

ベイズ的アプローチによる日本域における 地球温暖化に伴う地表気温上昇量の予測

PROJECTIONS OF SURFACE AIR TEMPERATURE CHANGE OVER JAPAN
DUE TO GLOBAL WARMING:
BAYESIAN APPROACH TO THE ANALYSIS OF MULTIMODEL ENSEMBLES

石崎安洋¹・仲江川敏之²・高藪出³

Yasuhiro ISHIZAKI, Toshiyuki NAKAEGAWA, Izuru TAKAYABU

¹正会員 工修 気象庁気象研究所 客員研究員 (〒305-0052 茨城県つくば市長峰1-1)

²正会員 工博 気象庁気象研究所 主任研究官 (〒305-0052 茨城県つくば市長峰1-1)

³非会員 理博 気象庁気象研究所 主任研究官 (〒305-0052 茨城県つくば市長峰1-1)

A Bayesian approach is applied to project surface air temperature (SAT) changes over Japan using available simulations from the Intergovernmental Panel on Climate Change fourth assessment report. The Bayesian model averaging (BMA) can produce projections constrained by observations and weighted probability density functions (PDFs). We project annual mean and seasonal mean (winter and summer) SAT changes using the BMA and the arithmetic ensemble mean (AEM) and investigate the difference between the two methods. Additionally, we investigate the sensitivity of training period to the PDFs produced by BMA and the influences of long-term and short-term variations on them. These results indicate that the annual mean SAT change projected by BMA is significantly different from that projected by AEM and that BMA is sensitive to training periods and short-term variations.

Key Words : Probabilistic climate change projection, Bayesian approach, Multi-model Ensembles, Surface air temperature change

1. はじめに

人為的な温室効果ガスの排出による将来の地球温暖化に関し、気候モデルを用いた予測研究が活発に行われている。この気候モデルを用いた将来の気候変動の予測は、排出シナリオ、気候モデルの構造、気候の内部変動に起因する不確実性を伴い^{1) 2)}、これらの不確実性を特定し、地域規模での確率的な情報を提供することが、将来の気候変動による影響評価の際に重要となっている^{3) 4)}。

これまで、これらの不確実性は複数の気候モデルを用いたマルチモデルアンサンブルにより特定され、各モデルに均一の重みを与える手法 (arithmetic ensemble mean, 以後AEM) が用いられてきた。一方、近年では、ベイズ統計学に基づく観測値の再現性による重みづけによる手法 (bayesian model average, 以後BMA) により将来予測を行う研究が注目を集めている^{5) 6) 7) 8) 9) 10)}。このBMAを用いた既存の将来予測研究は、全球や東アジア全域など広域な空間スケールでは行われているが、日本の将来

予測にはまだ適用されていない。

そこで、本研究ではCoupled Model Intercomparison Project(CMIP)3に参加した大気・海洋結合モデルの結果から、AEMとBMAを用いて、将来の日本における地表気温の上昇量について予測し、両手法による予測の違いを調べた。本研究では、まず、1900年から1999年の評価期間における地表気温偏差の平均値とトレンドで各モデルを評価し、年平均、夏季、冬季の昇温量の将来予測を行った。次に重みを作成する評価期間の違いや重みを作成する際、長期変動や短期変動を考慮した場合、将来予測にどのような違いがあるのかを調べた。

2. 使用したモデルとデータ

研究で用いたモデルは、CMIP3で提供されている大気・海洋結合モデルのうち、20世紀再現実験(20C3M)とSRES A1Bシナリオ実験を行っている23個のモデルである。本研究では、便宜的に各モデルに番号をつけ、モデル番号で表記している。23個のモデル番号とモデル

表-1 モデル番号とモデル名.

番号	モデル名	番号	モデル名	番号	モデル名
1	BCCR_BCM2_0	9	GISS_MODEL_EH	17	MIUB_ECHO_G
2	CCCMA_CGCM3.1	10	GISS_MODEL_ER	18	MPI_ECHAM5
3	CCCMA_CGCM3.1_1_t63	11	IAP_FGOALS1_0_g	19	MRI_CGCM3.2.2a
4	CSIRO_mk3_0	12	INGV_ECHAM4	20	NCAR_CCSM3_0
5	CSIRO_mk5_5	13	INMCM3_0	21	NCAR_PCM1
6	GFDL_CM2_0	14	IPSL_CM4	22	UKMO_HadCM3
7	GFDL_CM2_1	15	MIROC3.2(hires)	23	UKMO_HadGEM1
8	GISS_AOM	16	MIROC3.2(medres)		

名を表-1に示す. 観測値にはClimatic Research Unit¹¹⁾(CRU)が提供しているデータを用いた. 解析にはモデル, 観測ともに日本の全陸上域で領域平均した値を用いている. モデルスキルの評価には, 1900年から1999年の100年間を用いた. 評価期間の違いを調べる際には, この100年間に加えて, 1900年から1949年の50年間 (BMA1;20世紀前半), 1950年から1999年の50年間 (BMA2;20世紀後半)の2つの期間を調べている. 各モデルを評価する際, 使用する観測, モデルのデータは1900年から1919年の平均値からの偏差を用いた. 将来の推定では2080年から2099年の20年間を対象とし, 1980年から1999年の平均値からの偏差を用いた.

本研究では, 観測データとモデルデータをルジャンドル級数展開している. ルジャンドル級数展開を用いる利点は次の3つである. 第1の利点は, ベイズの定理における尤度を求める際, 直交級数展開を用いることで, 多次元の正規分布における共分散行列が特異行列になるのを避けることができることである. 第2の利点は, 直交級数展開の中でもルジャンドル級数展開は1次の係数をトレンドと解釈でき, トレンドを考慮したモデルスキルの評価が可能であることである. 第3の利点は, 次数の低いルジャンドル係数のみを扱うことで, 気候の内部変動の寄与が大きい成分を除いて気候モデルを評価することができることである. 本研究では, モデルのスキル評価は平均値 (0次) とトレンド (1次) で行っているが, 長期変動と短期変動を考慮した場合の予測の違いを調べる際には, 長期変動だけ考慮した予測には, 0次から4次までのルジャンドル係数を用い (BMAa), 短期変動まで考慮した予測には, 0次から12次までのルジャンドル係数を用いている (BMAb).

3. 手法

(1) ベイズ的アプローチによる将来推定

N個のモデル $m_i(i=1, \dots, N)$, 観測データ d が与えられている時, 観測データ d に対してモデルデータ m_i がどれくらいもっとうもらしいかという条件付き確率を $P(m_i|d)$ とする. ベイズの定理では, この確率は観測データを与えたときに得られるモデルの事後確率と考えることができ,

この確率は主観的な確信に基づく事前確率 $P(m_i)$ とモデルが与えられたときに観測データの確率分布を特徴づける尤度関数 $L(d|m_i)$ とで次のように表される.

$$P(m_i|d) = \frac{L(d|m_i)P(m_i)}{\sum_{j=1}^N L(d|m_j)P(m_j)} \quad (1)$$

Kass and Raftery¹²⁾によれば, この事後確率は各モデルにおける観測の制約を与えた重みと解釈できる. 一方, 尤度関数 $L(d|m_i)$ は, モデルデータ m_i と観測データ d が多次元正規分布であると仮定すると,

$$L(d|m_i) = \frac{1}{\sqrt{(2\pi)^q}} \sqrt{\frac{\det A_i^{-1}}{\det \Sigma_i \det \Sigma_0}} \exp\left(-\frac{1}{2} \Lambda_i\right) \quad (2)$$

と表すことができる^{13) 14)}. ここで, q は観測データ d の次元, Σ_0 と Σ_i は各々観測データとモデルデータの共分散行列, A_i はこの二つの行列の和で,

$$A_i = \Sigma_i^{-1} + \Sigma_0^{-1} \quad (3)$$

である. また, Λ_i は観測データ d とモデル m_i との間の一般化された距離 (マハラノビス距離) で,

$$\Lambda_i = (d - m_i)^T (\Sigma_0^{-1} + \Sigma_i^{-1}) (d - m_i) \quad (4)$$

と表わされる. 本研究では, 尤度を求める際に必要な観測, モデルの共分散行列については20世紀再現実験における23モデルの値で代用している.

(2) ベイズ因子

ベイズ因子 (B_{ip}) は観測に対するモデルの信頼性を示し, 事後オッズを事前オッズで割った比である. 本研究では事前確率をすべて等確率と仮定しており, 尤度比として表される.

$$B_{ip} = L(d|m_i)/L(d|m_r) \quad (5)$$

ここで, m_r は参照モデルデータであり, ここでは, 観測と同じ値を用いている. Kass and Raftery¹²⁾はベイズ因子の解釈を表-2のように提案している.

表-2 ベイズ因子の解釈.

ベイズ因子	1-0.33	0.33-0.083	0.083-0.0067	< 0.0067
スキル	とても良い	良い	悪い	とても悪い

(3) 各モデルの重みと推定量

AEMは各モデルに均一の重みを与える手法であるので、各モデルの重み w_k は、

$$w_k = 1/N \quad (6)$$

として求める。また、BMAにおける重みは、式(1)で求めた事後確率を用いる。既に述べたように、事前確率は等確率と仮定しているため、重み w_k は、式(5)より、

$$w_k = L(d|m_k) / \sum_{i=1}^N L(d|m_i) \quad (7)$$

として求める。

この重み w_k を用いて将来の推定量 $p(y|m_1, \dots, m_N, y^T)$ は、

$$p(y|m_1, \dots, m_N, y^T) = \sum_{k=1}^N w_k g_k(y|\mu_k, \sigma_k^2) \quad (8)$$

として求める。ここで μ_k, σ_k^2 は各モデルデータの将来の平均値と分散であり、 g_k は正規分布、 y^T は各評価期間における訓練データを表す。

4. 結果

(1) 年平均、夏季と冬季における将来の昇温量

図-1は年平均、夏季、冬季の各モデルと観測、AEM、BMAの0次(横軸)と1次(縦軸)のルジャンドル係数である。夏季には6月から8月の平均値を用い、冬季には1

2月から2月の平均値を用いている。観測により重みづけされているので、年平均、夏季、冬季いずれもAEMよりBMAの方が観測値に近く、観測をよく再現している。ただし、個々のモデルと比べると、BMAが最も再現が良いというわけではなく、いくつかのモデルはBMAよりも再現性が良い。全般的に、冬季では再現の良いモデルが多いが、夏季では再現の悪いモデルが多い。

図-2(a)に各モデルのベイズ因子を示す。図1で示したように、冬季で再現の良いモデルが多く、表-2に示したKass and Rafteryの提唱するベイズ因子の解釈に従えば、“とても良い”と評価されたモデルは4モデル存在する(モデル番号2, 8, 22, 23)。一方、年平均では“とても良い”と評価されたモデルは1モデル(モデル番号2)だけであり、また、夏季でも“とても良い”と評価されたモデルは1モデル(モデル番号2)だけであった。全般的に、モデルによって、年平均、夏季、冬季のスキルは必ずしも一致していないことがわかる。

図-2(b)に各モデルの重みを示す。重みの全般的な傾向は、ベイズ因子とそれほど違はないが、冬季は再現の良いモデルが多く、年平均や夏季と比べてスキルの高いモデルにもそれほど大きな重みは付いておらず、0.1程度の重みである。一方、年平均や夏季では冬季と比べると、全般的にモデルのスキルが低かったため、冬季と比べ、スキルの低いモデルにも、比較的大きな重みが付いている。




図-1 0次と1次のルジャンドル係数。(a) 年平均、(b) 夏季、(c) 冬季。

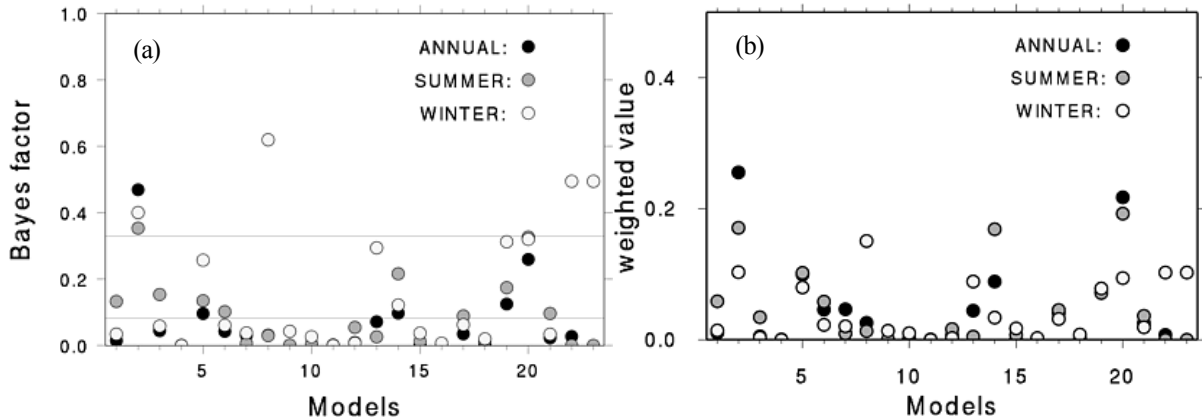


図-2 各モデルのベイズ因子と重み。(a) ベイズ因子、(b) 重み。(a) 中の横線は表-2のベイズ因子の解釈である。




図-3 将来 (2080年~2099年) の地表気温上昇量. (a) 年平均, (b) 夏季, (c) 冬季.

表-3 年平均, 夏季, 冬季におけるAEMとBMAの平均値, 最頻値, 5パーセンタイル値, 95パーセンタイル値.

	平均値	最頻値	5パーセンタイル値	95パーセンタイル値
AEM(年平均)	3.1K	2.5K	2.0K	4.7K
BMA(年平均)	2.9K	2.5K	2.2K	4.2K
AEM(夏季)	2.9K	2.2K	1.6K	4.7K
BMA(夏季)	2.8K	2.2K	1.8K	4.3K
AEM(冬季)	3.4K	2.8K	2.0K	5.2K
BMA(冬季)	3.3K	2.8K	2.3K	4.8K

図-3に年平均と夏季, 冬季についてAEMと図-2 (b)の重みにより作成されたBMAの2手法による地表気温上昇量を示す. 年平均では, 重みの大きかった2つのモデルによる地表気温上昇量の平均値の予測が 2.5Kと2.6Kであった. このため, BMAによる将来予測では2.5K付近に高いピークが現われている. 一方, 夏季や冬季においては, 年平均ほど, AEMとBMAの間には顕著な違いが見られなかった. これは, 夏季と冬季において, 重みのついたモデルの将来予測が幅広くばらついていたため, AEMと比較的類似した結果になっている.

表-3に年平均, 夏季, 冬季におけるAEMとBMAの平均値, 最頻値, 5パーセンタイル値, 95パーセンタイル値を示す. 平均値と最頻値はAEMとBMAではそれほど違いは見られないが, 5パーセンタイル値から95パーセンタイル値の間の幅は, 年平均, 夏季, 冬季ともにBMAの方が縮小している.

(2) 評価期間が異なる場合

図-4に評価期間が20世紀前半(BMA1)と20世紀後半(BMA2)における各モデル, 観測, AEM, BMA, BMA1, BMA2の0次 (横軸) と1次 (縦軸) のルジャンドル係数を示す. BMA, BMA1, BMA2の値は, (a)と(b)で異なる. これは, BMA, BMA1, BMA2の重みは(a)と(b)で同じ値を用いているが, それぞれの期間で各モデルのルジャンドル係数が異なるからである. 両期間においてAEMよりもBMA, BMA1, BMA2の方が観測をよく再現している. 一方, 評価期間を入れ替えたBMA, つまり, 図-4(a)におけるBMA2および, 図-4(b)におけるBMA1は, AEM

よりも再現は良いが, それぞれの評価期間で重みが作成されたBMA, つまり, 図-4(a)におけるBMA1および, 図-4(b)におけるBMA2より再現性が悪い. 図-5に評価期間が1900年から1999年の100年間(BMA), 評価期間が20世紀前半(BMA1)と20世紀後半(BMA2)のベイズ因子を示す. 図からわかるように, 各モデルのスキルは評価期間で大きく異なることがわかる.

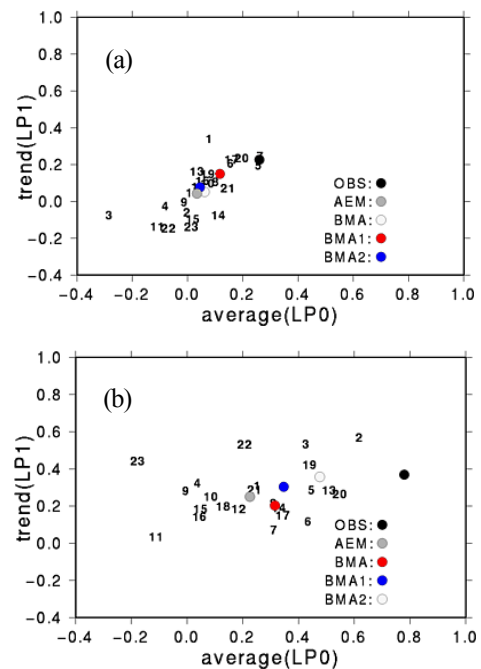


図-4 0次と1次のルジャンドル係数. (a) 20世紀前半, (b) 20世紀後半.

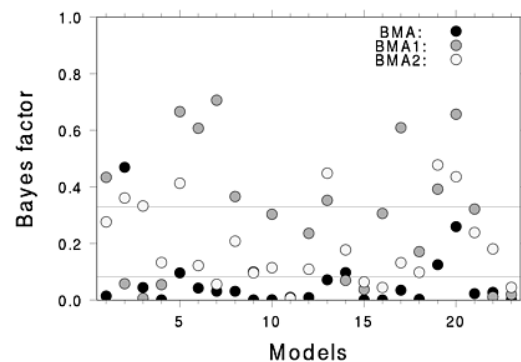


図-5 異なる評価期間での各モデルのベイズ因子.

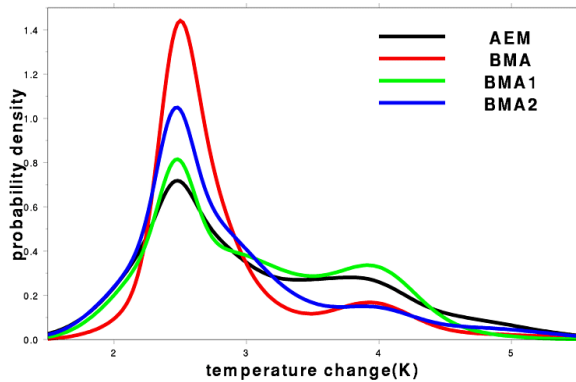


図-6 BMA, BMA1, BMA2, AEMによる将来 (2080年~2099年)の地表気温上昇量の確率密度分布。

図-6にBMA, BMA1, BMA2とAEMによる将来の地表気温上昇量を示す。BMA1による地表気温の上昇量の予測は、重みがついたモデルの平均値の予測が2.6K, 3.0K, 3.3K, 3.8K, 4.0Kとばらついているため、比較的幅広く予測している。一方、BMA2による予測は、重みがついたモデルの平均値の予測が2.6Kあたりで、BMAと同じように最頻値が2.6Kあたりになっている。

(3) 長期変動・短期変動を考慮した場合

図-7に観測, AEM, 0次から1次(BMA), 0次から4次(BMAa), 0次から12次(BMAb)まで考慮したそれぞれのルジャンドル係数を示す。BMA, BMAa, BMAbは0次や1次のルジャンドル係数で特にAEMより観測をよく再現している。また、BMAbはAEMでは再現できていない7次のルジャンドル係数をAEMより再現している。それ以外の次数ではAEMとそれほど変わらないが、全般的にBMAはAEMと比べて観測をよく再現している。図-8にBMA, BMAa, BMAbのベイズ因子を示す。BMAでは、‘とても良い’と判断されたモデルが1つあり、‘良い’と判断されたモデルも4個存在したが、BMAa, BMAbではモデルはすべて‘非常に悪い’と判断されており、長期変動, 短期変動まで再現の良いモデルは存在しないことがわかる。図-9にBMA, BMAa, BMAbより予測される将来の地表気温上昇量を示す。BMAaの確率密度の分布はBMAと比較的類似している。これはBMAaで重みがついたモデルの地表気温の上昇量とBMAで重みがついたモデルの昇温量が類似しているためである。一方、BMAbでは、モデル番号8のモデルに0.96という圧倒的な重みがついたため、ほぼ、この1つのモデルで予測している。このため、BMA, BMAaと比べると最頻値の確率密度が高く、予測の幅も小さい。

5. まとめ

WCRP CMIP3により提供されている23個の大气・海洋結合モデルのスキルをベイズ因子で評価し、21世紀後半の日本の地表気温上昇量をAEM, BMAで予測した。

本研究では、まず、年平均や夏季, 冬季でAEMとBMA両手法で将来予測にどのような違いがあるのかを調べた。次に、重みを作成する際の評価期間の違いと長期変動と短期変動を考慮した場合により将来予測にどのような違いがあるのかを調べた。年平均や夏季, 冬季による予測の違いについては、冬季のスキルが良くても年平均や夏季のスキルが悪いモデルが存在し、年平均と各季節では、モデルのスキルは異なっていた。この結果、AEMとBMAによる予測についても、年平均と各季節では予測が異なっていた。従って、季節が重要となる農業生産の将来予測などを行う場合、年平均ではなく各季節に基づ

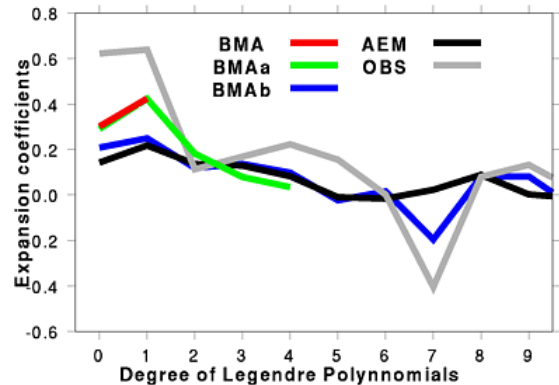


図-7 考慮するルジャンドル級数の次数を変化させて得られたマルチモデルアンサンブル平均のルジャンドル係数。

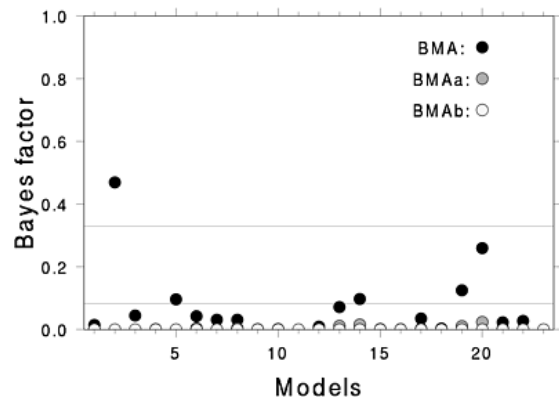


図-8 考慮するルジャンドル級数の次数を変化させた各モデルのベイズ因子。横線は表-2のベイズ因子の解釈。

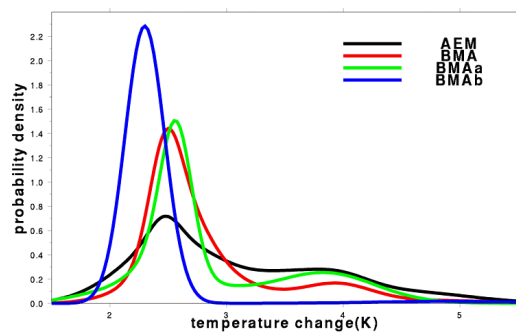


図-9 考慮するルジャンドル級数の次数を変化させたマルチモデルアンサンブル平均による将来の地表気温上昇量の確率密度分布。

いた重み付けが必要であることを示唆している。また、評価期間が異なる場合を調べたところ、20世紀の100年間、1900年から1949年の50年間、1950年から1999年の50年間でそれぞれモデルのスキルが異なっており、将来の予測についても、評価期間を1900年から1949年の50年間を用いた場合に、特に違いがみられた。また、長期変動を考慮した場合は、将来予測にはそれほど大きな違いは見られなかったが、短期変動まで考慮した場合には、将来予測に大きな違いが見られた。ただし、長期変動と短期変動を考慮した場合、すべてのモデルでスキルが悪く、その予測の信頼性は低い。

このように、BMAは”現在の再現性の良いモデルが将来も再現性が良い”という条件のもとに将来予測が可能である。ただし、年平均と各季節、評価期間の違い、長期変動、短期変動を考慮した場合で、モデルのスキルが異が異なり、その結果、将来予測も異なり注意が必要である。また、本研究では大気・海洋結合モデルの出力を用いたが、BMAは水文モデルや農業の影響評価モデルなどにも適用が可能であり、BMAを用いて、将来の温暖化の影響評価に関して重要な情報が得られる可能性がある。また、他の研究^{7) 8) 10) 15)}では、同じベイズ的アプローチでも、手法の違いや尤度の評価の仕方の違いにより、将来予測に違いが生じることが報告されている。また、ベイズ的アプローチ以外にも最適指紋法¹⁶⁾が将来予測に用いられており、この最適指紋法とベイズ的アプローチでも将来予測が大きく異なることが報告されている¹⁷⁾。今後は各手法にどのような特徴があるのかを調べていく必要がある。また、気候モデルの信頼性を評価する際、どのような指標を用いればよいのかといった議論も活発に行われており¹⁸⁾、信頼性の高い将来予測のためにも、気候モデルの信頼性に関する指標について今後詳しく議論していく必要がある。

謝辞：本研究の一部は環境省の地球環境研究総合推進費（S-5-3）および文部科学省21世紀気候変動予測革新プログラムの支援により実施された。

参考文献

- 1) Giorgi, F. and Francisco, R.: Evaluating Uncertainties in the Prediction of Regional Climate Change, *Geophys. Res. Lett.*, Vol. 27, pp.1295-1298, 2000.
- 2) Christensen, J. H., Räisänen, J., Iversen T., Bjørge D., Christensen, O. B. and Rummukainen, M.: A synthesis of regional climate change simulations - A Scandinavian perspective. *Geophys. Res. Lett.*, Vol. 28, pp. 1003-1006, 2001.
- 3) 東博紀・大楽浩司・松浦知徳：地球温暖化による豪雨発生頻度の変化と洪水氾濫への影響評価，水工学論文集，第 50 巻，pp. 205-210, 2006.
- 4) 大楽浩司・江守正多：高解像度全球気候モデルによる地球温暖化時の夏季アジアモンスーン，水工学論文集，第 50 巻，pp.547-552, 2006.
- 5) Tebaldi, C., Smith, R. L., Nychka, D. and Mearns, L. O.: Quantifying uncertainty in projections of regional climate change: a Bayesian approach to the analysis of multimodel ensembles. *J. Clim.*, Vol.18, pp. 1524–1540, 2005.
- 6) Tebaldi, C., Mearns, L., Nychka, D. and Smith, R.: Regional probabilities of precipitation change: a Bayesian analysis of multimodel simulations. *Geophys. Res. Lett.*, Vol.31, 2004.
- 7) Greene, A., Goddard, L. and Lall, U.: Probabilistic multimodel regional temperature change projections. *J. Clim.*, Vol. 19, pp. 4326–4343, 2006.
- 8) Furrer, R., Sain, S., Nychka, D. and Meehl, G.: Multivariate Bayesian analysis of atmosphere–ocean general circulation models. *Environ. Ecol. Stat.* Vol., 14, pp.249-266, 2007
- 9) Smith, R., Tebaldi, C., Nychka, D. and Mearns, L. Submitted.: Bayesian modeling of uncertainty in ensembles of climate models (in preparation).
- 10) Min, S. K., Simonis D., and Hense A.: Probabilistic climate change predictions applying Bayesian model averaging. *Phil. Trans R. Soc. A.*, Vol 365, pp. 2103–2116, 2007.
- 11) Jones, P. D. and Moberg, A.: Hemispheric and large-scale surface air temperature variations: an extensive revision and an update to 2001. *J. Clim.*, Vol.16, pp. 206–223, 2003.
- 12) Kass, R. E., and Raftery, A. E.: Bayes factors. *J. Am. Stat. Assoc.*, Vol. 90, pp.773– 795, 1995.
- 13) Min, S. K. and Hense, A.: A Bayesian assessment of climate change using multimodel ensembles. Part I: global mean surface temperature. *J. Clim.*, Vol. 19, pp. 3237–3256, 2006.
- 14) Min, S. K. and Hense, A.: A Bayesian assessment of climate change using multimodel ensembles. Part II: regional and seasonal mean surface temperatures. *J. Clim.*, Vol. 20, pp. 2769–2790, 2007.
- 15) Tebaldi, C. and Knutti, R.: The use of the multi-model ensemble in probabilistic climate projections. *Phil. Trans. R. Soc. A.*, Vol. 365, pp. 2053–2075, 2007.
- 16) Allen, M. R., and Stott, P. A.: Estimating signal amplitudes in optimal fingerprinting. Part I: Theory. *Climate Dyn.*, Vol. 21, pp.477–491, 2003.
- 17) Lopez, A., Tebaldi, C., New, M., Stainforth, D. A., Allen, M. R. and Kettleborough, J.: Two approaches to quantifying uncertainty in global temperature changes. *J. Clim.*, Vol. 19, pp. 4785–4796, 2006
- 18) Gleckler P. J., Taylor K. E., and Doutriaux C.: Performance metrics for climate models. *J. Geophys. Res.*, Vol. 113, 2008

(2008 . 9. 30受付)