}) \\ &\quad + \left\{ \frac{9(x_j - x)^2}{h^3} - \frac{6(x_j - x)}{h^2} \right\} \sum_{i=0}^N A_{j-1,i}^{-1} (G_i - G_{i-1}). \end{aligned} \quad (4.35)$$

(3.1)式の $a_{j,i}$ を用いて(4.35)式を整理すると、

$$\begin{aligned} S'_{BKS}(x) &= \frac{1}{h} (G_j - G_{j-1}) + \frac{3}{h^2} \sum_{i=0}^N a_{j,i} [G_{i+1} - 2G_i + G_{i-1}] + \frac{1}{h} (G_j - G_{j-1}) \left[-\frac{6(x - x_{j-1})^2}{h^2} + \frac{6(x - x_{j-1}) - h}{h} \right] \\ &\quad + \frac{3}{h^2} \left\{ \frac{(x - x_{j-1})^2}{h} - (x - x_{j-1}) + \frac{h}{6} \right\} \sum_{i=0}^N A_{j,i}^{-1} [G_{i+1} - 2G_i + G_{i-1}] \\ &\quad + \frac{3}{h^2} \left\{ \frac{2(x_j - x)^2}{h} - (x_j - x) - \frac{h}{6} \right\} \sum_{i=0}^N A_{j-1,i}^{-1} [G_{i+1} - 2G_i + G_{i-1}] \\ &\quad + \left\{ \frac{9(x - x_{j-1})^2}{h^3} - \frac{6(x - x_{j-1})}{h^2} \right\} \sum_{i=0}^N A_{j,i}^{-1} (G_i - G_{i-1}) \\ &\quad + \left\{ \frac{9(x_j - x)^2}{h^3} - \frac{6(x_j - x)}{h^2} \right\} \sum_{i=0}^N A_{j-1,i}^{-1} (G_i - G_{i-1}). \end{aligned} \quad (4.36)$$

(4.36)式の第3~7項について、

$$\begin{aligned}
& \frac{1}{h}(G_j - G_{j-1}) \left[-\frac{6(x - x_{j-1})^2}{h^2} + \frac{6(x - x_{j-1}) - h}{h} \right] + \frac{3}{h^2} \left\{ \frac{(x - x_{j-1})^2}{h} - (x - x_{j-1}) + \frac{h}{6} \right\} \sum_{i=0}^N A_{j,i}^{-1} [G_{i+1} - 2G_i + G_{i-1}] \\
& + \frac{3}{h^2} \left\{ \frac{2(x_j - x)^2}{h} - (x_j - x) - \frac{h}{6} \right\} \sum_{i=0}^N A_{j-1,i}^{-1} [G_{i+1} - 2G_i + G_{i-1}] \\
& + \left\{ \frac{9(x - x_{j-1})^2}{h^3} - \frac{6(x - x_{j-1})}{h^2} \right\} \sum_{i=0}^N A_{j,i}^{-1} (G_i - G_{i-1}) \\
& + \left\{ \frac{9(x_j - x)^2}{h^3} - \frac{6(x_j - x)}{h^2} \right\} \sum_{i=0}^N A_{j-1,i}^{-1} (G_i - G_{i-1}) \\
& = \frac{1}{h}(G_j - G_{j-1}) \left[-\frac{6(x - x_{j-1})^2}{h^2} + \frac{6(x - x_{j-1}) - h}{h} \right] + \left\{ \frac{3(x - x_{j-1})^2}{h^3} - \frac{3(x - x_{j-1})}{h^2} + \frac{1}{2h} \right\} \sum_{i=0}^N A_{j,i}^{-1} (G_{i+1} - G_i) \\
& + \left\{ \frac{6(x - x_{j-1})^2}{h^3} - \frac{3(x - x_{j-1})}{h^2} - \frac{1}{2h} \right\} \sum_{i=0}^N A_{j,i}^{-1} (G_i - G_{i-1}) \\
& + \left\{ \frac{6(x_j - x)^2}{h^3} - \frac{3(x_j - x)}{h^2} - \frac{1}{2h} \right\} \sum_{i=0}^N A_{j-1,i}^{-1} (G_{i+1} - G_i) + \left\{ \frac{3(x_j - x)^2}{h^3} - \frac{3(x_j - x)}{h^2} + \frac{1}{2h} \right\} \sum_{i=0}^N A_{j-1,i}^{-1} (G_i - G_{i-1}), \tag{4.37}
\end{aligned}$$

ここで、文献(4)の(12)式、p.228の結果を用いて、 $y_i = G_i$ であるため、

$$G_i - G_{i-1} = f(x)h + O(h^2),$$

となり、また、 $A_{j,i}^{-1}$ について文献(4)の(21)~(24)式から、 $\sum_{i=0}^N A_{j,i}^{-1} = 1/3$ であるため、これらを用いて(4.37)式を整理すると、

$$\begin{aligned}
& \left[-\frac{6(x - x_{j-1})^2}{h^3} + \frac{6(x - x_{j-1}) - h}{h^2} \right] f(x)h + \left\{ \frac{3(x - x_{j-1})^2}{h^3} - \frac{3(x - x_{j-1})}{h^2} + \frac{1}{2h} \right\} \sum_{i=0}^N A_{j,i}^{-1} f(x)h \\
& + \left\{ \frac{6(x - x_{j-1})^2}{h^3} - \frac{3(x - x_{j-1})}{h^2} - \frac{1}{2h} \right\} \sum_{i=0}^N A_{j,i}^{-1} f(x)h \\
& + \left\{ \frac{6(x_j - x)^2}{h^3} - \frac{3(x_j - x)}{h^2} - \frac{1}{2h} \right\} \sum_{i=0}^N A_{j-1,i}^{-1} f(x)h \\
& + \left\{ \frac{3(x_j - x)^2}{h^3} - \frac{3(x_j - x)}{h^2} + \frac{1}{2h} \right\} \sum_{i=0}^N A_{j-1,i}^{-1} f(x)h. \\
& = \left\{ \frac{3(x - x_{j-1})^2}{h^3} - \frac{2(x - x_{j-1})}{h^2} + \frac{3(x - x_{j-1})^2}{h^3} - \frac{6(x - x_{j-1})}{h^2} + \frac{3}{h} + \frac{2(x - x_{j-1})}{h^2} - \frac{2}{h} - \frac{6(x - x_{j-1})^2}{h^3} \right. \\
& \quad \left. + \frac{6(x - x_{j-1})}{h^2} - \frac{1}{h} \right\} f(x)h = 0. \tag{4.38}
\end{aligned}$$

以上より、(4.36)式は

$$S'_{BKS}(x) = \frac{1}{h}(G_j - G_{j-1}) + \frac{3}{h^2} \sum_{i=0}^N a_{j,i} [G_{i+1} - 2G_i + G_{i-1}],$$

となり、これはL&Rによる推定量(文献(4)、p.229)と同等である。以上より、補助定理が示された。

4.5. 系 2. ヒストスプラインの漸近正規性の証明

上記の補助定理から、ヒストスプラインの漸近正規性の成立は、L&R(1974)の Theorem 4.において示される。これを踏まえて、平均と分散の明示的な表現を示す。

4.2 節の $AMISE(\hat{f}(x))$ の導出から、各ビンにおけるスプライン推定量について $Bias\{\hat{f}_j(x)\} = E[\hat{f}_j(x)] - f(x)$ であり、 $h \propto O(n^{-\alpha})$, $x \in B_j$ に対して、 $\alpha = \frac{1}{7}$ のとき、 $\sqrt{nh}\{\hat{f}_j(x) - f(x)\}$ の平均は $\sqrt{nh}Bias\{\hat{f}_j(x)\}$ となることが示されるため(4.15)式より、

$$\sqrt{nh} \frac{f'''(x)}{6} \left\{ \left(x_j^3 - \frac{3}{2} x_j^2 h + \frac{1}{2} x_j h^2 \right) + \left(-3x_j^2 + 3x_j h - \frac{1}{2} h^2 \right) x + \left(3x_j - \frac{3}{2} h \right) x^2 - x^3 \right\}, \quad (4.39)$$

ここで、 $r = \frac{1}{h}(x_j - x)$ とおくと、

$$\begin{aligned} \sqrt{nh} \frac{f'''(x)}{6} \left\{ \left(x_j^3 - \frac{3}{2} x_j^2 h + \frac{1}{2} x_j h^2 \right) + \left(-3x_j^2 + 3x_j h - \frac{1}{2} h^2 \right) x + \left(3x_j - \frac{3}{2} h \right) x^2 - x^3 \right\} \\ = \sqrt{nh} \frac{f'''(x)}{6} \left\{ (x_j - x)^3 - \frac{3}{2} h (x_j - x)^2 + \frac{1}{2} h^2 (x_j - x) \right\} \\ = \sqrt{nh} \frac{f'''(x)}{6} h^3 \left(r^3 - \frac{3}{2} r^2 + \frac{1}{2} r \right). \end{aligned} \quad (4.40)$$

また、 $\sqrt{nh}\{\hat{f}_j(x) - f(x)\}$ の分散については $AMISE(\hat{f}(x))$ の分散項(4.27)式より、

$$\frac{5\sqrt{3} + 3}{10} f(\xi_j), \quad (4.41)$$

である。

$\alpha > \frac{1}{7}$ のとき、 $Bias\{\hat{f}_j(x)\}$ よりもビン幅 h の収束スピードの方が速いことから、平均は 0 となる。以上より、ヒストスプラインの漸近正規性について平均と分散の明示的な表現が証明された。

5. 数値実験

ヒストグラムとヒストスプラインの有限標本における密度推定の精度を比較するため、積分二乗誤差(以下、ISE と呼ぶ)について数値実験を行う。ここでは、MISE の変動を ISE の標本平均と標準偏差で評価した。定義域 $[-3,3]$ の標準正規分布 $N(0,1)$ に従う標本について、標本サイズ $n = 100, 200, 500, 1000, 5000$ と設定する。ビン幅は Leave-one-out CV^2 により推定する。ヒストグラムとヒストスプラインそれぞれについて ISE の計算シミュレーションを 10000 回行い、ISE の標本平均と標準偏差を算出する。

図1 数値実験結果($n = 200$)

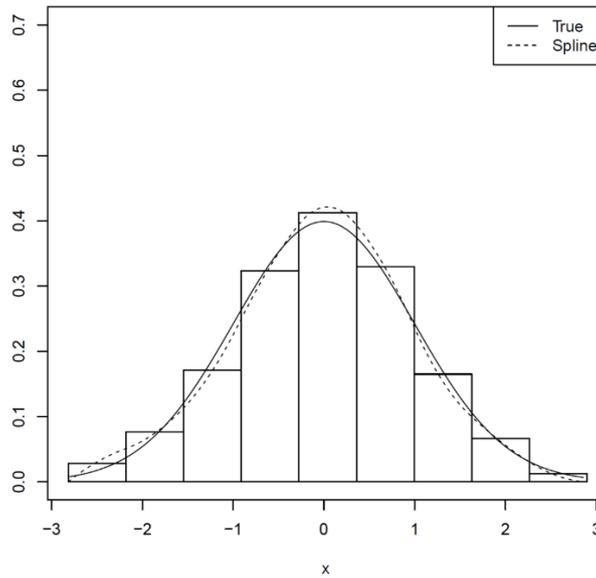


図1は、 $n = 200$ のヒストグラムとヒストスプラインの数値実験結果を示す。実線が真の密度関数、破線がヒストスプラインである。

表2は、ISEの標本平均についての数値実験結果を示す。推定精度が良いほどISEは0に近いので、比較して値が小さい方に下線を引いてある。ヒストグラムとヒストスプラインのどちらも、標本サイズが大きくなるにつれてISEは小さくなる。標本サイズに関わらず、ヒストスプラインの方がISEは小さい。しかしながら、標本サイズが大きくなるにつれて両者のISE差は小さくなる。

表2 ISE 標本平均の数値実験結果

	$n = 100$	$n = 200$	$n = 500$	$n = 1000$	$n = 5000$
ヒストグラム	0.02783	0.01785	0.00924	0.00561	0.00180
ヒストスプライン	<u>0.02387</u>	<u>0.01516</u>	<u>0.00782</u>	<u>0.00457</u>	<u>0.00143</u>

表3は、ISE標準偏差の数値実験結果を示す。表では、ヒストグラムとヒストスプラインで比較して値が小さい方に下線を引いてある。ヒストグラムとヒストスプラインのどちらも、標本サイズが大きくなるにつれてISE標準偏差は小さくなる。標本サイズに関わらず、ヒストグラムの方がISE標準偏差は小さい。しかしながら、標本サイズが大きくなるにつれて両者のISE標準偏差の差は小さくなる。

表3 ISE 標準偏差の数値実験結果

	$n = 100$	$n = 200$	$n = 500$	$n = 1000$	$n = 5000$
ヒストグラム	<u>0.01693</u>	<u>0.01051</u>	<u>0.00472</u>	<u>0.00241</u>	<u>0.00051</u>
ヒストスプライン	0.02388	0.01482	0.00684	0.00345	0.00081

6. 結論と考察

本研究では、ヒストグラムのスプライン平滑化に関する BKS+Schoenberg と L&R の 2 つの問題についての同等性を示し、また、ヒストスプライン推定量の漸近表現を陽な形で導出した。また、有限標本におけるヒストグラムとヒストスプラインの推定精度を比較する目的で、数値実験を行った。大標本特性として、一般的な正則条件の下で①BKS+Schoenberg と L&R の同等性、②ヒストスプラインの明示的な AMISE、⑤ヒストスプラインの MSE の上限、④補助定理及び明示的な漸近正規性を証明した。①BKS+Schoenberg と L&R の同等性について、 $S'_{BKS}(x)$ において L&R による推定量と係数を揃えたときに $S'_{BKS}(x) = S'_{LR}(x)$ であることを示した。②ヒストスプラインの AMISE について、分散項が

$\frac{5\sqrt{3}+3}{10} \frac{1}{nh}$ 、二乗バイアス項が $\frac{R(f''')}{30240} h^6$ であることを示した。この AMISE はヒストグラムの

$AMISE_{hist}(\hat{f}(x)) = \frac{1}{nh} + \frac{R(f')}{12} h^2$ と比較すると、分散は増加する一方、二乗バイアス項は減少してい

る。③ヒストスプラインの MSE の上限について、 $0 \leq |x_j - x| \leq h$ とすると、分散項が

$\left(\frac{16\sqrt{3}}{9} + \frac{9}{4}\right) \frac{1}{nh} f(x)$ 、二乗バイアス項が $\sqrt{nh} \frac{f'''(x)}{2} h^3$ であることを示した。④明示的な漸近正規性につい

て、各ビンにおけるヒストスプラインの正規性に関しては、 $h \propto O(n^{-\alpha})$, $x \in B_j$ に対して、 $r = \frac{1}{h}(x_j - x)$

とおくと、 $\alpha = \frac{1}{7}$ のときは $\sqrt{nh}\{\hat{f}_j(x) - f(x)\} \xrightarrow{d} N\left(\sqrt{nh} \frac{f'''(x)}{6} h^3 \left(r^3 - \frac{3}{2}r^2 + \frac{1}{2}r\right), \frac{5\sqrt{3}+3}{10} f(\xi_j)\right)$ 、 $\alpha > \frac{1}{7}$ の

ときは $\sqrt{nh}\{\hat{f}_j(x) - f(x)\} \xrightarrow{d} N\left(0, \frac{5\sqrt{3}+3}{10} f(\xi_j)\right)$ であることを示した。

有限標本時の特性について、ISE の標本平均と標準偏差についての計算シミュレーション結果から、ヒストグラムとヒストスプラインのどちらの場合も、ISE の標本平均と標準偏差は標本サイズが大きくなるにつれてその値が小さくなる。ヒストスプラインの方が、どの標本サイズの時にも ISE 値は小さく、ヒストグラムよりも推定精度が改良される。両者の ISE 差は標本サイズが大きくなるほど縮まっていく。また、ISE 標準偏差は、標本サイズに関わらずヒストグラムの方が値は小さいが、標本サイズが大きくなるほど両者の値は近づいていく。このことから、ヒストスプラインはヒストグラムよりも分散は増加するが、バイアスは減少する。バイアス減少の効果が推定精度に及ぼす影響の方が大きいので、全体の ISE はヒストグラムよりも改良されることが分かった。

ここまで、ヒストグラムを 3 次スプライン曲線で平滑化する問題について議論した。スプライン関数の次元を 4 次、5 次、...と上げた際の一般化表現とその漸近的性質については明らかにされていないため、その導出が今後の課題である。

[注]

1) ヒストグラムの各ビンにおける面積と、スプライン平滑化後の推定量での各ビンにおける面積が等しくなるとき、面積相等性をもつという。

2) Leave-one-out CV とは、ビン幅推定法の一つである。具体的には、標本から 1 つデータ点を抜き出し、

残りのデータ点でヒストグラムを構築し、抜き出したデータ点でそのヒストグラムを評価する。以上をデータ点ごとに繰り返し、それら評価について平均を算出する。この標本平均を最小化するようなビン幅を求め、それを推定ビン幅とする手法である。ヒストグラムの場合には、最終的な計算が陽に示され、標本サイズ n 、ビン B_k における度数を v_k 、ビン幅 h とすると、unbiased CV(UCV)は、

$$\text{UCV}(h) = \frac{2}{(n-1)h} - \frac{n+1}{n^2(n-1)h} \sum_k v_k^2.$$

[引用・参考文献]

- (1)D.W. Scott, "Frequency Polygons: Theory and Application", *Journal of the American Statistical Association*, 80.390, 1985, pp.348-354.
- (2)I. J. Schoenberg, "Splines and Histograms", *Spline Functions and Approximation Theory*, Birkhauser, Basel, 1973, pp.277-327.
- (3)I. J. Schoenberg, "Contribution to The problem of Approximation of Equidistant Data by Analytic Functions", *Quartely of Applied Mathematics*, 4(2), 1946, pp.112-141.
- (4)Keh-Shin Lii, and M. Rosenblatt, "Asymptotic Behavior of A Spline Estimate of A Density Function", *Computers & Mathematics with Applications*, 1(2), 1975, pp.223-235.
- (5)Liliana I. Boneva, David Kendall, and Ivan Stefanov, "Spline Transformations: Three New Diagnostic Aids for the Statistical Data-Analyst.", *Journal of the Royal Statistical Society. Series B (Methodological)*, 33.1, 1971, pp.1-71.
- (6)M.C.Jones, M.Samiuddin, A. H.Al-Harbey, and T. A. H.Maatouk, "The Edge Frequency Polygon", *Biometrika*, 85(1), 1998, pp.235-239.
- (7)M.C.Minnotte, "The Bias-Optimized Frequency Polygon", *Computational Statistics*, 11, 1996, pp.35-48.