

出典：Duell et al.(2007)

図 4 Model-based Method と Locally Weighted Average Method の効果の比較

以上の既存研究レビューの結果から、本研究で用いる 3 つの手法¹¹(LWA、経験ベイズ法、階層ベイズ法)の利点と欠点を整理すると、表 1 のように示すことができる。また、階層ベイズ法による 2 つのモデル(ポアソンガンマモデルとポアソン対数正規モデル)を含めた計 4 つの手法について、手法の複雑さと推定精度により、位置づけを行ったものが図 5 である。本研究では、以下で行う分析と考察において、これら手法の利点と欠点を踏まえつつ、医療費適正化上、受診指数を改良する際にいずれの手法を用いることが適切といえるのか検討することとする。

表 1 各手法の概要と利点・欠点

| 手法 | 補正方法 | 利点 | 欠点 |
|---------------------------------|---|--|--|
| Locally weighted average method | ①近隣地域の値との差を減らそうとする ②周辺地域の値を用いて、加重平均をとる | ①四則演算のみで計算可能 ②ベイズ統計学を知らなくても補正が出来る ③一定以上の分散を持つ地域のみを補正する | ①隣接市町村数が多いほど、補正がなされる ②都道府県の外側にある市町村は必然的に隣接市町村が少ないため、補正があまりされない傾向にある ③隣接関係によって補正の程度が異なってしまう |
| Empirical bayes (経験ベイズ) | ①ベイズ統計の考え方をういて、指数に事前分布を仮定。 ②パラメータが分布を持つと仮定 ③ θ というリスクのパラメータ、つまり医療費指数がどのような地理的分布に従うのかという考えを補正に反映できる | ①事前分布の形状を決定するパラメータをデータから計算する手法 ②ベイズ法の手法の中でも計算方法がより簡便である | ①高度な統計的知識や技術を要することから、利用が遅れているといわれる ②ベイズ統計学の知識がないと利用できない ③精度の高い手法を用いようとすると、複雑なモデルになってしまう |
| Hierarchical bayes (階層ベイズ) | ①SAEの最も新しいの手法 ②精度という観点から、最も優れている ③事前分布の形状を決定するパラメータをサンプリングの手法を使って計算 | ①パラメータの不確実性を考慮に入れ、限られたデータから、より精度の高い推定結果を導くことが出来る | ①計算するためにMCMC法を使うため、RやWinBUGS等のソフトウェアを用いる必要があるため、ソフトウェアに慣れる必要がある |

¹¹ 補正に際しては、以下の 3 つの手法 LWA、経験ベイズ法、階層ベイズ法を用い、そのうち階層ベイズ法については 2 つのモデル(ポアソンガンマモデルとポアソン対数正規モデル)を用いるため、結果として合計で 4 つの方法を用いて補正を行うこととする。

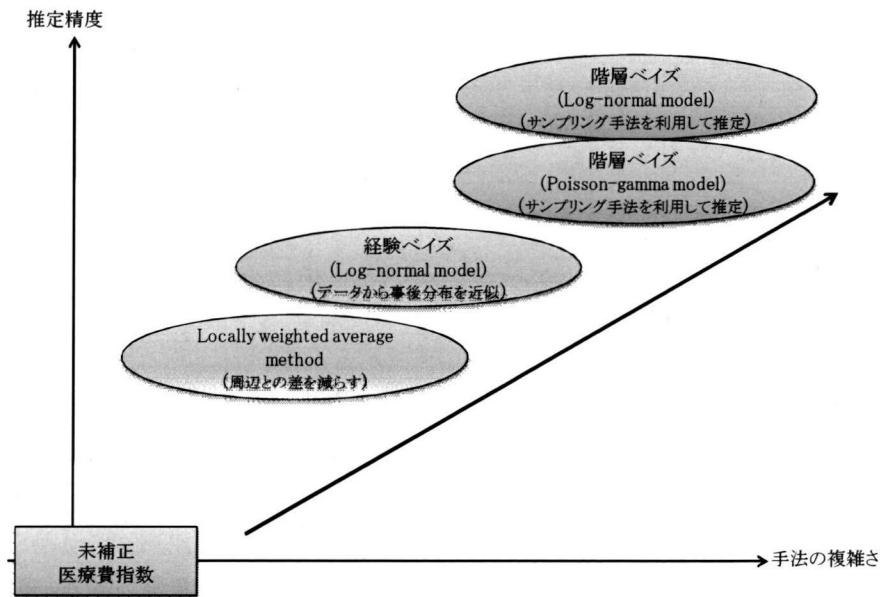


図 5 推定精度と手法の複雑さによる手法の位置づけ

3. 本研究の目的と意義

本研究の目的は、大きく分けて2つある。第1は、ベイズ統計を用いて受診指数の精密な推定を行うこと、第2は、小地域推定の方法選択の知見を獲得することである。

地域の受診行動の水準を相対的に把握するため、医療費の地域差指数等の算出に用いられる相対リスクの式を応用し、受診件数の指数(以下、受診指数)を算出する。しかし、受診指数を地域別あるいは性、年齢、疾患別等の細かな区分に分けて推定すると、分析単位の小ささから Small Area Estimation(SAE)の問題が生じてしまう。SAEとは、分析地域の人口が少ない、あるいは分析単位が小さいために誤差変動が大きくなり、精度の高い推定結果を得られない問題である。

SAEに関する国内の既存研究では、市区町村別の死亡率等を経験ベイズ法により補正を行う研究がなされているが、患者の受診行動の水準を示すとともに代替的な医療費水準を示す指標である受診指数の分析では未だ実施されていない。また、補正の方法には、経験ベイズ法を用いた方法以外にもいくつかあるが、適切な手法選択については十分な議論がなされていない。一方、国外の研究では、精度を高めることを念頭に複数の補正方法が開発された結果、補正方法が高度に複雑化し、精度と簡便性の間にトレードオフの関係が生じている。

そこで、本研究では、既存研究のレビューから受診指数の推定に有用と判断した4つのSAEの手法(Locally Weighted Average(LWA)、経験ベイズ法(Empirical. Bayes Method)、階層ベイズ法(Hierarchical. Bayes Method)によるポアソンガンマモデルとポアソン対数正規モデル)を用いて、受診指数の精密な推定を行う。受診指数の推定をSAEの補正手法を用いて行うことにより、より精度の優れた指数を算出する。さらに、これら4つの手法により得られた結果から、医療費適正化上、いずれの手法を用いて推定すべきかを検討し選択する。最後に、補正前と補正後の指数から、適正化重点対象地域として選択される地域に変化が生じるのかを考察することにより、指数の補正の必要性を確認する。

本研究を通じて、受診指数の改良を行うことにより、医療費適正化計画の策定に際して、各都

道府県が医療費の実態を細かな地域あるいは対象別に把握することを手助けすることができると思われる。ただし、医療費適正化計画では受診指数のみでなく医療費指数についても精密な推定を行うことが必要と考えられるが、今回は予防に重点を置き、受診指数の推定を行うこととした。医療費指数の精密な推定については今後の課題である。

精度と簡便性という2つの視点から多様な手法が提案されるSAEの手法について、データ特性に応じて適切な手法を選択することにより、政策現場においてSAEの補正手法を用いる際の判断基準に示唆を与えることができよう。そして、これは医療費データに限らず他のデータに対してSAEの手法選択を行う場合にも参考になるものと考えられる。

4. 分析方法

4.1. 分析データ

平成18年度5月診療分の山形県国民健康保険の市町村別レセプト集計データを用いて、高血圧疾患の受診件数に関する分析を行った。これは、平成21年度厚生労働科学研究「国、都道府県の医療費適正化計画の重点対象の発見に関する研究」において協力自治体から提供されたデータの一部¹²である。

本研究の目的は、第1にベイズ統計を用いて受診指数の精密な推定を行うこと、第2に、小地域推定の方法選択の知見を獲得することであった。したがって、SAEの問題が発生しやすい人口規模が小さい市町村や細分化した対象（性別、年齢、疾病別など）の受診件数において、ベイズ統計の有用性を実証的に明らかにすることが課題である。そのため、複数の市町村の受診指数を改良する必要がある。また、この研究は学術的な精度の向上だけでなく、医療費適正化計画の政策資料の充実を目指しているため、医療費適正化政策上重要な疾病を分析することも必要である。

そこで本研究では、小規模自治体から比較的大きな自治体まで兼ね備えている山形県を対象にし、また予防の観点から最重要と考えられている高血圧疾患のデータを分析対象に取り上げた。たしかに、人口規模が異なる市町村が所属し、詳細なデータが入手できるのであれば、他の都道府県を分析対象に行ってもよい。条件を満たすならば他の任意の都道府県を対象にしてよく、今回はデータの入手可能性の観点から山形県を分析対象とした。また、医療費適正化の観点からいえば、一つの都道府県だけでなく、複数の都道府県、できれば全都道府県を対象に分析する方が望ましいとの指摘もありえよう。しかし、研究の目的は、政策資料としての分析手法の改良を、理論的だけでなく実証的に吟味することにあるため、改良した手法を包括的に適用し、政策資料の改善を目指す部分までは、研究の射程を超えており、今後の課題とすることにした。

次に、医療費を直接分析せず、受診件数を分析対象としていることについて説明する。通常、一人当たり医療費を分析することが多いが、一人当たり医療費は医療費の3要素¹³（受診件数、受診日数、点数）に分解できることが知られている。しかも、一人当たり医療費は、3要素の中でも受診件数によって大きく影響を受けることが、これまでの研究により実証されている。また、保健予防の観点から見ても、患者の発症数を間接的に把握できる受診件数が最も重要な指標にあ

¹² 本研究は、平成21年度厚生労働科学研究「国、都道府県の医療費適正化計画の重点対象の発見に関する研究」の一部として行った研究であるため、平成21年度報告書に掲載予定である。


¹³ 1人当たり医療費は、①(医療機関への)受診率、②1件当たり日数、③1日当たり医療費の積で表わすことが出来る。つまり、1人当たり医療費=1日当たり医療費×受診率×1件当たり日数となる。これら3つの要素を医療費の3要素と呼ぶ。

たる。さらに、既存研究において、国内外を含め受診件数と点数共に医療費を題材としてSAEの補正を行った研究は筆者が調べた限りでは見当たらない。したがって、これら3つの理由から、受診件数を用いた受診指数を補正することに政策的意義があるものと考え、受診指数の精密な推定を行うこととした。

最後に、高血圧疾患を分析対象に選択した理由について簡単に説明する。高血圧疾患のデータを用いた理由は、①財政上、また医療費適正化上も重要な疾患であること、②性別・年齢階層別に受診傾向、期待件数が大きく異なることの2つである。期待件数とは、被保険者数に6府県(山形県、静岡県、長野県、大阪府、広島県、高知県)の平均受診率¹⁴を乗じた値であり、性・年齢階層・疾患別に計算することができる。

高血圧疾患は、生活習慣病の代表疾患であるとともに、予防効果の高さから医療費適正化上重要な疾患として位置づけられている。実際に、医療費に占める割合を疾患別に確認すると、高血圧疾患は生活習慣病の医療費総額10.4兆円のうち総額で2.8兆円と最も大きな割合を占めていることがわかる(図6)。

さらに、死因別死亡割合においても、悪性新生物や心疾患あるいは脳血管疾患などの重症疾患の前段階の疾患として高血圧疾患は捉えられており、早期に予防に取り組むことで医療費を大幅に適正化できる可能性がある疾患として重要な疾患だといえる。



出典：平成19年度厚生労働白書
 図6 生活習慣病の医療費の割合

また、高血圧疾患の受診傾向と期待件数は、性別、年齢階層別に大きく異なっており、他の疾患に比べデータ区分(性・年齢階層区分)による違いが大きい。実際に補正を行う際には、どの程度データ区分を細かくするのかにすることによって補正の必要性が異なる。図7、図8より、高血圧疾患の受診率は性別・年齢階層別に大きく異なっていることが確認できる。他の疾患においても差が生じていることが確認出来るが、高血圧疾患ほど大きく異なる疾患は見当たらない。図9は、

¹⁴一人当たり受診件数の算出にあたっては、本研究のデータ出典である「国、都道府県の医療費適正化計画の重点対象の発見に関する研究」の研究協力自治体である6府県(山形県、長野県、静岡県、大阪府、広島県、高知県)のデータを用いている。

医療費適正化上重要な疾患として位置づけられる2つの疾患(高血圧疾患と脳卒中(くも膜下出血、脳内出血、脳梗塞の3疾患の合計)の性・年齢階層別の受診率を比較したグラフであるが、脳卒中の受診率に高血圧ほどの性差あるいは年齢階層による差はないことが確認出来る。

さらに、高血圧疾患の医療費データを、高血圧(合計)、男性高血圧、女性高血圧、0-39歳高血圧、40-49歳高血圧、50-59歳高血圧、60-69歳高血圧、70歳以上高血圧の8つのデータ区分別に、実績件数または期待件数の被保険者数との関係を示したグラフが図10である。また、それらの期待件数の要約統計量をデータ区分別に示したものが図11と表2である。全体的な傾向として、被保険者数が少ないほど、実績件数と期待件数ともにデータがばらついていることがわかる。さらに、同一の被保険者数でみると、期待件数の方が実績件数を下回っている場合が多いことがわかる。被保険者数が少ない方が受診件数が多くなるとは考えにくいいため、被保険者が小さいほど件数のばらつきが大きいことは、SAEの問題、つまり誤差を生じていることを示唆する結果だといえる。

また、図11と表2からは、期待件数と期待件数の平均、最大値、最小値、標準偏差共に、高血圧(合計)のデータ区分が最も高い値を示していることがわかる。高血圧(合計)は、対象となる被保険者数が最も多い区分であるため、当然の結果だといえる。

また、高血圧に次いで高い値を示しているのが、70歳以上高血圧、女性高血圧、男性高血圧のデータ区分である。その他の区分においては、60-69歳高血圧、50-59歳高血圧、40-49歳高血圧、0-39歳高血圧のデータ区分の順に、期待件数の平均、最大値、最小値、標準偏差の4つが共に小さい値を示している。これは、高血圧疾患が年齢階層別にみると高齢であるほど罹患しやすく、性別でみると女性であるほど罹患しやすい、あるいは受診頻度が高いという傾向を示しているといえる。このようなデータ区分による受診率の違いあるいは期待件数の違いを有するデータ区分では、佐伯ほか(2005)が期待件数の大きさによって補正の度合いが異なっていることを示したように、補正の必要性が大きく異なる可能性が高い。

以上の理由より、本研究では、分析データとして、平成18年度5月診療分における山形県国民健康保険市町村別レセプト集計データの高血圧疾患に関する受診件数を用いる。




図 7 疾患別受診率(合計・性別)




図 8 疾患別受診率(年齢階層別)





図 9 高血圧と脳卒中の性・年齢階層別受診率






図 11 各データ区分の期待件数の要約統計量

表 2 各データ区分の要約統計量

| | 期待件数の平均 | 期待件数の最大値 | 期待件数の最小値 | 期待件数の標準偏差 |
|------------|---------|----------|----------|-----------|
| 高血圧 | 2,036 | 13,618 | 270 | 2,775 |
| 男性 高血圧 | 827 | 5,462 | 108 | 1,106 |
| 女性 高血圧 | 1,209 | 8,156 | 162 | 1,670 |
| 0-39歳 高血圧 | 5 | 36 | 1 | 7 |
| 40-49歳 高血圧 | 22 | 132 | 4 | 28 |
| 50-59歳 高血圧 | 160 | 921 | 23 | 200 |
| 60-69歳 高血圧 | 494 | 3,354 | 61 | 687 |
| 70歳以上 高血圧 | 1,354 | 9,175 | 174 | 1,855 |

4.2. 分析の流れ

分析の流れを図 12 に示した。はじめに、1.補正手法の選択に関する分析として、受診指数の改良を行う。改良にあたっては、補正結果の比較を行うことにより、データ区分別に適切な手法を選択する。つぎに、2.適正化重点対象地域の選定に関する分析として、補正された受診指数を用いて、政策的に重要な地域を選定する。これら 2 つの分析を通じて、本研究の目的である 1. 受診指数の改良と 2.SAE の手法選択に関する知見の獲得を目指す。

1. 補正手法の選択に関する分析では、既存研究レビューの結果選択した 4 つの SAE の手法(① Locally Weighted Average Method、②経験ベイズ法(モーメント法を用いたポアソンガンマモデル)、階層ベイズ法(③ポアソンガンマモデル、④ポアソン対数正規モデル))を、次の 8 つのデータ区分に当てはめて、受診指数の補正を行い比較分析した。8 つのデータ区分とは、高血圧(合計)、男性高血圧、女性高血圧、0-39 歳高血圧、40-49 歳高血圧、50-59 歳高血圧、60-69 歳高血圧、70 歳以上高血圧である。

なお、補正の比較分析の際には、補正の精度と簡便性のバランスの観点から考察した。学術的には補正の精度が高いことが重視されるが、政策的には行政官や保健師が計算できるよう簡便性も重視される。したがって、精度に大差が出ないのであれば、より簡便な方法が望ましい。した

がって、4つの補正方法を8つのデータ区分に適用し、補正の精度を実証的に確かめたうえで、8つのデータ区分ごとに有用な補正手法を検討した。

2.適正化重点対象地域の選定では、補正前と補正後の指数をマッピングすることにより、結果の違いを考察した。重要地域の選定にあたっては、標準偏差分類¹⁵という手法を用いて地域の選定を行う。標準偏差分類とは、GIS や空間統計の分野において地理的な情報を視覚化する際に用いられる手法の1つであり、平均値からの乖離度に基づいてクラス分けする方法である(村山、柴崎(2008))。この手法を用いることで、それぞれの県内で医療費が著しく高いあるいは低い地域を客観的に識別し、選定することができる。分類された結果より、重点的に施策を行うべき地域が、補正手法により異なるのか、あるいは異なるのかを明らかにする。

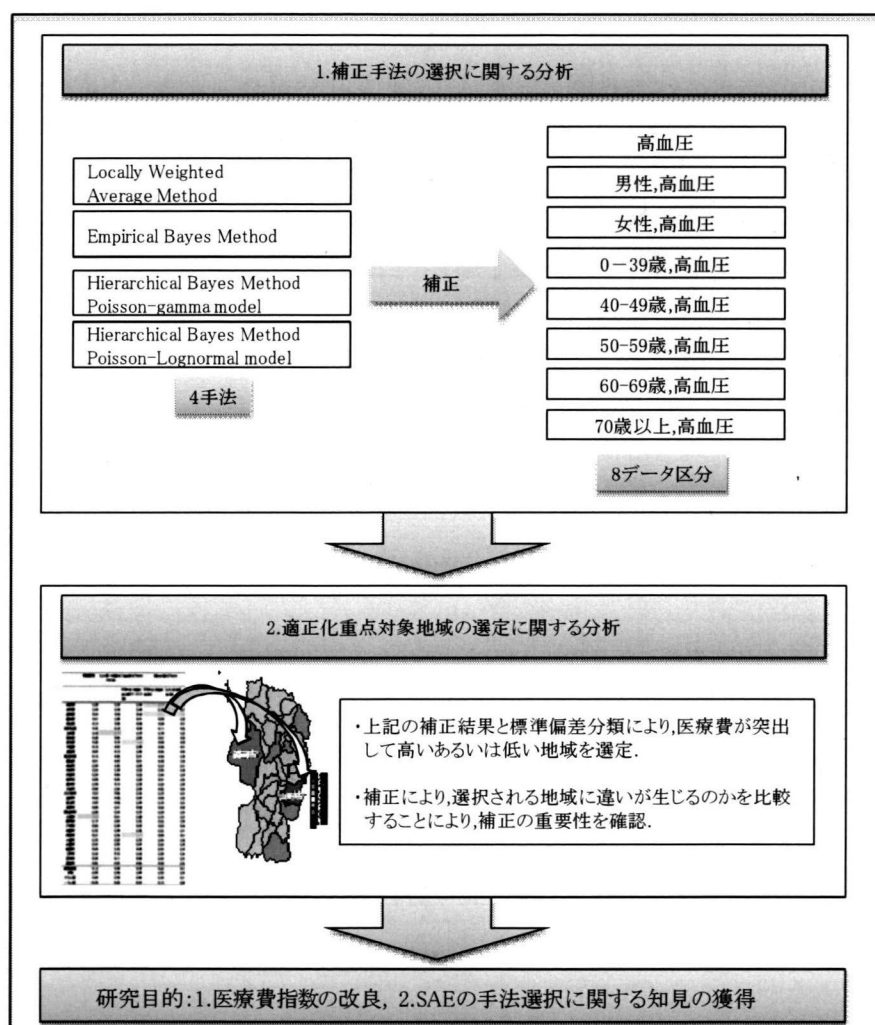


図 12 分析の流れ

4.3. 補正手法

以下では、既存研究のレビューから選択した4つの補正手法について説明を行う。Locally Weighted Average Method (LWA)は、非ベイジアン的手法として選択した手法であり、複雑なモ

¹⁵ 詳しくは、村山、柴崎(2008)あるいは Arc Map ユーザーガイドを参照されたい。

ど加重の加え方が推定上の重要な要素となる。加重の仕方にはいくつかの方法が存在しており、Waller and Gotway(2004)によれば、①距離による重み付け、②人口規模による重み付け、③境界線の有無による重み付け、④近隣地域というグループ属性による重み付けなどが可能となっている。これらの加重の加え方は補正対象であるデータの特性に応じて選択する必要がある、複数の要素を用いて同時に重みづけすることも可能である。

受診指数の補正を行う場合には、同一の二次医療圏でかつ隣接地域の中では医療供給体制や患者の諸条件がある程度同質だと仮定することが出来るため、本研究では同一二次医療圏という要素に加えて隣接地域として境界線を接するという要素で重み付けを行うこととした。しかし、近接地域の設定方法は推定結果を大きく変化させる可能性があるため、より妥当な設定方法は如何なる条件かについては別途研究が必要であろう。特に、二次医療圏の設定方法についてはいくつかの問題点が指摘されているため、真に同質な範囲とは如何なるものかについて明らかにする必要がある。さらに、実績件数の補正の際には、人口規模の影響を除去していないため、人口規模を補正の要素に入れ込むこととした。

したがって、本研究では①同一の二次医療圏内にあるか否か、②境界線を接するか否か、③人口規模という3つの要素を加味して補正することとした。これらの条件を用いて LWA を定義すると、次式のように示すことができる。

$$\hat{\theta}_i = \frac{\sum_{j=1}^N W_{ij} * r_j I[j \in N_i] + r_i}{\sum_{j=1}^N W_{ij} * p_j I[j \in N_i] + p_i}$$

$$W_{ij} = \begin{cases} 1 & \text{領域 } i \text{ と } j \text{ が境界を共有するとき} \\ 0 & \text{それ以外} \end{cases}$$

$$I[j \in N_i] = \begin{cases} 1 & \text{領域 } i \text{ と } j \text{ が同一の二次医療圏内} \\ 0 & \text{それ以外} \end{cases}$$

r : 単純受診指数(未補正の受診指数)
 p_i : 人口

(4.1)

ここで、 y_i は観測された受診指数、 $\hat{\theta}_i$ はLWAによる補正後の指数を示している。また、 N_i は地域 j が地域 i と同一の二次医療圏であることを指す。

4.3.2. Empirical Bayes(EB) Method

Empirical Bayes(EB) Method(以下、経験ベイズ法)とは、ベイズ統計の考え方をSAEの手法に応用したものであり、事前分布に関するパラメータをデータから計算するという特徴を有する。このようなベイズアンによる手法は、1980年代以降発達した手法であり(Lawson et al. (1999))、SAEの新たなアプローチとして注目され、より精度の優れた手法として広く用いられるようになってきている。ベイズアンによる推定では、通常SAEの手法に限らず、データに事前分布を想定し、尤度と事前分布をかけあわせることにより、事後分布を得る。この事後分布が推定結果となる。

ベイジアンの手法では、パラメータが分布を持つという仮定をモデルに組み込むことができるという点が特徴的である。この分布とは、分析者が事前に有している分析対象のデータに関する信念あるいは考えを指している。つまり、本研究でいえば θ_i というリスクのパラメータ、つまり受診指数がどのような分布に従うのかという考えを反映したものである。

経験ベイズ法は、事前分布の形状を決定するパラメータに対して、更なる事前分布(パラメータ)を仮定し、推定を行う手法である。なお、更に設けた事前分布のパラメータをハイパーパラメータと呼ぶ。また、ハイパーパラメータを設定するという点でいえば、経験ベイズ法は Hierarchical Bayes Method¹⁷(以下、階層ベイズ法)の一部だといえる。しかし、たいていの場合には事前分布のパラメータは未知であるため、今手元に有しているデータを用いてパラメータの値を設定し、推定値を算出しようとするのが経験ベイズ法である。つまり、経験ベイズ法による推定では、データに基づいて事前分布を設定しているといえ、その意味でより頻度論に近い手法だといえる(Rao(2003))。

また、後に詳述するが、これらのパラメータを数値計算(MCMC法(マルコフ連鎖モンテカルロ法))により与えようとする手法が階層ベイズ法である。

ここで、 m 個の地域に対する受診指数(θ_i)を補正するため、ポアソンガンマモデルを仮定するとき、受診指数は以下のように表わすことができる。

$$\hat{\theta}_i^{eb} = (O_i + \hat{\alpha}) / (e_i + \hat{\beta}) = (1 - \hat{B}_i) \hat{\theta}_i + \hat{B}_i \hat{\mu} \quad (4.2)$$

ここで、 $B_i = \hat{\beta} / (e_i + \hat{\beta})$, $\hat{\mu} = \hat{\alpha} / \hat{\beta}$, $\varphi^2 = \beta / \alpha^2$ であり、 $i=1, \dots, m$ を指す。

$$\begin{aligned} \theta_i &\sim \text{Gamma}(\beta/\alpha, \beta/\alpha^2) \\ y_i &\sim \text{Poisson}(\theta_i e_i) \end{aligned} \quad (4.3)$$

θ_i は平均 β/α 、分散、 β/α^2 を持つガンマ分布に従うと仮定し、観測された受診件数(y_i)は平均と分散共に $\theta_i e_i$ であるポアソン分布に従うと仮定している。

上式において、ハイパーパラメータとは α と β を指し、経験ベイズ法はこれらの値をデータから計算しようとしている。また、Devine et al.(1994)は、ベイズ推定値を観測値である θ_i と事前分布の平均である $\hat{\mu}$ のそれぞれについて重みづけを行い、足し合わせたものだと説明した。また、V. Gomez-Rubio and A.Lopez-Quilez(2006)は経験ベイズ法を Direct estimation と Relative risk(相対リスク)の事前平均との妥協点だと説明している。推定値 $\hat{\theta}_i^{eb}$ は、結果として人口規模が小さいとき $\hat{\mu}$ に近づき、反対に人口規模が大きいときには、 $\hat{\theta}_i$ に近づくこととなる。つまり、人口規模が大きいときには、観測された指数が安定した精度を持つと考えるため補正を行わず、観測値 $\hat{\theta}_i$ に収束させるということを意味している。

さらに、経験ベイズ法におけるハイパーパラメータの算出方法については、複数の方法が提案されている。本研究では、より簡便な方法として Marshall(1991)によって提案されたモーメント

¹⁷ 階層ベイズ法は、事前分布のパラメータに更なる事前分布(ハイパーパラメータ)を仮定し、モデルを階層構造として推定する手法である。

法¹⁸による算出方法を用いる。実際に、自治体の政策担当者が計算を行う場合には、ベイジアン
の手法を用いることによって推定精度を上げつつも、より簡便な方法であることが望ましいと考
えたためである。その他の手法(最尤法等)では収束計算を行う必要があるため、単純な四則演算の
みで計算を行うことが難しい¹⁹ため、より単純なモーメント法を選択した。

モーメント法によるハイパーパラメータの値は、次式から得ることができる。

$$\hat{\mu} = \frac{\sum_i O_i}{\sum e_i}$$

$$\varphi^2 = S^2 - \frac{\hat{\mu}}{\frac{1}{m} \sum_{i=1}^m e_i} \quad (4.4)$$

ここで、 $S^2 = \frac{\sum_{i=1}^m e_i (\hat{\theta}_i - \hat{\mu})^2}{\sum_{i=1}^m e_i}$ である。また、 φ^2 が負値となる場合には、ゼロで切り捨てを行う。

また、 $\hat{\mu}$ の値の設定の仕方には2つの方法があり、Global mean(全体の平均値)に収束させる場
合と Local mean(限定された地域の平均値)に収束させる場合とが考えられる。受診指数の場合に
は、地理的な条件やその他の状況により二次医療圏が設定されているため、二次医療圏内の値に
収束させるのが Global mean を用いることよりも妥当と考え、Local mean を用いることとする。
同一の二次医療圏内においては、医療供給体制や社会的状況、あるいは患者の生活習慣等がある
程度似ているであろうという前提に基づいている。つまり、医療費の発生に関わる諸要因がある
程度同じだと仮定している。経験ベイズ法を用いて合計特殊出生率や標準化死亡比のスムージン
グを行った佐伯ほか(1999)、平子ほか(1999)においても、二次医療圏の平均値を Local mean と
設定し補正を行っている。Global mean として県全体の平均値に収束させるよりも、二次医療圏
等の近接地域あるいは諸条件が同じと考えられる Local mean への収束の方が、地理的状況を加
味しているため、より良い推定値だと考えているためである。ただし、Local mean をどの範囲に
設定すべきかについては、LWA の近隣地域の設定方法と同様、議論の余地が残る。そもそも医療
圏の設定自体が恣意的に行った設定であり、二次医療圏の実態についても人口や面積にばらつき
が生じていることや日常生活と住民の受診行動が一致しないなどの問題点が指摘されているため、
詳細な分析が必要であろう。つまり、経験ベイズ法として Global mean ではなく Local mean に
収束させたほうがより地理的な条件を加味できる(Martuzzi and Elliott(1996))ということに異論
はないが、Local mean をどの範囲に設定すべきかについては別途詳細な研究が必要だといえる。

4.3.3. Hierarchical Bayes(HB) Method

Hierarchical Bayes(HB) Method(階層ベイズ法)は、SAE の手法の中でも最も新しい手法だと
いえる(Trevisani and Torelli(2004))。また、事後分布を得る際に異なるタイプの効果(例えば、固
定効果(Fixed Effect)や混合効果(Random Effect)、あるいは変化の源となる変数等をモデルに組
み込むことができ、モデルパラメータの不確実性を統一的に扱うことができる手法である(V.

¹⁸ この点について、国内の文献として中谷ほか(2004)や佐伯ほか(2005)が説明を加えているので参照されたい。

¹⁹ ただし、経験ベイズ法については、R コマンドとしていくつかの関数が既に定義されている。

Gomez-Rubio and A.L.opez-Quilez(2006))。

階層ベイズ法による推定値は以下のように表わされる。

$$\theta_i^b = (O_i + \alpha) / (e_i + \beta) = (1 - B_i)\hat{\theta}_i + B_i\mu \quad (4.5)$$

推定式は、経験ベイズ法によるものと同様、受診指数 θ_i と平均 μ の加重平均の形をとる。

階層ベイズ法による SAE の補正では、単純なモデルから、非常に複雑なモデルまで数多くのモデルが存在している²⁰。前述したように固定効果や混合効果を同時に入れるタイプのモデルや空間的な自己相関を加味できる複雑なモデルまで非常に幅広いが、本研究では、政策判断材料として用いることを念頭に置き、複雑過ぎないモデルとして、以下にあげるポアソンガンマモデル(HBP)とポアソン対数正規モデル(HBL)を用いることとする。

ポアソンガンマモデルは次式のように示される。

$$\begin{aligned} \theta_i &\sim \text{Gamma}(\beta/\alpha, \beta/\alpha^2) \\ y_i &\sim \text{Poisson}(\theta_i e_i) \end{aligned} \quad (4.6)$$

また、ポアソン対数正規モデルは、以下のように示される。

$$\begin{aligned} y_i &\sim \text{Poisson}(\theta_i e_i) \\ \text{Log}\theta_i &= \alpha + v_i \\ v_i &\sim N(0, \tau_v^2) \end{aligned} \quad (4.7)$$

両者のモデルの違いは、空間的な相関を扱えるか否かという点である。Lawson et al.(2003)によれば、空間的な相関を扱えないことがポアソンガンマモデルの欠点だと指摘されている。つまり、指数の分布を補正する際に、ポアソンガンマモデルを仮定した階層ベイズ法では、受診指数などのリスクが近隣地域で同じような傾向を持つという、空間的な相関をモデルに組み込むことが出来ない。それに対し、ポアソン対数正規モデルでは指数に関わる空間的な相関関係をモデルに組み込むことができ、より柔軟な推定を行うことができる。2つのモデルを受診指数の補正に用いることで、受診指数の補正にあたってどちらが適切かという点について、示唆を与えることができるといえよう。

なお、階層ベイズ法による補正に際しては、すべてMCMC法(ギブズサンプラー)を用いて推定を行い、各々のシミュレーション結果についてはマルコフ連鎖が収束しているか否か(定常状態に達したか)を確認するため、Gelman-Rubin 統計量により収束診断²¹を行った。

²⁰詳しくは、Rao(2003)、Lawson et al.(2003)を参照されたい。

²¹ 詳しくは、Lawson et al.(2003)、古谷(2008)を参照されたい。

5. 分析結果と考察

以下では、補正手法の選択に関する分析、適正化重点対象地域の分析の順に、分析と考察を行う。補正手法の選択に関する分析では、高血圧疾患に関する8つのデータ区分²²(性別、年齢によってデータを分割した)に対して、既存研究レビューの結果選択した4つの補正手法(LWA、経験ベイズ法(EB)、階層ベイズ法の2つのモデル(ポアソンガンマモデル(HBP)とポアソン対数正規モデル(HBL))を適用し、補正を行った。

補正にあたっては、データ区分によって適切な手法は異なるのか、あるいは全てのデータ区分において適切な手法は同じなのかを明らかにするため、補正結果の比較を行った。その際、データ区分によって手法選択で重視すべき点(精度あるいは簡便性など)を明らかにした。これは、医療費適正化という政策目的を念頭に置いて受診指数の補正を行うため、実際にSAEの手法を用いる主体として想定する国あるいは都道府県等の政策担当者が使うためには、ある程度の推定精度を改善しつつも、複雑過ぎない手法であることが求められるためである。

適正化重点対象地域の分析では、補正された指数を用いて、医療費適正化上重点的に施策を行うべき地域を選定した。選定に際しては、平均値からの乖離度によって突出して高いあるいは低い地域を選定するため、標準偏差分類という手法を用いて重要地域の選定を行った。補正前と補正後の指数の地図を視覚的に確認することにより、選定される地域に違いが出るのかを明らかにした。最後に、これらの分析を通じて、政策的に補正を行うことが有用であるか否かを考察した。

5.1. 補正手法の選択に関する分析

5.1.1. 分析結果

5.1.1.1. 4つの補正手法の比較分析

4つの手法を用いた補正結果の一覧を、本節の最後にある表6から表13に示した。また、手法別の補正結果の全体の傾向を把握し、比較するため、図14、図15に各手法による補正結果の最大値、第3四分位点、第1四分位点、最小値を箱ひげ図の形で表した。図では単純指数、LWA(Locally Weighted Average Method)、Empirical. Bayes Method(EB)、Hierarchical. Bayes MethodのPoisson-gammaモデル(HBP)、Hierarchical. Bayes MethodのLog-normal.モデル(HBL)の順に示している。

はじめに、データ区分別に箱ひげ図に示した値と全体の傾向を図14、図15より確認すると、高血圧では、手法による差異はあまり生じていない。最大値、第3四分位点、第1四分位点は大きな変化を生じていない一方で、LWAによる最大値のみ小さくなっていることがわかる。

男性高血圧では、階層ベイズ法の2つの手法による結果と単純指数の結果が類似した傾向にあることがわかる。一方で、LWAと経験ベイズ法による結果の最大値が大きく縮みこんでいることが分かる。最大値、第3四分位点、第1四分位点は大きな変化を生じていない。

女性高血圧では、男性高血圧とほぼ同様の傾向にあり、LWAと経験ベイズ法による結果が類似しており、最大値のみ大きく縮みこむ結果となった。

0-39歳高血圧では、LWAから階層ベイズ法へと精度が高い補正方法になるほど補正後の指数の変動が縮小する傾向にあった。このような顕著な推移は、上記の高血圧、男性高血圧、女性高

²²高血圧(合計)、男性高血圧、女性高血圧、0-39歳高血圧、40-49歳高血圧、50-59歳高血圧、60-69歳高血圧、70歳以上高血圧の8つの区分である。

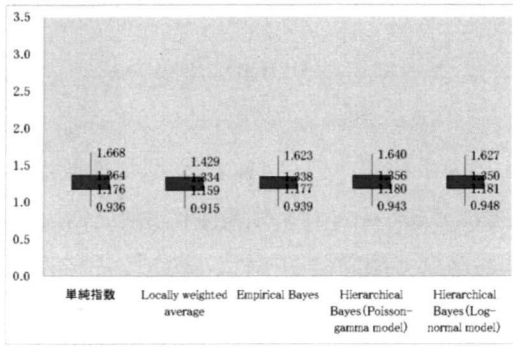
血圧等のデータ区分にはみられず、特徴的な結果だといえる。さらに、補正前の単純指数の値も大きく広がっていることも読み取れる。また、他の区分では著しい差のみられなかった階層ベイズ法と経験ベイズ法の補正結果に差が生じていることがわかる。

40-49 歳高血圧では、0-39 歳高血圧と同様、LWA から階層ベイズ法へと精度が高い補正方法になるほど補正後の指数の変動が縮小する傾向にあった。また、補正前の単純指数の値が大きく広がっていることがわかる。さらに、経験ベイズ法と階層ベイズ法による結果にも差異が生じていることがわかった。


50-59 歳高血圧では、LWA の補正結果は、最大値が単純指数よりも大きくなるという結果になった。また、単純指数と階層ベイズ法の結果に著しい差はみられない。一方、経験ベイズ法による第 3 四分位点と第 1 四分位点は他の手法と比べ、その幅が小さくなっていることがわかる。また、最小値に大きな差は見られなかったものの、最大値は手法ごとに差を生じる結果となった。

60-69 歳高血圧では、経験ベイズの補正結果が他の手法と比較して、大きく縮みこむ結果となった。経験ベイズ以外の手法では、単純指数の全体的な傾向と比較して著しい差は見られなかった。


70 歳以上高血圧では、LWA による最大値が他の手法に比べ小さくなっていた。最小値に関しては大きな変化はみられなかった。また、経験ベイズ法による最大値も LWA について小さくなっていることがわかる。




高血圧



男性 高血圧




女性 高血圧




0-39歳 高血圧


図 14 データ区分の違いによる各手法の指数の補正結果



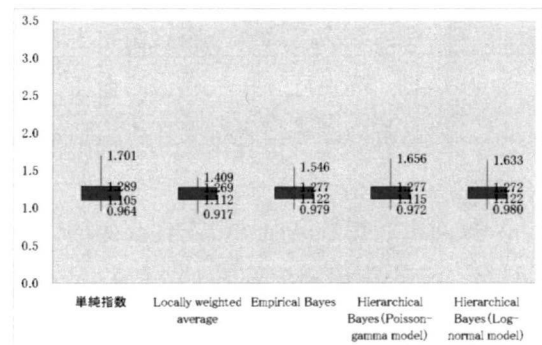
40-49歳 高血圧



50-59歳 高血圧



60-69歳 高血圧



70歳以上 高血圧

図 15 データ区分の違いによる各手法の指数の補正結果

5.1.1.2. 補正差の傾向

全てのデータ区分を統合し、補正差(各手法による補正結果の単純指数との差)と期待件数を同時に示したものが図 16 である。

図 16 から、全体の傾向を観察すると、4つの手法すべてにおいて、期待件数が小さいほど補正差が大きくなっていることがわかる。補正差は 0.5 から -0.5 の範囲に集中しており、補正差が絶対値で 0.5 以上の指数は期待件数が 500 以下となる傾向にあった。また、期待件数が 2,000 以上の指数では、補正差がほぼゼロに近いところに位置しており、あまり補正がなされていないことがわかる。さらに、期待件数が非常に小さい指数では、補正差の絶対値が最大で約 2.7 と期待件数が大きい指数の補正差がゼロであることと対照的な結果となっている。これらの結果から、期待件数が小さい場合ほど、SAE の問題を生じる誤差が大きく生じていることが示唆された。さらに、0.5 以上の補正差を生じた指数は、4つの手法すべてにおいて存在していることがわかった。

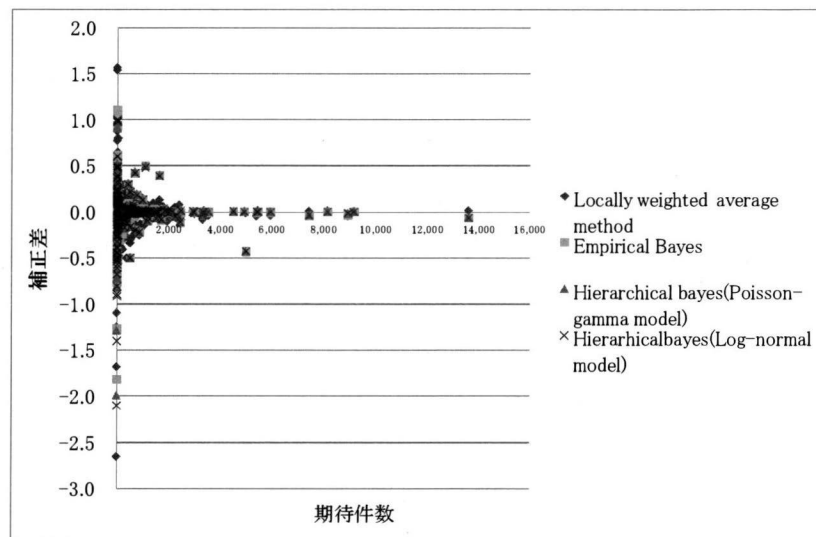


図 16 すべてのデータ区分における期待件数と補正差

5.1.1.3. データ区分別にみた補正差の傾向

つぎに、図 17 と図 18 より、データ区分別に補正差と期待件数の関係を確認した。全体の傾向と同様、すべてのデータ区分において期待件数が小さいほど、補正差が大きくなっていることがわかる。高血圧、0-39 歳高血圧、40-49 歳高血圧、50-59 歳高血圧の 4つのデータ区分では、補正差のばらつきが大きく生じると同時に、0.5 以上の補正差を伴った指数が複数存在している。

反対に、男性高血圧、女性高血圧、60-69 歳高血圧、70 歳以上高血圧の 4つのデータ区分では、0.5 以上の補正差を 1つも生じていない。

個別に補正差と期待件数の関係をみてみると、高血圧のデータ区分では、期待件数が約 3,000 以下の範囲で補正差のばらつきが生じており、補正差のほとんどが 0.5 から -0.5 の範囲に収まっている。

男性高血圧のデータ区分では、期待件数が 1,000 以下の範囲で補正差がゼロから多少乖離している指数が確認できるが、すべての指数で補正差は絶対値で 0.5 以下となっており、あまり大き

な補正は全体としてなされていないことがわかる。

女性高血圧のデータ区分では、男性高血圧のデータ区分と同様に期待件数が約 1,000 以下の範囲で補正差のばらつきが生じている。ただし、補正差はすべて絶対値で 0.5 以下の範囲に収まっており、あまり補正がなされていないものといえる。

0-39 歳高血圧のデータ区分では、補正差の大きい指数が目立っており、補正差が 1.0 以上を示す指数が複数存在している。0-39 歳高血圧以外に、1.0 以上の補正差を複数生じたデータ区分は他になく、その他の区分では殆どの指数が絶対値で 0.5 以下の補正差に留まっている。0-39 歳高血圧のデータ区分では、殆どの指数が絶対値で 0.5 以上の補正差を生じさせている。

40-49 歳高血圧のデータ区分では、期待件数が 50 以下の範囲で補正差にばらつきが生じている。また、補正差が絶対値で 0.5 以上の指数も複数存在しており、0-39 歳高血圧について補正が大きくなされていることがわかる。

50-59 歳高血圧のデータ区分では、期待件数が 400 以下で補正差にばらつきが生じている。しかし、ほとんどの補正差は絶対値で 0.5 以下の範囲に収まっている。ただし、補正差が絶対値で 0.5 以上の指数もいくつか存在している。

60-69 歳高血圧のデータ区分では、期待件数が 1,000 以下の範囲で、補正差にばらつきが生じている。補正差のすべては絶対値で 0.5 以下の範囲に収まっており、あまり大きな補正はなされていない。

70 歳以上高血圧のデータ区分では、期待件数が 2,000 以下で補正差にばらつきが生じている。ただし、ほぼすべての指数は補正差が絶対値で 0.5 以下の範囲に収まっており、ほぼゼロに近い範囲に収まっていることもわかる。

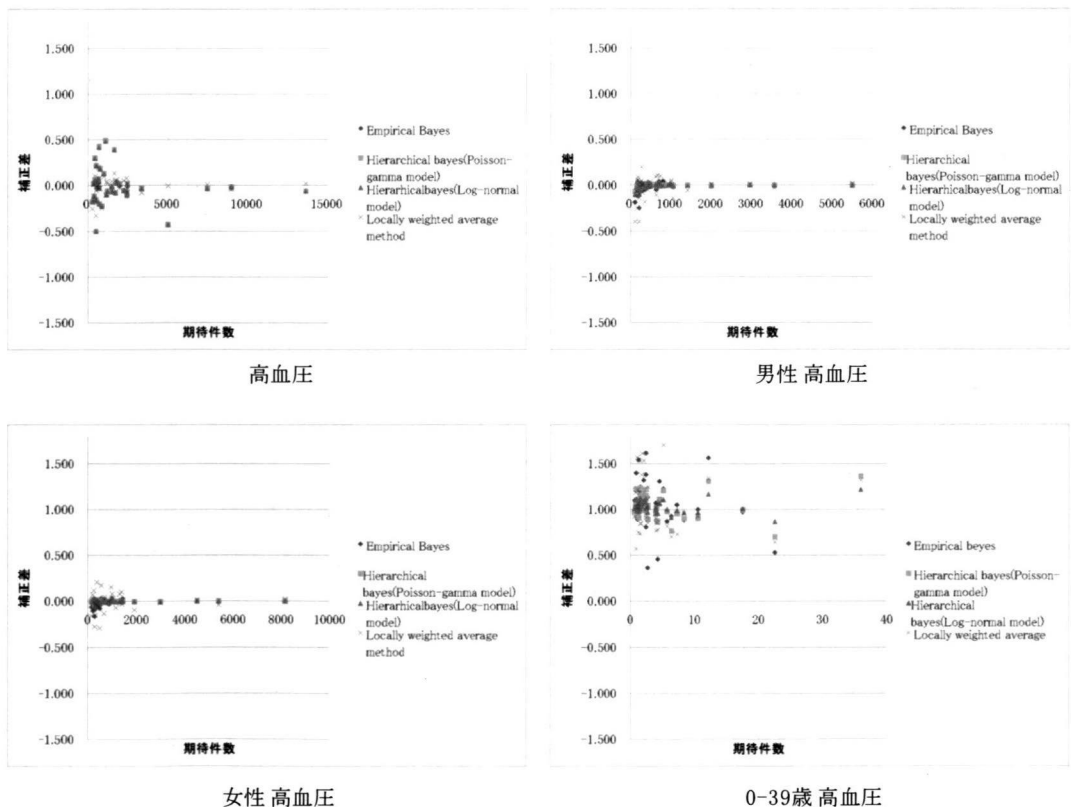


図 17 データ区分別の期待件数と補正差

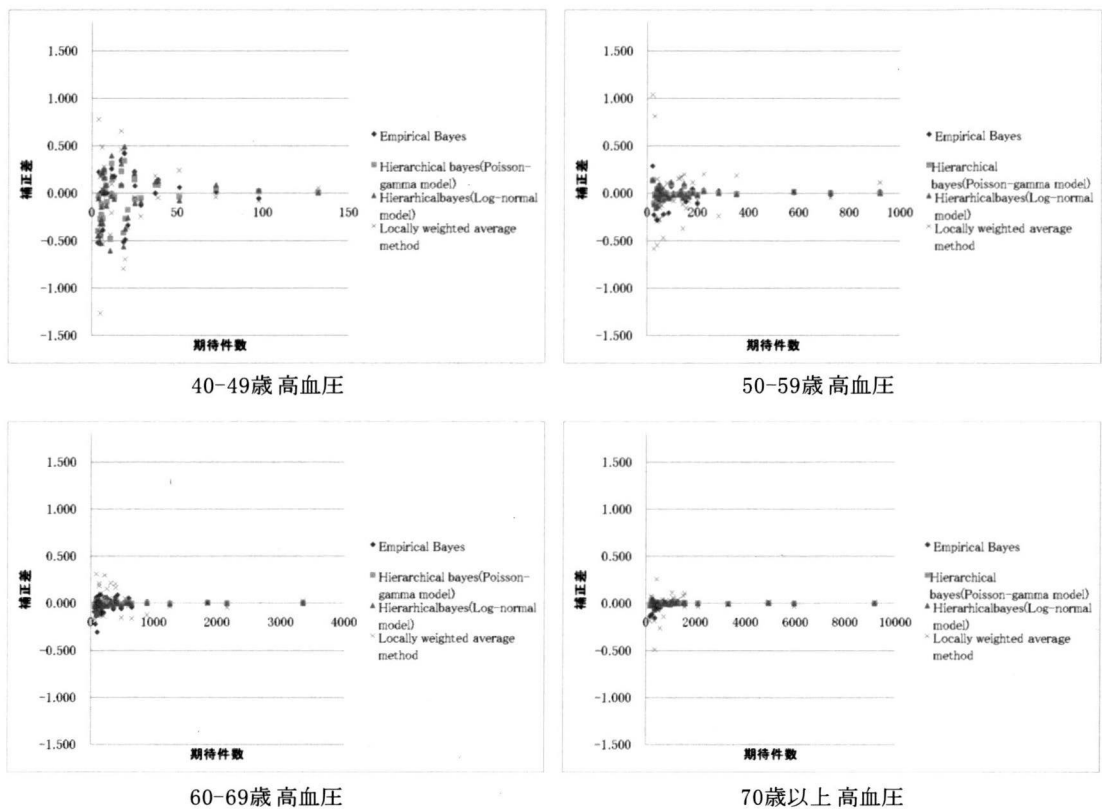


図 18 データ区分別の期待件数と補正差

図 19 は、データ区分別の補正差の標準偏差を示している。高血圧、0-39 歳高血圧、40-49 歳高血圧、50-59 歳高血圧の 4 つのデータ区分では、補正差の標準偏差がその他のデータ区分に比べ非常に大きな値となっている。特に 0-39 歳高血圧、40-49 歳高血圧、50-59 歳高血圧の 3 つのデータ区分の標準偏差は非常に大きな値を示しており、補正により指数の結果に差が生じているものといえる。

つぎに、補正差の標準偏差を手法別に比較すると、同じデータ区分においても異なった結果を示していることがわかる。たとえば、全体として大きな標準偏差を示している 0-39 歳高血圧、40-49 歳高血圧、60-69 歳高血圧においても、手法によってその値に差が生じている。特に、LWA とベイジアンによる 3 つの手法間では大きな差が生じている。LWA の標準偏差は、高血圧を除いてすべてのデータ区分で他の 3 つの手法よりも高い値を示しており、その差が大きい。データ区分によって、各種手法による補正の度合が変化するものといえる。

また、多くのデータ区分において、経験ベイズ法、階層ベイズ法(ポアソンガンマモデル)、階層ベイズ法(ポアソン対数正規モデル)による 3 つの結果は、比較的類似した傾向を示しているが、0-39 歳高血圧、40-49 歳高血圧のデータ区分では、経験ベイズ法と階層ベイズ法の間に差が生じていることがわかる。