

II-73

極値分布関数の棄却基準と年最大日雨量資料への適用について

横浜国立大学工学部 正員 合田良実
日本IBM株式会社 李 孝秀

1. まえがき

水文統計を始めとして極値資料の取り扱いでは、データにあてはめるべき分布関数の選択が常に問題となる。一般には、複数の分布関数の中からデータに最も適合すると判断される関数を選択する。しかし、そのための客観的な方法が確立されているとはいいがたい。ここでは逆に、対象とするデータの側からみてあてはめを棄却すべき分布関数の判断基準を検討してみた。あてはめは最小2乗法による場合を対象とし、分布関数として極値I型分布、ワイブル分布（形状母数4種）、および2母数対数正規分布について検討した。

2. 標本中の異常値の出現特性

極値資料では標本中に他とかけ離れて大きな値が含まれていることがある。既に角屋¹⁾は、標本が対数正規分布あるいは対数極値分布の母集団に帰属するものとして、これから外れる観測値を棄却するための基準を示している。しかし、異常値も他の値と同種類の気象原因で生じたものであるならば、観測値ではなくて不適合の分布関数のほうを棄却すべきであるとも考えられる。その場合は、母関数からランダムに抽出された標本における最大値の分布状況を調べておく必要がある。このため、 $N=10\sim100$ の大きさの標本を母集団から10,000組ずつ疑似一様乱数を使って抽出し、各標本中の最大値 x_1 を次のように無次元化した。

$$\xi = (x_1 - x_m) / s_x \quad (1)$$

ただし、 x_m はその標本の平均値、 s_x は標本の標準偏差である。式(1)の標本最大値の無次元偏差は分布関数の母数の絶対値に影響されない、すなわちパラメーターフリーであり、このことは確認済みである。

式(1)の ξ の値各10,000個を大きさの順に並べ替え、上から100番目および500番目の値を求めることによって ξ の1%および5%超過限界値が得られたので、これを式(2)のような直線回帰式で近似した。

$$\xi = a + b \ln N \quad (2)$$

表-1 異常値偏差の係数aおよびbの値

分布関数	5%限界値		1%限界値	
	a	b	a	b
ワイブル($k=0.75$)	-1.220	1.745	-2.168	2.146
ワイブル($k=1.00$)	-0.162	1.284	-0.859	1.622
ワイブル($k=1.40$)	0.673	0.873	0.355	1.092
ワイブル($k=2.00$)	1.170	0.586	1.165	0.699
極値I型分布	0.341	0.996	-0.119	1.273
対数正規分布	1.438	0.386	1.585	0.444

各分布関数に対する係数値を求めた結果は表-1のとおりである。なお、対数正規分布については極値データの生の値ではなく、その自然対数を取った値について平均、標準偏差などを計算して処理するものとする。式(2)による近似値とモンテカルロ法による数値実験値との差はおおむね $\pm 2\%$ 以内であるが、ワイブル分布の $k=0.75$ は ξ と $\ln N$ の関係がやや上向きにカーブ、 $k=2.0$ や対数正規分布ではやや下向きにカーブしているため、特に $N=10$ などで誤差が大きい傾向がある。

3. 最小2乗法における相関係数の残差値の分布特性

最小2乗法による分布関数の母数推定の際には、まずプロット・ポジション公式として分布関数毎に最も適切なものを使用しないと、再現確率統計量の推定値に偏りを生じる²⁾。データの順序統計量 x_i とその基準化変量 y_i に対して最小2乗法を適用したときの相関係数 r はデータに対する分布関数の適合度を最もよく表示する。そこで、前項と同様なモンテカルロ法によって相関係数の残差 $\Delta r = 1 - r$ の累積分布を求め、これからその5%超過限界値を算出してこれを式(3)のように表示した。

$$\Delta r = A N^B \quad (3)$$

係数AおよびBの値は分布関数毎に表-2のように算定されている。式(3)のあてはめ誤差は、ワイブル分布の $k=2.0$ が $-3\%\sim+4\%$ 、対数正規分布が $-2\%\sim+3\%$ とやや大きい、その他は $\pm 2\%$ 以下である。

また、相関係数の残差の平均値について式(3)のべき乗回帰式を適用して係数を求めた結果も表-2に示している。この場合のあてはめ誤差は5%限界値よりも幾分大きい。特に $k=2.0$ のワイブル分布では下方に凸の傾向が強く、 $\pm 8\%$ 程度の誤差を伴う。

表-2 相関係数の残差値の係数AおよびB

分布関数	5%限界値		平均値	
	A	B	A	B
ワイブル($k=0.75$)	0.339	-0.444	0.127	-0.428
ワイブル($k=1.00$)	0.371	-0.553	0.147	-0.541
ワイブル($k=1.40$)	0.421	-0.672	0.163	-0.639
ワイブル($k=2.00$)	0.451	-0.751	0.162	-0.676
極値I型分布	0.378	-0.614	0.164	-0.616
対数正規分布	0.538	-0.802	0.207	-0.745

4. 分布関数の棄却基準

上述の標本中の異常値および最小2乗法適用の際の相関係数の残差値の分布特性を利用すると、データにあてはめるべき分布関数の棄却検定を行なうことが可能である。ここで、標本中の最大値の偏差を用いるものをDOL(Deviation of OutLier)基準、相関係数の残差値を用いるものをREC(REsidue of Correlation coefficient)基準と呼ぶことにする。すなわち、想定した分布関数に対して標本の Δr 値が表-1の5%限界値を上回る、あるいは Δr が表-2の5%限界値を上回るときは、データがその分布関数で表される母集団に所属する確率が5%未満であると判断し、その分布関数を棄却する。実データに対する適用事例ではREC基準のほうが厳しく、DOL基準で棄却されるものは同時に前者でも棄却される場合が多い。

また、最適の判断基準として著者の一人は先に相関係数が最大のものを採択することを提案した²⁾が、表-2のように相関係数の平均値が分布関数によって異なることを考慮すると、 Δr の平均値に対する比率の最小のものを最適と判断するほうが妥当ではないかと思われる。この判断基準をここではMIR(Minimum Ratio of residual correlation coefficient)基準と呼んでおく。

5. 年最大日雨量資料に対する適用結果

気象庁観測年報に記載されているもののうち、観測期間ができるだけ長く取れるよう、明治年間からの観測値のある58地点(1987年までの観測年数76~111年)を対象とした。棄却検定の結果を表-3に示す。

表-3 年最大日雨量に対する各種分布関数あてはめの適合度

地点名	a b c d e f	地点名	a b c d e f	地点名	a b c d e f	地点名	a b c d e f	地点名	a b c d e f
網走	▲○○▲○○	小名浜	▲◎○▲○○	甲府	▲○○▲○○	京都	◎○▲▲▲▲	浜田	◎○▲▲▲▲
根室	▲▲○○○○	宇都宮	▲○○○○◎	飯田	○○■●●●	大阪	◎○▼●▼▼	下関	◎○■●▼▼
釧路	▲○○■○○	水戸	○○○■○○	浜松	○○○■○▲	神戸	◎○●▲▲▲	腋原	▲○○○○◎
札幌	◎○○■○○	銚子	○○○■○○	名古屋	▲○○○○◎	和歌山	○○○■○○	福岡	▲○○○○◎
寿都	◎○▲▲▲▲	八丈島	○○○○○○	津	▲○○○○◎	潮岬	○○○▲○○	佐賀	◎○■●▲▲
函館	○○▼■○○	横浜	▲○○○○◎	岐阜	▲◎○▲○○	高知	◎○■●▼■	長崎	◎○○▲○○
青森	○○○■○▲	東京	○○■●●▼	高山	○○○■▲▲	徳島	◎○▲▲▲○	熊本	◎○▲▲▲▲
秋田	▲○○○○◎	熊谷	○○○▲○○	伏木	○○○▲○▲	多度津	○○○▲○○	大分	◎○○■○○
宮古	▲○○▲○○	前橋	◎▼■●●■	福井	○○○▲○○	松山	▲○○■○○	宮崎	◎○■●▲▲
石巻	▲▲○○○○	新潟	○○○▲○○	金沢	○○○■○▲	広島	◎○■●●■	鹿児島	▲▲○○○○
山形	◎○▲▲▲▲	長野	▲○○○○○	敦賀	▲▲○○○○	岡山	▲○○▼○○		
福島	▲○○▲○○	松本	○○○▲○▲	彦根	■●●●●■	境	◎○○■○○		

注1) 分布関数: a=ワイブル($k=0.75$), b=ワイブル($k=1.0$), c=ワイブル($k=1.4$),
d=ワイブル($k=2.0$), e=極値I型分布, f=対数正規分布。

注2) 適合度判定: ◎=MIR基準最適, ○=棄却基準に該当せず,
▲=REC棄却基準に該当, ▼=DOL棄却基準に該当, ■=両棄却基準に該当。

この結果では、指数分布(ワイブルの $k=1.0$)の棄却率が約9%と最小であってかつ最適の割合も高いのに対し、極値I型分布や対数正規分布は棄却率が約30%もあり、一般性を保ち得ないといえる。

参考文献 1) 角屋 睦: 農業土木研究, 別冊第3号, 1962, pp.23-27.

2) 合田良実: 港湾技術研究所報告, 第27巻第1号, 1988, pp.31-92.