

英国民のインフレ認識・期待の 分布の計測

非弁別閾をもつ区間データに対する
正規混合モデルのベイズ分析

村澤 康友

甲南大学

日本経済学会 2017 年度春季大会

報告の流れ

- 1 研究の動機と貢献
- 2 データ
- 3 モデル
- 4 ベイズ分析
- 5 計測結果 I (6 区間または 8 区間)
- 6 計測結果 II (18 区間)
- 7 計測結果の応用
- 8 まとめ

報告の流れ

- 1 研究の動機と貢献
- 2 データ
- 3 モデル
- 4 ベイズ分析
- 5 計測結果 I (6 区間または 8 区間)
- 6 計測結果 II (18 区間)
- 7 計測結果の応用
- 8 まとめ

期待の異質性・不一致

人々の期待は異なる

- 情報の偏在（粘着的情報）
- 情報処理能力の差（限定合理性・合理的不注意・適応学習）

Mankiw, Reis, and Wolfers (2004) 以降「期待インフレ率の分布の変化」に関心

- 多くの先行研究は数値データを使用（例：ミシガン調査）
- 実際はカテゴリー・データを収集する調査が多い

期待の異質性・不一致

人々の期待は異なる

- 情報の偏在（粘着的情報）
- 情報処理能力の差（限定合理性・合理的不注意・適応学習）

Mankiw et al. (2004) 以降「期待インフレ率の分布の変化」に関心

- 多くの先行研究は数値データを使用（例：ミシガン調査）
- 実際はカテゴリー・データを収集する調査が多い

期待の異質性・不一致

人々の期待は異なる

- 情報の偏在（粘着的情報）
- 情報処理能力の差（限定合理性・合理的不注意・適応学習）

Mankiw et al. (2004) 以降「期待インフレ率の分布の変化」に関心

- 多くの先行研究は数値データを使用（例：ミシガン調査）
- 実際はカテゴリー・データを収集する調査が多い

期待の異質性・不一致

人々の期待は異なる

- 情報の偏在（粘着的情報）
- 情報処理能力の差（限定合理性・合理的不注意・適応学習）

Mankiw et al. (2004) 以降「期待インフレ率の分布の変化」に関心

- 多くの先行研究は数値データを使用（例：ミシガン調査）
- 実際はカテゴリー・データを収集する調査が多い

期待の異質性・不一致

人々の期待は異なる

- 情報の偏在（粘着的情報）
- 情報処理能力の差（限定合理性・合理的不注意・適応学習）

Mankiw et al. (2004) 以降「期待インフレ率の分布の変化」に関心

- 多くの先行研究は数値データを使用（例：ミシガン調査）
- 実際はカテゴリー・データを収集する調査が多い

期待の異質性・不一致

人々の期待は異なる

- 情報の偏在（粘着的情報）
- 情報処理能力の差（限定合理性・合理的不注意・適応学習）

Mankiw et al. (2004) 以降「期待インフレ率の分布の変化」に関心

- 多くの先行研究は数値データを使用（例：ミシガン調査）
- 実際はカテゴリー・データを収集する調査が多い

質的変数の数量化

期待インフレ率 y_i^* の調査

$$y_i := \begin{cases} 1 & \text{if } y_i^* < 0 \\ 2 & \text{if } y_i^* \approx 0 \text{ (非弁別閾)} \\ 3 & \text{if } y_i^* > 0 \end{cases}$$

質的変数の数量化

y_i^* の平均／中央値を $\{y_i\}$ から推定したい

非常に強い仮定が必要（例：カールソン＝パーキン法）
⇒ 区間データなら不要，かつ y_i^* の分布を推定できる

質的変数の数量化

期待インフレ率 y_i^* の調査

$$y_i := \begin{cases} 1 & \text{if } y_i^* < 0 \\ 2 & \text{if } y_i^* \approx 0 \text{ (非弁別閾)} \\ 3 & \text{if } y_i^* > 0 \end{cases}$$

質的変数の数量化

y_i^* の平均／中央値を $\{y_i\}$ から推定したい

非常に強い仮定が必要（例：カールソン＝パーキン法）
⇒ 区間データなら不要，かつ y_i^* の分布を推定できる

質的変数の数量化

期待インフレ率 y_i^* の調査

$$y_i := \begin{cases} 1 & \text{if } y_i^* < 0 \\ 2 & \text{if } y_i^* \approx 0 \text{ (非弁別閾)} \\ 3 & \text{if } y_i^* > 0 \end{cases}$$

質的変数の数量化

y_i^* の平均／中央値を $\{y_i\}$ から推定したい

非常に強い仮定が必要（例：カールソン＝パーキン法）
⇒ 区間データなら不要，かつ y_i^* の分布を推定できる

質的変数の数量化

期待インフレ率 y_i^* の調査

$$y_i := \begin{cases} 1 & \text{if } y_i^* < 0 \\ 2 & \text{if } y_i^* \approx 0 \text{ (非弁別閾)} \\ 3 & \text{if } y_i^* > 0 \end{cases}$$

質的変数の数量化

y_i^* の平均／中央値を $\{y_i\}$ から推定したい

非常に強い仮定が必要 (例: カールソン=パーキン法)

⇒ 区間データなら不要, かつ y_i^* の分布を推定できる

質的変数の数量化

期待インフレ率 y_i^* の調査

$$y_i := \begin{cases} 1 & \text{if } y_i^* < 0 \\ 2 & \text{if } y_i^* \approx 0 \text{ (非弁別閾)} \\ 3 & \text{if } y_i^* > 0 \end{cases}$$

質的変数の数量化

y_i^* の平均／中央値を $\{y_i\}$ から推定したい

非常に強い仮定が必要（例：カールソン＝パーキン法）
⇒ 区間データなら不要，かつ y_i^* の分布を推定できる

区間データの使用

Murasawa (2013, OBES)

- 1 日本の家計のインフレ期待の分布を推定
- 2 正規分布・歪んだ正規分布・歪んだ指数べき（一般化誤差）分布・歪んだt分布（全て単峰）
- 3 最尤法

本論文

- 1 英国国民のインフレ認識・期待の分布を推定
- 2 正規混合分布（多峰）
- 3 ベイズ法

区間データの使用

Murasawa (2013, OBES)

- 1 日本の家計のインフレ期待の分布を推定
- 2 正規分布・歪んだ正規分布・歪んだ指数べき（一般化誤差）分布・歪んだt分布（全て単峰）
- 3 最尤法

本論文

- 1 英国国民のインフレ認識・期待の分布を推定
- 2 正規混合分布（多峰）
- 3 ベイズ法

区間データの使用

Murasawa (2013, OBES)

- 1 日本の家計のインフレ期待の分布を推定
- 2 正規分布・歪んだ正規分布・歪んだ指数べき（一般化誤差）分布・歪んだ t 分布（全て単峰）
- 3 最尤法

本論文

- 1 英国国民のインフレ認識・期待の分布を推定
- 2 正規混合分布（多峰）
- 3 ベイズ法

区間データの使用

Murasawa (2013, OBES)

- 1 日本の家計のインフレ期待の分布を推定
- 2 正規分布・歪んだ正規分布・歪んだ指数べき（一般化誤差）分布・歪んだ t 分布（全て単峰）
- 3 最尤法

本論文

- 1 英国国民のインフレ認識・期待の分布を推定
- 2 正規混合分布（多峰）
- 3 ベイズ法

区間データの使用

Murasawa (2013, OBES)

- 1 日本の家計のインフレ期待の分布を推定
- 2 正規分布・歪んだ正規分布・歪んだ指数べき（一般化誤差）分布・歪んだ t 分布（全て単峰）
- 3 最尤法

本論文

- 1 英国民のインフレ認識・期待の分布を推定
- 2 正規混合分布（多峰）
- 3 ベイズ法

区間データの使用

Murasawa (2013, OBES)

- 1 日本の家計のインフレ期待の分布を推定
- 2 正規分布・歪んだ正規分布・歪んだ指数べき（一般化誤差）分布・歪んだ t 分布（全て単峰）
- 3 最尤法

本論文

- 1 英国国民のインフレ認識・期待の分布を推定
- 2 正規混合分布（多峰）
- 3 ベイズ法

区間データの使用

Murasawa (2013, OBES)

- 1 日本の家計のインフレ期待の分布を推定
- 2 正規分布・歪んだ正規分布・歪んだ指数べき（一般化誤差）分布・歪んだ t 分布（全て単峰）
- 3 最尤法

本論文

- 1 英国国民のインフレ認識・期待の分布を推定
- 2 正規混合分布（多峰）
- 3 ベイズ法

区間データの使用

Murasawa (2013, OBES)

- 1 日本の家計のインフレ期待の分布を推定
- 2 正規分布・歪んだ正規分布・歪んだ指数べき（一般化誤差）分布・歪んだ t 分布（全て単峰）
- 3 最尤法

本論文

- 1 英国国民のインフレ認識・期待の分布を推定
- 2 正規混合分布（多峰）
- 3 ベイズ法

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国民のインフレ認識・期待の分布の計測 (2001Q1–2015Q4)
- 3 計測結果の応用：英国民のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国民のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
- 3 計測結果の応用：英国民のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国民のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
- 3 計測結果の応用：英国民のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国民のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
- 3 計測結果の応用：英国民のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国民のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
- 3 計測結果の応用：英国民のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国民のインフレ認識・期待の分布の計測
(2001Q1-2015Q4)
- 3 計測結果の応用：英国民のインフレ期待における情報の硬直性の検証

報告の流れ

- 1 研究の動機と貢献
- 2 データ
- 3 モデル
- 4 ベイズ分析
- 5 計測結果 I (6 区間または 8 区間)
- 6 計測結果 II (18 区間)
- 7 計測結果の応用
- 8 まとめ

イングランド銀行の調査データ

BoE/GfK NOP Inflation Attitudes Survey の集計データ

- 2001年2月調査-2015年11月調査（60四半期）
- イギリス在住の16歳以上の成人を対象とした割当抽出
- 2月調査は4,000人，その他は2,000人の割当

イングランド銀行の調査データ

BoE/GfK NOP Inflation Attitudes Survey の集計データ

- 2001年2月調査-2015年11月調査（60四半期）
- イギリス在住の16歳以上の成人を対象とした割当抽出
- 2月調査は4,000人，その他は2,000人の割当

イングランド銀行の調査データ

BoE/GfK NOP Inflation Attitudes Survey の集計データ

- 2001年2月調査-2015年11月調査（60四半期）
- イギリス在住の16歳以上の成人を対象とした割当抽出
- 2月調査は4,000人，その他は2,000人の割当

イングランド銀行の調査データ

BoE/GfK NOP Inflation Attitudes Survey の集計データ

- 2001年2月調査-2015年11月調査（60四半期）
- イギリス在住の16歳以上の成人を対象とした割当抽出
- 2月調査は4,000人，その他は2,000人の割当

選択肢

8 区間 ('No idea' を除く)

- 1 Gone/Go down
- 2 Not changed/change (非弁別閾)
- 3 Up by 1% or less
- 4 Up by 1% but less than 2%
- 5 Up by 2% but less than 3%
- 6 Up by 3% but less than 4%
- 7 Up by 4% but less than 5%
- 8 Up by 5% or more

選択肢

8 区間 ('No idea' を除く)

- 1 Gone/Go down
- 2 Not changed/change (非弁別閾)
- 3 Up by 1% or less
- 4 Up by 1% but less than 2%
- 5 Up by 2% but less than 3%
- 6 Up by 3% but less than 4%
- 7 Up by 4% but less than 5%
- 8 Up by 5% or more

選択肢

8 区間 ('No idea' を除く)

- 1 Gone/Go down
- 2 Not changed/change (非弁別閾)
- 3 Up by 1% or less
- 4 Up by 1% but less than 2%
- 5 Up by 2% but less than 3%
- 6 Up by 3% but less than 4%
- 7 Up by 4% but less than 5%
- 8 Up by 5% or more

選択肢

8 区間 ('No idea' を除く)


- 1 Gone/Go down
- 2 Not changed/change (非弁別閾)
- 3 Up by 1% or less
- 4 Up by 1% but less than 2%
- 5 Up by 2% but less than 3%
- 6 Up by 3% but less than 4%
- 7 Up by 4% but less than 5%
- 8 Up by 5% or more

選択肢

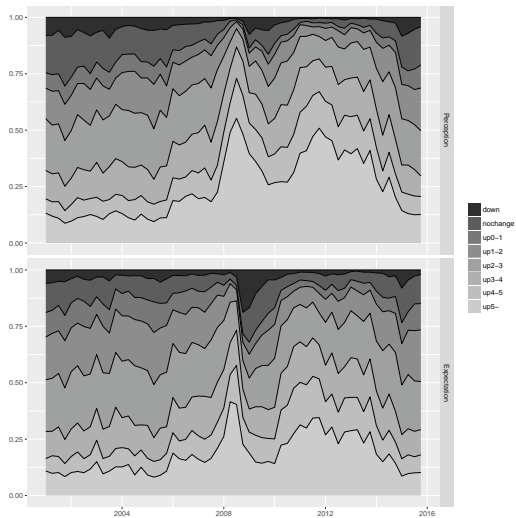
8 区間 ('No idea' を除く)

- 1 Gone/Go down
- 2 Not changed/change (非弁別閾)
- 3 Up by 1% or less
- 4 Up by 1% but less than 2%
- 5 Up by 2% but less than 3%
- 6 Up by 3% but less than 4%
- 7 Up by 4% but less than 5%
- 8 Up by 5% or more

インフレ認識 (2001年2月と2008年8月)



相対度数の推移



報告の流れ

- 1 研究の動機と貢献
- 2 データ
- 3 モデル**
- 4 ベイズ分析
- 5 計測結果 I (6 区間または 8 区間)
- 6 計測結果 II (18 区間)
- 7 計測結果の応用
- 8 まとめ

区間（順序）応答モデル

非弁別閾をもつ区間（順序）応答モデル

$$y_i := \begin{cases} 1 & \text{if } \gamma_0 < y_i^* \leq \gamma_1 \\ \vdots & \\ J & \text{if } \gamma_{J-1} < y_i^* \leq \gamma_J \end{cases}$$

ただし

- y_i^* は潜在変数
- $-\infty = \gamma_0 < \dots < \gamma_l < 0 < \gamma_u < \dots < \gamma_J = \infty$
- 非弁別閾 $[\gamma_l, \gamma_u]$ 以外の $\{\gamma_j\}$ は既知

区間（順序）応答モデル

非弁別閾をもつ区間（順序）応答モデル

$$y_i := \begin{cases} 1 & \text{if } \gamma_0 < y_i^* \leq \gamma_1 \\ \vdots & \\ J & \text{if } \gamma_{J-1} < y_i^* \leq \gamma_J \end{cases}$$

ただし

- y_i^* は潜在変数
- $-\infty = \gamma_0 < \cdots < \gamma_l < 0 < \gamma_u < \cdots < \gamma_J = \infty$
- 非弁別閾 $[\gamma_l, \gamma_u]$ 以外の $\{\gamma_j\}$ は既知

正規混合モデル

潜在変数の正規混合モデル

$$y_i^* \sim \sum_{k=1}^K \pi_k \mathcal{N}(\mu_k, \sigma_k^2)$$

母数

- $\pi := (\pi_1, \dots, \pi_K)'$
- $\mu := (\mu_1, \dots, \mu_K)'$
- $\sigma := (\sigma_1, \dots, \sigma_K)'$
- $\gamma := (\gamma_l, \gamma_u)'$

正規混合モデル

潜在変数の正規混合モデル

$$y_i^* \sim \sum_{k=1}^K \pi_k \mathcal{N}(\mu_k, \sigma_k^2)$$

母数

- $\boldsymbol{\pi} := (\pi_1, \dots, \pi_K)'$
- $\boldsymbol{\mu} := (\mu_1, \dots, \mu_K)'$
- $\boldsymbol{\sigma} := (\sigma_1, \dots, \sigma_K)'$
- $\boldsymbol{\gamma} := (\gamma_l, \gamma_u)'$

報告の流れ

- 1 研究の動機と貢献
- 2 データ
- 3 モデル
- 4 ベイズ分析**
- 5 計測結果 I (6 区間または 8 区間)
- 6 計測結果 II (18 区間)
- 7 計測結果の応用
- 8 まとめ

なぜベイズ法？

正規混合分布の最尤推定は困難

- 1 数値データだと尤度関数が有界でない (Kiefer and Wolfowitz (1956))
- 2 区間データなら尤度関数は有界だが、最尤法の収束に問題 (Biernacki (2007))

ベイズ法の方が安全

なぜベイズ法？

正規混合分布の最尤推定は困難

- 1 数値データだと尤度関数が有界でない (Kiefer and Wolfowitz (1956))
- 2 区間データなら尤度関数は有界だが、最尤法の収束に問題 (Biernacki (2007))

ベイズ法の方が安全

なぜベイズ法？

正規混合分布の最尤推定は困難

- 1 数値データだと尤度関数が有界でない (Kiefer and Wolfowitz (1956))
- 2 区間データなら尤度関数は有界だが、最尤法の収束に問題 (Biernacki (2007))

ベイズ法の方が安全

なぜベイズ法？

正規混合分布の最尤推定は困難

- 1 数値データだと尤度関数が有界でない (Kiefer and Wolfowitz (1956))
- 2 区間データなら尤度関数は有界だが、最尤法の収束に問題 (Biernacki (2007))

ベイズ法の方が安全

事前分布

基本的に **weakly informative prior**

$$\pi \sim \text{Dirichlet}(\mathbf{z}_K)$$

$$\mu_k \sim N(2.5, 100), \quad k = 1, \dots, K$$

$$\sigma_k^2 \sim \text{Inv-Gam}(2, \beta_0), \quad k = 1, \dots, K$$

β_0 のみ **階層的な事前分布** (Richardson and Green (1997))

$$\beta_0 \sim \text{Gam}(.2, .1)$$

非弁別閾に関する事前分布

$$\gamma_l \sim U(-\infty, 0)$$

$$\gamma_u \sim U(0, 1)$$

事前分布

基本的に **weakly informative prior**

$$\boldsymbol{\pi} \sim \text{Dirichlet}(\boldsymbol{z}_K)$$

$$\mu_k \sim \text{N}(2.5, 100), \quad k = 1, \dots, K$$

$$\sigma_k^2 \sim \text{Inv-Gam}(2, \beta_0), \quad k = 1, \dots, K$$

β_0 のみ **階層的な事前分布** (Richardson and Green (1997))

$$\beta_0 \sim \text{Gam}(.2, .1)$$

非弁別閾に関する事前分布

$$\gamma_l \sim \text{U}(-\infty, 0)$$

$$\gamma_u \sim \text{U}(0, 1)$$

事前分布

基本的に **weakly informative prior**

$$\boldsymbol{\pi} \sim \text{Dirichlet}(\boldsymbol{z}_K)$$

$$\mu_k \sim \text{N}(2.5, 100), \quad k = 1, \dots, K$$

$$\sigma_k^2 \sim \text{Inv-Gam}(2, \beta_0), \quad k = 1, \dots, K$$

β_0 のみ **階層的な事前分布** (Richardson and Green (1997))

$$\beta_0 \sim \text{Gam}(.2, .1)$$

非弁別関に関する事前分布

$$\gamma_l \sim \text{U}(-\infty, 0)$$

$$\gamma_u \sim \text{U}(0, 1)$$

事前分布

基本的に **weakly informative prior**

$$\boldsymbol{\pi} \sim \text{Dirichlet}(\boldsymbol{z}_K)$$

$$\mu_k \sim \text{N}(2.5, 100), \quad k = 1, \dots, K$$

$$\sigma_k^2 \sim \text{Inv-Gam}(2, \beta_0), \quad k = 1, \dots, K$$

β_0 のみ **階層的な事前分布** (Richardson and Green (1997))

$$\beta_0 \sim \text{Gam}(.2, .1)$$

非弁別閾に関する事前分布

$$\gamma_l \sim \text{U}(-\infty, 0)$$

$$\gamma_u \sim \text{U}(0, 1)$$

MCMC

1) 大標本による非弁別閾の推定の問題

ギブス抽出 極めて遅い

MH 法 工夫すれば速くなるが、低い採択率 (20–50 %)

NUTS 格段に速く、高い採択率 (80–99 %). Stan で簡単に実装可能

2) Label switching problem

- component のラベルが MCMC の最中に入れ替わる
⇒ 混合分布の母数は収束しない
- ラベルに依存しない母数 (積率・分位点) に注目

MCMC

1) 大標本による非弁別閾の推定の問題

ギブス抽出 極めて遅い

MH 法 工夫すれば速くなるが，低い採択率（20–50 %）

NUTS 格段に速く，高い採択率（80–99 %）. Stan で簡単に実装可能

2) Label switching problem

- component のラベルが MCMC の最中に入れ替わる
⇒ 混合分布の母数は収束しない
- ラベルに依存しない母数（積率・分位点）に注目

MCMC

1) 大標本による非弁別閾の推定の問題

ギブス抽出 極めて遅い

MH 法 工夫すれば速くなるが、低い採択率 (20–50 %)

NUTS 格段に速く、高い採択率 (80–99 %). Stan で簡単に実装可能

2) Label switching problem

- component のラベルが MCMC の最中に入れ替わる
⇒ 混合分布の母数は収束しない
- ラベルに依存しない母数 (積率・分位点) に注目

MCMC

1) 大標本による非弁別閾の推定の問題

ギブス抽出 極めて遅い

MH 法 工夫すれば速くなるが，低い採択率（20–50 %）

NUTS 格段に速く，高い採択率（80–99 %）. Stan で簡単に実装可能

2) Label switching problem

- component のラベルが MCMC の最中に入れ替わる
⇒ 混合分布の母数は収束しない
- ラベルに依存しない母数（積率・分位点）に注目

MCMC

1) 大標本による非弁別閾の推定の問題

ギブス抽出 極めて遅い

MH 法 工夫すれば速くなるが、低い採択率 (20–50 %)

NUTS 格段に速く、高い採択率 (80–99 %). Stan で簡単に実装可能

2) Label switching problem

- component のラベルが MCMC の最中に入れ替わる
⇒ 混合分布の母数は収束しない
- ラベルに依存しない母数 (積率・分位点) に注目

MCMC

1) 大標本による非弁別閾の推定の問題

ギブス抽出 極めて遅い

MH 法 工夫すれば速くなるが、低い採択率 (20–50 %)

NUTS 格段に速く、高い採択率 (80–99 %). Stan で簡単に実装可能

2) Label switching problem

- component のラベルが MCMC の最中に入れ替わる
⇒ 混合分布の母数は収束しない
- ラベルに依存しない母数 (積率・分位点) に注目

MCMC

1) 大標本による非弁別閾の推定の問題

ギブス抽出 極めて遅い

MH 法 工夫すれば速くなるが、低い採択率 (20–50 %)

NUTS 格段に速く、高い採択率 (80–99 %). Stan で簡単に実装可能

2) Label switching problem

- component のラベルが MCMC の最中に入れ替わる
⇒ 混合分布の母数は収束しない
- ラベルに依存しない母数 (積率・分位点) に注目

計算上の留意点

- Stan 2.14.1 を R 3.3.2 上で実行
- 4 つの並列なマルコフ連鎖を生成
- それぞれ最初の 1,000 個の抽出を warm-up とし, 次の 1,000 個 \times 4 = 4,000 個の抽出で事後分布をシミュレート
- 収束の診断
 - potential scale reduction factor \hat{R}
 - effective sample size (ESS)
- MCMC を 60 期間 \times 2 = 120 回繰り返す

計算上の留意点

- Stan 2.14.1 を R 3.3.2 上で実行
- 4 つの並列なマルコフ連鎖を生成
- それぞれ最初の 1,000 個の抽出を warm-up とし, 次の 1,000 個 \times 4 = 4,000 個の抽出で事後分布をシミュレート
- 収束の診断
 - potential scale reduction factor \hat{R}
 - effective sample size (ESS)
- MCMC を 60 期間 \times 2 = 120 回繰り返す

計算上の留意点

- Stan 2.14.1 を R 3.3.2 上で実行
- 4 つの並列なマルコフ連鎖を生成
- それぞれ最初の 1,000 個の抽出を warm-up とし, 次の 1,000 個 \times 4 = 4,000 個の抽出で事後分布をシミュレート
- 収束の診断
 - potential scale reduction factor \hat{R}
 - effective sample size (ESS)
- MCMC を 60 期間 \times 2 = 120 回繰り返す

計算上の留意点

- Stan 2.14.1 を R 3.3.2 上で実行
- 4 つの並列なマルコフ連鎖を生成
- それぞれ最初の 1,000 個の抽出を warm-up とし, 次の 1,000 個 \times 4 = 4,000 個の抽出で事後分布をシミュレート
- 収束の診断
 - potential scale reduction factor \hat{R}
 - effective sample size (ESS)
- MCMC を 60 期間 \times 2 = 120 回繰り返す

計算上の留意点

- Stan 2.14.1 を R 3.3.2 上で実行
- 4 つの並列なマルコフ連鎖を生成
- それぞれ最初の 1,000 個の抽出を warm-up とし, 次の 1,000 個 \times 4 = 4,000 個の抽出で事後分布をシミュレート
- 収束の診断
 - potential scale reduction factor \hat{R}
 - effective sample size (ESS)
- MCMC を 60 期間 \times 2 = 120 回繰り返す

計算上の留意点

- Stan 2.14.1 を R 3.3.2 上で実行
- 4 つの並列なマルコフ連鎖を生成
- それぞれ最初の 1,000 個の抽出を warm-up とし, 次の 1,000 個 \times 4 = 4,000 個の抽出で事後分布をシミュレート
- 収束の診断
 - potential scale reduction factor \hat{R}
 - effective sample size (ESS)
- MCMC を 60 期間 \times 2 = 120 回繰り返す

報告の流れ

- 1 研究の動機と貢献
- 2 データ
- 3 モデル
- 4 ベイズ分析
- 5 計測結果 I (6 区間または 8 区間)**
- 6 計測結果 II (18 区間)
- 7 計測結果の応用
- 8 まとめ

6 区間または 8 区間のデータによる計測

- 6 区間（非弁別閾なし）と 8 区間（非弁別閾あり）で比較
- インフレ認識・期待の分布
- 計測期間：2001Q1-2015Q4
- $K = 2$
- 1~5 次の（中心・標準化）積率に注目
 - 1 平均
 - 2 標準偏差
 - 3 歪度
 - 4 過剰尖度
 - 5 裾の非対称性

6 区間または 8 区間のデータによる計測

- 6 区間（非弁別閾なし）と 8 区間（非弁別閾あり）で比較
- インフレ認識・期待の分布
- 計測期間：2001Q1-2015Q4
- $K = 2$
- 1~5 次の（中心・標準化）積率に注目
 - 1 平均
 - 2 標準偏差
 - 3 歪度
 - 4 過剰尖度
 - 5 裾の非対称性

6 区間または 8 区間のデータによる計測

- 6 区間（非弁別閾なし）と 8 区間（非弁別閾あり）で比較
- インフレ認識・期待の分布
- 計測期間：2001Q1-2015Q4
- $K = 2$
- 1~5 次の（中心・標準化）積率に注目
 - 1 平均
 - 2 標準偏差
 - 3 歪度
 - 4 過剰尖度
 - 5 裾の非対称性

6 区間または 8 区間のデータによる計測

- 6 区間（非弁別閾なし）と 8 区間（非弁別閾あり）で比較
- インフレ認識・期待の分布
- 計測期間：2001Q1-2015Q4
- $K = 2$
- 1~5 次の（中心・標準化）積率に注目
 - 1 平均
 - 2 標準偏差
 - 3 歪度
 - 4 過剰尖度
 - 5 裾の非対称性

6 区間または 8 区間のデータによる計測

- 6 区間（非弁別閾なし）と 8 区間（非弁別閾あり）で比較
- インフレ認識・期待の分布
- 計測期間：2001Q1–2015Q4
- $K = 2$
- 1～5 次の（中心・標準化）積率に注目
 - 1 平均
 - 2 標準偏差
 - 3 歪度
 - 4 過剰尖度
 - 5 裾の非対称性

6 区間または 8 区間のデータによる計測

- 6 区間（非弁別閾なし）と 8 区間（非弁別閾あり）で比較
- インフレ認識・期待の分布
- 計測期間：2001Q1–2015Q4
- $K = 2$
- 1～5 次の（中心・標準化）積率に注目
 - 1 平均
 - 2 標準偏差
 - 3 歪度
 - 4 過剰尖度
 - 5 裾の非対称性

6 区間または 8 区間のデータによる計測

- 6 区間（非弁別閾なし）と 8 区間（非弁別閾あり）で比較
- インフレ認識・期待の分布
- 計測期間：2001Q1-2015Q4
- $K = 2$
- 1~5 次の（中心・標準化）積率に注目
 - 1 平均
 - 2 標準偏差
 - 3 歪度
 - 4 過剰尖度
 - 5 裾の非対称性

観察

- 1 分布の平均値の推定精度は高い（狭い誤差バンド）
- 2 高次の積率の推定精度は低い
- 3 非弁別閾に関する事前情報（ $\gamma_l < 0 < \gamma_u$ ）の導入により、高次の積率の事後分布は変化
- 4 非弁別閾の下限は -1% を大きく下回ることが多い

観察

- 1 分布の**平均値の推定精度は高い**（狭い誤差バンド）
- 2 高次の積率の推定精度は低い
- 3 非弁別閾に関する事前情報（ $\gamma_l < 0 < \gamma_u$ ）の導入により、高次の積率の事後分布は変化
- 4 非弁別閾の下限は -1% を大きく下回ることが多い

観察

- 1 分布の**平均値の推定精度は高い**（狭い誤差バンド）
- 2 高次の積率の推定精度は低い
- 3 非弁別閾に関する事前情報（ $\gamma_l < 0 < \gamma_u$ ）の導入により、高次の積率の事後分布は変化
- 4 非弁別閾の下限は -1% を大きく下回ることが多い


観察

- 1 分布の平均値の推定精度は高い（狭い誤差バンド）
- 2 高次の積率の推定精度は低い
- 3 非弁別閾に関する事前情報（ $\gamma_l < 0 < \gamma_u$ ）の導入により、高次の積率の事後分布は変化
- 4 非弁別閾の下限は -1% を大きく下回ることが多い

観察


- 1 分布の平均値の推定精度は高い（狭い誤差バンド）
- 2 高次の積率の推定精度は低い
- 3 非弁別閾に関する事前情報（ $\gamma_l < 0 < \gamma_u$ ）の導入により、高次の積率の事後分布は変化
- 4 非弁別閾の下限は -1% を大きく下回ることが多い

平均（6 区間，非弁別閾なし）




事後中央値と 68 % 誤差バンド

平均（8 区間，非弁別閾あり）




事後中央値と 68 % 誤差バンド

標準偏差（6 区間，非弁別閾なし）




事後中央値と 68 % 誤差バンド

標準偏差（8 区間，非弁別閾あり）




事後中央値と 68 % 誤差バンド

歪度 (6 区間, 非弁別閾なし)




事後中央値と 68 % 誤差バンド

歪度 (8 区間, 非弁別閾あり)




事後中央値と 68 % 誤差バンド

過剰尖度（6 区間，非弁別閾なし）



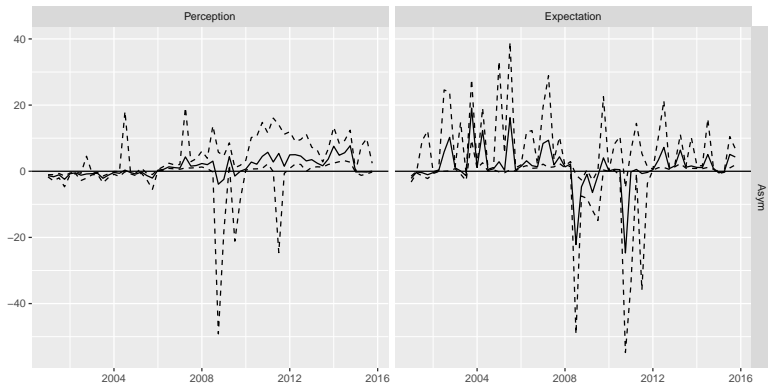
事後中央値と 68 % 誤差バンド

過剰尖度（8 区間，非弁別閾あり）




事後中央値と 68 % 誤差バンド

裾の非対称性（6 区間，非弁別閾なし）



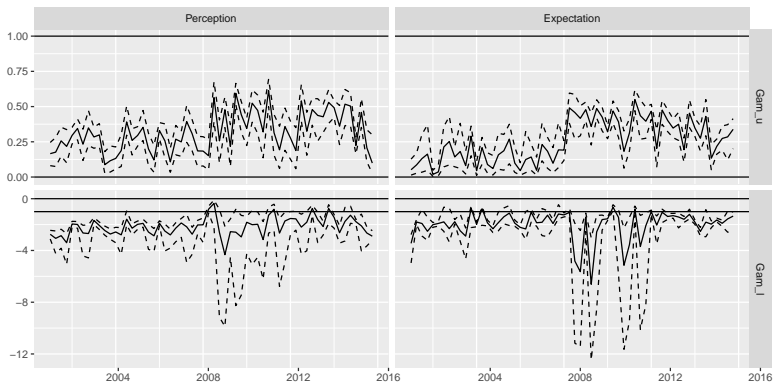
事後中央値と 68 % 誤差バンド

裾の非対称性（8 区間，非弁別閾あり）



事後中央値と 68 % 誤差バンド

非弁別閾




事後中央値と 68 % 誤差バンド

報告の流れ

- 1 研究の動機と貢献
- 2 データ
- 3 モデル
- 4 ベイズ分析
- 5 計測結果 I (6 区間または 8 区間)
- 6 計測結果 II (18 区間)**
- 7 計測結果の応用
- 8 まとめ

インフレ認識 (2011年5月と2015年11月)



18 区間のデータによる計測

- 計測期間：2011Q2–2015Q4
- $K = 2$
- 事前分布の変更： $\gamma_l \sim U(-1, 0)$

18 区間のデータによる計測

- 計測期間：2011Q2–2015Q4
- $K = 2$
- 事前分布の変更： $\gamma_l \sim U(-1, 0)$

18 区間のデータによる計測

- 計測期間：2011Q2–2015Q4
- $K = 2$
- 事前分布の変更： $\gamma_l \sim U(-1, 0)$

18 区間のデータによる計測

- 計測期間：2011Q2–2015Q4
- $K = 2$
- 事前分布の変更： $\gamma_l \sim U(-1, 0)$

観察

- 1 事後分布の精度が大きく向上
- 2 非弁別閾の事後分布も安定

教訓：区間データを継続的に収集する際は、**区間の設定が重要**

観察

- 1 事後分布の精度が大きく向上
- 2 非弁別閾の事後分布も安定

教訓：区間データを継続的に収集する際は、**区間の設定が重要**

観察

- 1 事後分布の精度が大きく向上
- 2 非弁別閾の事後分布も安定


教訓：区間データを継続的に収集する際は、**区間の設定が重要**

観察

- 1 事後分布の精度が大きく向上
- 2 非弁別閾の事後分布も安定

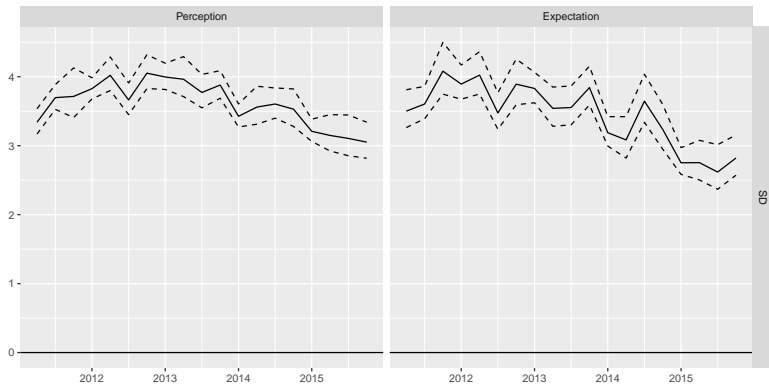
教訓：区間データを継続的に収集する際は、**区間の設定が重要**

平均




事後中央値と 95 % 誤差バンド

標準偏差




事後中央値と 95 %誤差バンド

歪度




事後中央値と 95 % 誤差バンド

過剰尖度



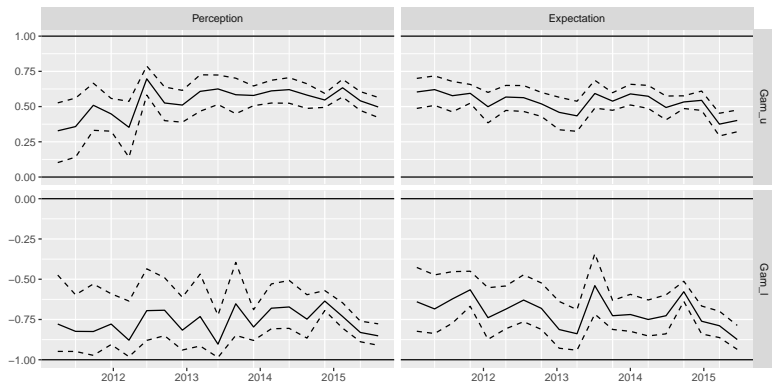
事後中央値と 95 % 誤差バンド

裾の非対称性




事後中央値と 95 % 誤差バンド

非弁別閾



事後中央値と 95 % 誤差バンド

十分位点



報告の流れ

- 1 研究の動機と貢献
- 2 データ
- 3 モデル
- 4 ベイズ分析
- 5 計測結果 I (6 区間または 8 区間)
- 6 計測結果 II (18 区間)
- 7 計測結果の応用**
- 8 まとめ

インフレ期待の分析

期待インフレ率の分布の平均値の分析

- 期待の合理性の検証
- 情報の硬直性の計測 (cf. Coibion and Gorodnichenko (2015, AER))

分布の定式化で結果が異なる \implies フレキシブルな分布を使うべき (詳細は論文を参照)

インフレ期待の分析

期待インフレ率の分布の平均値の分析

- 期待の合理性の検証
- 情報の硬直性の計測 (cf. Coibion and Gorodnichenko (2015, AER))

分布の定式化で結果が異なる \implies フレキシブルな分布を使うべき (詳細は論文を参照)

インフレ期待の分析

期待インフレ率の分布の平均値の分析

- 期待の合理性の検証
- 情報の硬直性の計測 (cf. Coibion and Gorodnichenko (2015, AER))

分布の定式化で結果が異なる \implies フレキシブルな分布を使うべき (詳細は論文を参照)

インフレ期待の分析

期待インフレ率の分布の平均値の分析

- 期待の合理性の検証
- 情報の硬直性の計測 (cf. Coibion and Gorodnichenko (2015, AER))

分布の定式化で結果が異なる \implies フレキシブルな分布を使うべき (詳細は論文を参照)

報告の流れ

- 1 研究の動機と貢献
- 2 データ
- 3 モデル
- 4 ベイズ分析
- 5 計測結果 I (6 区間または 8 区間)
- 6 計測結果 II (18 区間)
- 7 計測結果の応用
- 8 まとめ**

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
 - 8 区間：平均値の推定精度は高い
 - 18 区間：非常に推定精度が高い
- 3 計測結果の応用：英国のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
 - 8 区間：平均値の推定精度は高い
 - 18 区間：非常に推定精度が高い
- 3 計測結果の応用：英国のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
 - 8 区間：平均値の推定精度は高い
 - 18 区間：非常に推定精度が高い
- 3 計測結果の応用：英国のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
 - 8 区間：平均値の推定精度は高い
 - 18 区間：非常に推定精度が高い
- 3 計測結果の応用：英国のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国国民のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
 - 8 区間：平均値の推定精度は高い
 - 18 区間：非常に推定精度が高い
- 3 計測結果の応用：英国国民のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国国民のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
 - 8 区間：平均値の推定精度は高い
 - 18 区間：非常に推定精度が高い
- 3 計測結果の応用：英国国民のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
 - 8 区間：平均値の推定精度は高い
 - 18 区間：非常に推定精度が高い
- 3 計測結果の応用：英国のインフレ期待における情報の硬直性の検証

論文の貢献

- 1 非弁別閾をもつ区間データに対する正規混合モデルのベイズ分析
 - 事前分布の設定：階層ベイズ
 - 事後分布の計算：NUTS (No U-Turn Sampler)
- 2 英国民のインフレ認識・期待の分布の計測 (2001Q1-2015Q4)
 - 8 区間：平均値の推定精度は高い
 - 18 区間：非常に推定精度が高い
- 3 計測結果の応用：英国民のインフレ期待における情報の硬直性の検証

今後の課題

本研究の拡張

- 1 非弁別閾の異質性の導入
- 2 K の推定
- 3 状態空間モデルを用いた繰り返し横断データの時系列分析
- 4 日本のデータの分析（2009年4月以降は可能）

個票データの利用

- 1 インフレ認識・期待の同時分布
- 2 インフレ認識・期待の決定要因

今後の課題

本研究の拡張

- 1 非弁別閾の異質性の導入
- 2 K の推定
- 3 状態空間モデルを用いた繰り返し横断データの時系列分析
- 4 日本のデータの分析（2009年4月以降は可能）

個票データの利用

- 1 インフレ認識・期待の同時分布
- 2 インフレ認識・期待の決定要因

今後の課題

本研究の拡張

- 1 非弁別閾の異質性の導入
- 2 K の推定
- 3 状態空間モデルを用いた繰り返し横断データの時系列分析
- 4 日本のデータの分析（2009年4月以降は可能）

個票データの利用

- 1 インフレ認識・期待の同時分布
- 2 インフレ認識・期待の決定要因

今後の課題

本研究の拡張

- 1 非弁別閾の異質性の導入
- 2 K の推定
- 3 状態空間モデルを用いた繰り返し横断データの時系列分析
- 4 日本のデータの分析（2009年4月以降は可能）

個票データの利用

- 1 インフレ認識・期待の同時分布
- 2 インフレ認識・期待の決定要因

今後の課題

本研究の拡張

- 1 非弁別閾の異質性の導入
- 2 K の推定
- 3 状態空間モデルを用いた繰り返し横断データの時系列分析
- 4 日本のデータの分析（2009年4月以降は可能）

個票データの利用

- 1 インフレ認識・期待の同時分布
- 2 インフレ認識・期待の決定要因

今後の課題

本研究の拡張

- 1 非弁別閾の異質性の導入
- 2 K の推定
- 3 状態空間モデルを用いた繰り返し横断データの時系列分析
- 4 日本のデータの分析（2009年4月以降は可能）

個票データの利用

- 1 インフレ認識・期待の同時分布
- 2 インフレ認識・期待の決定要因

今後の課題

本研究の拡張

- 1 非弁別閾の異質性の導入
- 2 K の推定
- 3 状態空間モデルを用いた繰り返し横断データの時系列分析
- 4 日本のデータの分析（2009年4月以降は可能）

個票データの利用

- 1 インフレ認識・期待の同時分布
- 2 インフレ認識・期待の決定要因

今後の課題

本研究の拡張

- 1 非弁別閾の異質性の導入
- 2 K の推定
- 3 状態空間モデルを用いた繰り返し横断データの時系列分析
- 4 日本のデータの分析（2009年4月以降は可能）

個票データの利用

- 1 インフレ認識・期待の同時分布
- 2 インフレ認識・期待の決定要因

- Biernacki, C. (2007). Degeneracy in the maximum likelihood estimation of univariate Gaussian mixtures for grouped data and behavior of the EM algorithm. *Scandinavian Journal of Statistics*, 34, 569–586.
- Coibion, O., & Gorodnichenko, Y. (2015). Information rigidity and the expectations formation process: A simple framework and new facts. *American Economic Review*, 105, 2644–2678.
- Kiefer, J., & Wolfowitz, J. (1956). Consistency of the maximum likelihood estimator in the presence of infinitely many incidental parameters. *Annals of Mathematical Statistics*, 27, 887–906.
- Mankiw, N. G., Reis, R., & Wolfers, J. (2004). Disagreement about inflation expectations. In M. Gertler & K. Rogoff

(Eds.), *NBER macroeconomics annual 2003* (Vol. 18, pp. 209–248). MIT Press.

Murasawa, Y. (2013). Measuring inflation expectations using interval-coded data. *Oxford Bulletin of Economics and Statistics*, 75, 602–623.

Richardson, S., & Green, P. J. (1997). On Bayesian analysis of mixtures with an unknown number of components (with discussion). *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 59, 731–792.