

# Peut-on prévoir le climat du futur avec des statistiques ?

Aurélien Ribes  
CNRM - Météo-France and CNRS

Journées MAS, 29 Août 2016

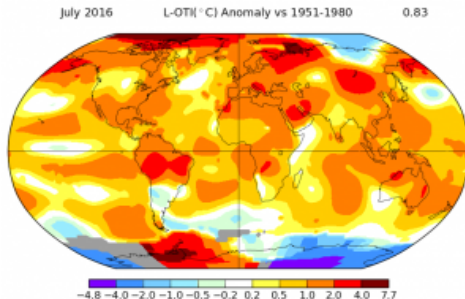


- 1 Introduction - Problématique
- 2 Modèles et inférence statistique
- 3 Problèmes et défis
- 4 Conclusion

# Introduction

16 août 2016

## Climat : juillet 2016 nouveau record



La série des mois records de chaleur planétaire s'est poursuivie en juillet. C'est ce qu'annonce l'équipe Nasa/Université Columbia de New York. Avec un écart à la moyenne calculée sur la période 1951/1980 de 0,83°C, juillet 2016 détient le nouveau record du mois.


La carte de ces écarts à la







# Problématique principale

Décrire le climat de demain, conditionnellement aux émissions de GES



# Problématique principale

Décrire le climat de demain, conditionnellement aux émissions de GES




## ● Notion de sensibilité climatique

# Problématique principale (2)


- Question posée identiquement pour d'autres variables, échelles, caractéristiques (e.g. événements extrêmes), etc.

## Température moyenne




## Extremes de précipitations

Daily precipitation 20-yr RV change per 1°C warming





# Approche historique : la modélisation



Source : IPSL

Les modèles reposent sur:

- équations physiques
- solutions numériques approchées des EDP (schémas numériques)

Résolution :


- spatiale (H)  $\sim 100$  km,
- spatiale (V)  $\sim 500$  m,
- temporelle  $\sim 15'$ .

Résultats :

- nombreux progrès dans la connaissance du CC,
- pas de convergence sur la sensibilité climatique depuis  $\sim 30$ ans.



# Alternative : les statistiques !

Alternative : étudier les 150 ans de données (observations) disponibles, avec des outils statistiques.



# Alternative : les statistiques !

Alternative : étudier les 150 ans de données (observations) disponibles, avec des outils statistiques.




Réchauffement (1951 – 2010) attribuable à différents forçages externes

Étude des tendances observées de toutes façons nécessaire pour vérifier les résultats des modèles.

# Comment distinguer GHG et OA ?

On utilise l'information disponible (modèles) sur leur distribution spatiale / temporelle


## Séries temporelles




Variations de température moyenne ;  
rouge:GHG, bleu:NAT, vert OA (i.e. autres anthropiques).

## Distributions spatiales

(c) GHG



(d) AER



Tendance de réchauffement 1851-2010

- 1 Introduction - Problématique
- 2 Modèles et inférence statistique
  - OLS
  - TLS
  - EIV
  - Alternative
- 3 Problèmes et défis
- 4 Conclusion

# Regression based models

$$Y_\ell = \sum_{i=1}^k \beta_i X_\ell^{(i)} + \varepsilon_\ell, \quad \text{Cov}(\varepsilon) = \Sigma,$$

$$\begin{array}{ccccccc} Y & = & X & \beta & + & \varepsilon, & \text{Cov}(\varepsilon) = \Sigma, \\ n \times 1 & & n \times k, & k \times 1 & & n \times 1 & n \times n \end{array}$$


- $\ell$ : location (space-time),
- $Y$ : observations (space-time vector),
- $\beta_i$ : scaling factor (scalar), unknown,
- $X^{(i)}$ : expected response to forcing  $i$  (space-time vector), known,
- $\varepsilon$ : internal variability (space-time vector),
- $\Sigma$ : IV covariance matrix (matrix).

# Regression based models


$$Y_\ell = \sum_{i=1}^k \beta_i X_\ell^{(i)} + \varepsilon_\ell, \quad \text{Cov}(\varepsilon) = \Sigma,$$

$$\begin{array}{ccccccc} Y & = & X & \beta & + & \varepsilon, & \text{Cov}(\varepsilon) = \Sigma, \\ n \times 1 & & n \times k, & k \times 1 & & n \times 1 & & n \times n \end{array}$$

X : simulations



Y : observations



# Regression based models

$$Y_\ell = \sum_{i=1}^k \beta_i X_\ell^{(i)} + \varepsilon_\ell, \quad \text{Cov}(\varepsilon) = \Sigma,$$

$$\begin{array}{ccccccc} Y & = & X & \beta & + & \varepsilon, & \text{Cov}(\varepsilon) = \Sigma, \\ n \times 1 & & n \times k, & k \times 1 & & n \times 1 & n \times n \end{array}$$

## General philosophy

- The space-time pattern of the response to each forcing is known (eg GHG, AER),
- We have some uncertainty on the magnitude of the response (eg a factor 3 on climate sensitivity),
- So, based on the pattern, we want to estimate the amplitude of each response, from observations.



# OLS

Philosophy: The response patterns  $X$  are perfectly known.

$$Y = X\beta + \varepsilon, \quad \varepsilon \sim N(0, \Sigma), \quad (\Sigma \text{ known})$$

Likelihood ( $-2 \log$ -):  $\ell_{\text{OLS}}(\beta) = (Y - X\beta)' \Sigma^{-1} (Y - X\beta).$

## Inference

- If  $\Sigma$  known, then multiply by  $\Sigma^{-1/2}$  !
- $\hat{\beta} = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} Y \quad \sim N(\beta, (X' \Sigma^{-1} X)^{-1}),$
- The issue of how estimating  $\Sigma$  to efficiently approximate  $\hat{\beta}$  is uncommon.

- 1 Introduction - Problématique
- 2 Modèles et inférence statistique
  - OLS
  - **TLS**
  - EIV
  - Alternative
- 3 Problèmes et défis
  - Grande dimension
  - Modélisation de la variabilité interne
  - Estimation de grandes matrices de covariance
  - Estimer l'incertitude de modélisation
- 4 Conclusion

# TLS model (Allen & Stott, 2003)

Philosophy: Taking into account the internal variability within the climate simulations leading to  $X$ .

$$Y = X^* \beta + \varepsilon, \quad \varepsilon \sim N(0, \Sigma) \quad (1)$$

$$X = X^* + \varepsilon_X, \quad \varepsilon_X \sim N(0, \Sigma/n_X) \quad (2)$$

# TLS: model and likelihood

## TLS model

Regression equation

$$Y^* = X^* \beta$$

One observes

$$\begin{cases} X = X^* + \varepsilon_X, & \text{Cov}(\varepsilon_X) = \Sigma_X \\ Y = Y^* + \varepsilon_Y, & \text{Cov}(\varepsilon_Y) = \Sigma_Y. \end{cases}$$

$$\Sigma_X = \lambda \Sigma_Y.$$

# TLS: model and likelihood

## TLS model

Regression equation


$$Y^* = X^* \beta$$

One observes

$$\begin{cases} X = X^* + \varepsilon_X, & \text{Cov}(\varepsilon_X) = \Sigma_X \\ Y = Y^* + \varepsilon_Y, & \text{Cov}(\varepsilon_Y) = \Sigma_Y. \end{cases}$$

$$\Sigma_X = \lambda \Sigma_Y.$$

$$\ell_{\text{TLS}}(\beta, X^*) = (Y - X^* \beta)' \Sigma_Y^{-1} (Y - X^* \beta) + (X - X^*)' \Sigma_X^{-1} (X - X^*).$$



# TLS: model and likelihood

## TLS model

Regression equation

$$Y^* = X^* \beta$$

One observes

$$\begin{cases} X = X^* + \varepsilon_X, & \text{Cov}(\varepsilon_X) = \Sigma_X \\ Y = Y^* + \varepsilon_Y, & \text{Cov}(\varepsilon_Y) = \Sigma_Y. \end{cases}$$

$$\Sigma_X = \lambda \Sigma_Y.$$

$$\ell_{\text{TLS}}(\beta, X^*) = (Y - X^* \beta)' \Sigma_Y^{-1} (Y - X^* \beta) + (X - X^*)' \Sigma_X^{-1} (X - X^*).$$


$$\ell_{\text{TLS}}^c(\beta) = \frac{(Y - X\beta)' \Sigma^{-1} (Y - X\beta)}{1 + \beta^2} \quad (\text{assuming } \lambda = 1).$$

## Inference

- Estimation : MLE in closed form (SVD of  $[Y, X]$ ),
- CI : asymptotic - too low coverage probability.

# TLS: Likelihood

$$\ell_{\text{TLS}}^c(\beta) = \frac{(Y - X\beta)' \Sigma^{-1} (Y - X\beta)}{1 + \beta^2}. \quad (3)$$



If you assume the wrong model

- OLS is "the truth":  $\hat{\beta}_{\text{TLS}}$  is not optimal (too much variance),
- TLS is "the truth":  $\hat{\beta}_{\text{OLS}}$  is biased toward 0.

- 1 Introduction - Problématique
- 2 **Modèles et inférence statistique**
  - OLS
  - TLS
  - **EIV**
  - Alternative
- 3 Problèmes et défis
  - Grande dimension
  - Modélisation de la variabilité interne
  - Estimation de grandes matrices de covariance
  - Estimer l'incertitude de modélisation
- 4 Conclusion



# EIV model (Huntingford et al., 2006; Hannart et al., 2014)

Philosophy: Taking into account the modeling uncertainty (ie different climate models provide different patterns  $X$  or  $X^*$ ).

Regression equation  $Y^* = X^* \beta$

One observes 
$$\left\{ \begin{array}{l} Y = Y^* + \underbrace{\varepsilon_{Y,IV}}_{\varepsilon_Y} \\ X = X^* + \underbrace{\varepsilon_{X,IV}}_{\varepsilon_X} \end{array} \right.$$

With 
$$\left\{ \begin{array}{l} \text{Cov}(\varepsilon_Y) = \Sigma_Y = \Sigma_{IV}, \quad (\text{I.V.}) \\ \text{Cov}(\varepsilon_X) = \Sigma_X = \Sigma_{IV}, \quad (\text{I.V.}) \end{array} \right.$$

# EIV model (Huntingford et al., 2006; Hannart et al., 2014)

Philosophy: Taking into account the modeling uncertainty (ie different climate models provide different patterns  $X$  or  $X^*$ ).

Regression equation

$$Y^* = X^* \beta$$

One observes

$$\left\{ \begin{array}{l} Y = Y^* + \underbrace{\varepsilon_{Y,IV}}_{\varepsilon_Y} \\ X = X^* + \underbrace{\varepsilon_{X,IV} + \varepsilon_{Mod}}_{\varepsilon_X} \end{array} \right.$$

With

$$\left\{ \begin{array}{ll} \text{Cov}(\varepsilon_Y) = \Sigma_Y = \Sigma_{IV}, & \text{(I.V.)} \\ \text{Cov}(\varepsilon_X) = \Sigma_X = \Sigma_{IV} + \Sigma_{Mod}, & \text{(I.V. + Mod. Uncert.)} \end{array} \right.$$

# EIV model (Huntingford et al., 2006; Hannart et al., 2014)

Philosophy: Taking into account the modeling uncertainty (ie different climate models provide different patterns  $X$  or  $X^*$ ).

Regression equation

$$Y^* = X^* \beta$$

One observes

$$\left\{ \begin{array}{l} Y = Y^* + \underbrace{\varepsilon_{Y,IV} + \varepsilon_{Obs}}_{\varepsilon_Y} \\ X = X^* + \underbrace{\varepsilon_{X,IV} + \varepsilon_{Mod}}_{\varepsilon_X} \end{array} \right.$$

With

$$\left\{ \begin{array}{ll} \text{Cov}(\varepsilon_Y) = \Sigma_Y = \Sigma_{IV} + \Sigma_{Obs}, & (\text{I.V.} + \text{Obs. Uncert.}) \\ \text{Cov}(\varepsilon_X) = \Sigma_X = \Sigma_{IV} + \Sigma_{Mod}, & (\text{I.V.} + \text{Mod. Uncert.}) \end{array} \right.$$

# EIV model

Regression equation

$$Y^* = X^* \beta$$

Observations

$$\begin{cases} Y = Y^* + \varepsilon_Y, & \text{Cov}(\varepsilon_Y) = \Sigma_Y, \\ X = X^* + \varepsilon_X, & \text{Cov}(\varepsilon_X) = \Sigma_X. \end{cases}$$

$\Sigma_Y$  and  $\Sigma_X$  have no relationship.

# EIV: Likelihood

Regression equation

$$Y^* = X^* \beta$$

Observations

$$\begin{cases} Y = Y^* + \varepsilon_Y, & \text{Cov}(\varepsilon_Y) = \Sigma_Y, \\ X_i = X_i^* + \varepsilon_{X,i}, & \text{Cov}(\varepsilon_{X,i}) = \Sigma_{X,i}. \end{cases}$$

Assuming  $k = 1$ ,

$$l(\beta, X^*) = \text{cte} + (Y - X^* \beta)' \Sigma_Y^{-1} (Y - X^* \beta) + (X - X^*)' \Sigma_X^{-1} (X - X^*).$$

$$l_c(\beta) = \text{cte} + (Y - X \beta)' (\beta^2 \Sigma_X + \Sigma_Y)^{-1} (Y - X \beta).$$

**No explicit maximum (i.e. MLE) !**

# Estimation (Hannart et al., 2014)

Philosophy: maximize  $\ell(\beta, X^*)$  with a numerical algorithm (MLE).

## Estimation: algorithm

- 1. Fix  $\hat{\beta}^0$ ,
- 2i. Compute  $\hat{X}_i^* = \text{Argmax}_{X^*} \ell(\hat{\beta}^{i-1}, X^*)$ ,
- 3i. Compute  $\hat{\beta}_i = \text{Argmax}_{\beta} \ell(\beta, \hat{X}_i^*)$ ,
- 4. When convergence occurs, you have  $(\hat{\beta}, \hat{X}^*)$ .

Issue(s): may converge to a critical point or local maximum (not necessarily the global maximum, i.e. MLE).

## Confidence intervals

Use asymptotic property of MLE.

Issue(s): too low coverage probability (i.e.: too small CI).

- 1 Introduction - Problématique
- 2 Modèles et inférence statistique
  - OLS
  - TLS
  - EIV
  - **Alternative**
- 3 Problèmes et défis
  - Grande dimension
  - Modélisation de la variabilité interne
  - Estimation de grandes matrices de covariance
  - Estimer l'incertitude de modélisation
- 4 Conclusion

# Motivation: Is linear regression suitable?

$$Y = \sum_{i=1}^k \beta_i X_i + \varepsilon$$

- Assumes that
  - models are able to simulate response patterns,
  - response magnitudes are unknown.



# Motivation: Is linear regression suitable?

$$Y = \sum_{i=1}^k \beta_i X_i + \varepsilon$$

- Assumes that
  - models are able to simulate response patterns,
  - response magnitudes are unknown.
- The reality is probably more balanced

# A new possible approach (Ribes et al., 2016)

$$\begin{cases} Y = Y^* + \varepsilon_Y, & \varepsilon_Y \sim N(0, \Sigma_Y), \\ X_i = X_i^* + \varepsilon_{X_i}, & \varepsilon_{X_i} \sim N(0, \Sigma_{X_i}), \quad i = 1, \dots, k, \end{cases}$$

# A new possible approach (Ribes et al., 2016)

$$Y^* = \sum_{i=1}^k X_i^*,$$

$$\begin{cases} Y = Y^* + \varepsilon_Y, & \varepsilon_Y \sim N(0, \Sigma_Y), \\ X_i = X_i^* + \varepsilon_{X_i}, & \varepsilon_{X_i} \sim N(0, \Sigma_{X_i}), \quad i = 1, \dots, k, \end{cases}$$

# A new possible approach (Ribes et al., 2016)

$$Y^* = \sum_{i=1}^k X_i^*,$$

$$\begin{cases} Y = Y^* + \varepsilon_Y, & \varepsilon_Y \sim N(0, \Sigma_Y), \\ X_i = X_i^* + \varepsilon_{X_i}, & \varepsilon_{X_i} \sim N(0, \Sigma_{X_i}), \quad i = 1, \dots, k, \end{cases}$$

- Interpretation: models give information on each term  $X_i^*$ , then an additional constraint on their sum comes from observations.
- Bayesian perspective:
  - Prior on each  $X_i^*$ , derived from models,
  - Posterior after constraining the sum by observations.
- All inference can be made with maximum likelihood

$$\widehat{X}_i^* = X_i + \Sigma_{X_i}(\Sigma_Y + \Sigma_X)^{-1}(Y - X) \sim N(X_i, \Sigma_{\widehat{X}_i^*}).$$

- 1 Introduction - Problématique
- 2 Modèles et inférence statistique
- 3 Problèmes et défis**
  - Grande dimension
  - Modélisation de la variabilité interne
  - Estimation de grandes matrices de covariance
  - Estimer l'incertitude de modélisation
- 4 Conclusion

# Grande dimension des données

## Jeu de donnée climatique typique (e.g. temperature de surface)

- Dimension spatiale :  $5^{\circ} \times 5^{\circ} \sim 2600$  points de grille,
- Dimension temporelle : 50 - 100 ans (periode instrumentale),
- Dimension de  $Y \sim 10^5$ .
- Autre possibilités : cycle annuel, cycle diurne, autres variables...

# Grande dimension des données

## Jeu de donnée climatique typique (e.g. temperature de surface)

- Dimension spatiale :  $5^{\circ} \times 5^{\circ} \sim 2600$  points de grille,
- Dimension temporelle : 50 - 100 ans (periode instrumentale),
- Dimension de  $Y \sim 10^5$ .
- Autre possibilités : cycle annuel, cycle diurne, autres variables...

Cycle annuel, cycle diurne, autres variables...

# Grande dimension des données

## Jeu de donnée climatique typique (e.g. temperature de surface)

- Dimension spatiale :  $5^{\circ} \times 5^{\circ} \sim 2600$  points de grille,
- Dimension temporelle : 50 - 100 ans (periode instrumentale),
- Dimension de  $Y \sim 10^5$ .
- Autre possibilités : cycle annuel, cycle diurne, autres variables...

Cycle annuel, cycle diurne, autres variables...

Question : quelle(s) variable(s) regarder, quelle période / région, etc ?



# Decreasing the dimension (or pre-processing)

Statistical investigation of climate at the global scale requires to reduce the spatio-temporal dimension of datasets.

- Decadal means,
- Projection on spherical harmonics (e.g. truncation T4,  $\sim$  spatial scales  $>$  5000 kms),
- Use of simple climate indices (global mean, land-sea contrast, inter-hemispheric contrast, annual cycle, etc).
- Projection on PCs,


This treatment is quite arbitrary and non optimal.

- 1 Introduction - Problématique
- 2 Modèles et inférence statistique
  - OLS
  - TLS
  - EIV
  - Alternative
- 3 **Problèmes et défis**
  - Grande dimension
  - **Modélisation de la variabilité interne**
  - Estimation de grandes matrices de covariance
  - Estimer l'incertitude de modélisation
- 4 Conclusion


# Comment modéliser la variabilité interne ?

Quelques illustrations de la variabilité interne :

Temporel



Spatial



# Comment modéliser la variabilité interne ?

Quelques illustrations de la variabilité interne :

## Variations du réseau d'observation

HadCRUT4      Ann. mean 1990:2010 - 1901:1920      glb. mean: 0.8C





Figure credit: National Center for Atmospheric Research, climateguide.ucar.edu (D. Schneider)



Observational coverage in the early 20th century.

Pas de modélisation statistique spatio-temporelle simple !

- 1 Introduction - Problématique
- 2 Modèles et inférence statistique
  - OLS
  - TLS
  - EIV
  - Alternative
- 3 Problèmes et défis**
  - Grande dimension
  - Modélisation de la variabilité interne
  - Estimation de grandes matrices de covariance**
  - Estimer l'incertitude de modélisation
- 4 Conclusion

# Problem statement

- Most inference methods assume that  $\Sigma$  is known.  
(and the full distribution of the internal variability  $\varepsilon$ ).
- Usually, climate models are used to derive a few realisations of  $\varepsilon$ , say  $\varepsilon_1, \dots, \varepsilon_p$ .
- The distribution, or at least,  $\Sigma = \text{Cov}(\varepsilon)$  is estimated from these.
- Optimal statistics requires to estimate  $\Sigma^{-1}$   
(eg  $\widehat{\beta}_{OLS} = (X' \Sigma^{-1} X)^{-1} X' \Sigma^{-1} Y$ ).

This is very challenging in high dimension.

# Estimation of $\Sigma$ in large dimension

Let us assume that  $\varepsilon_1, \dots, \varepsilon_p \sim N(0, \Sigma)$  are available for estimating  $\Sigma$  ( $n \times n$ ).

# Estimation of $\Sigma$ in large dimension

Let us assume that  $\varepsilon_1, \dots, \varepsilon_p \sim N(0, \Sigma)$  are available for estimating  $\Sigma$  ( $n \times n$ ).

What about  $\hat{\Sigma}$  ?

The sample estimate  $\hat{\Sigma}$  is a poor estimator of  $\Sigma$  in large dimension ( $n$  close to  $p$ ).




# Estimation of $\Sigma$ in large dimension

Let us assume that  $\varepsilon_1, \dots, \varepsilon_p \sim N(0, \Sigma)$  are available for estimating  $\Sigma$  ( $n \times n$ ).

What about  $\widehat{\Sigma}$  ?

The sample estimate  $\widehat{\Sigma}$  is a poor estimator of  $\Sigma$  in large dimension ( $n$  close to  $p$ ).

Illustration : case  $\Sigma = I$ , distribution of the eigenvalues of  $\widehat{\Sigma}$  when  $n, p \rightarrow \infty$  (Marčenko-Pastur distribution).



# Regularising $\Sigma$ (1)

## Principle

### Principle

We use an estimator of  $\Sigma$  such as

$$\tilde{\Sigma} = \gamma \hat{\Sigma} + \rho I.$$

# Regularising $\Sigma$ (1)

## Principe

### Principe

We use an estimator of  $\Sigma$  such as

$$\tilde{\Sigma} = \gamma \hat{\Sigma} + \rho I.$$

### LW estimate (Ledoit & Wolf, 2004)

- Introduction of estimators  $\hat{\gamma}, \hat{\rho}$  of  $\gamma, \rho$  to minimise the mean square error

$$E \left( \|\tilde{\Sigma} - \Sigma\|_{\mathcal{M}}^2 \right).$$

- $$\hat{\Sigma}_l = \hat{\gamma} \hat{\Sigma} + \hat{\rho} I.$$

# Regularising $\Sigma$ (1)

## Principe

### Principe

We use an estimator of  $\Sigma$  such as

$$\tilde{\Sigma} = \gamma \hat{\Sigma} + \rho I.$$

### LW estimate (Ledoit & Wolf, 2004)

- Introduction of estimators  $\hat{\gamma}, \hat{\rho}$  of  $\gamma, \rho$  to minimise the mean square error

$$E \left( \|\tilde{\Sigma} - \Sigma\|_{\mathcal{M}}^2 \right).$$

- $$\hat{\Sigma}_l = \hat{\gamma} \hat{\Sigma} + \hat{\rho} I.$$

### New estimator (Ribes et al., 2009)

$$\hat{\beta}_l = (X' \hat{\Sigma}_l^{-1} X)^{-1} X' \hat{\Sigma}_l^{-1} Y.$$

# Integrated Optimal Fingerprinting approach

- Regularization with a target  $\Delta \neq I$  (Hannart et Naveau, 2014, JMVA).

Use of a Bayesian prior:  $\Sigma \sim \mathcal{W}^{-1}(\Delta, \alpha)$  (centered on  $\Delta$ ),

Derive estimators  $\hat{\rho}_1, \hat{\rho}_2$  leading to  $\tilde{\Sigma}_\Delta = \hat{\rho}_1 \hat{\Sigma} + \hat{\rho}_2 \Delta$ .

- Estimation of  $\Sigma$  (and therefore  $\Sigma^{-1}$ ) and  $\beta$  in a joint statistical framework (Hannart, 2016, JClim).

Uncertainty on  $\Sigma$  is partly taken into account in the estimation and CI on  $\beta$ .

$$\hat{\beta}_\Delta = (X' \hat{\Sigma}_\Delta^{-1} X)^{-1} X' \hat{\Sigma}_\Delta^{-1} Y.$$

- 1 Introduction - Problématique
- 2 Modèles et inférence statistique
  - OLS
  - TLS
  - EIV
  - Alternative
- 3 Problèmes et défis**
  - Grande dimension
  - Modélisation de la variabilité interne
  - Estimation de grandes matrices de covariance
  - Estimer l'incertitude de modélisation**
- 4 Conclusion

# Estimer l'incertitude de modélisation

- Ensemble de modèles de taille limitée ( $\sim 30$ , contrainte sur la dimension),
- Modèles non-indépendants (développements communs), plutôt *Ensemble d'opportunité*,
- Modèles trop coûteux pour utiliser les techniques classiques de quantification de l'incertitude,
- Approche la plus répandue : considérer la dispersion des modèles,  
“models ( $m_i$ ) are stat. indistinguishable from the truth ( $m^*$ )”, i.e.

$$(m_i - m_j) \sim N(0, 2\Sigma_m), \quad (m_i - m^*) \sim N(0, 2\Sigma_m),$$

# Estimer l'incertitude de modélisation

- Ensemble de modèles de taille limitée ( $\sim 30$ , contrainte sur la dimension),
- Modèles non-indépendants (développements communs), plutôt *Ensemble d'opportunité*,
- Modèles trop coûteux pour utiliser les techniques classiques de quantification de l'incertitude,
- Approche la plus répandue : considérer la dispersion des modèles,

“models ( $m_i$ ) are stat. indistinguishable from the truth ( $m^*$ )”, i.e.

$$(m_i - m_j) \sim N(0, 2\Sigma_m), \quad (m_i - m^*) \sim N(0, 2\Sigma_m),$$

ou écrit différemment ( $\mu$ : espérance de la population des modèles)

$$(m_i - \mu) \sim N(0, \Sigma_m), \quad (\mu - m^*) \sim N(0, \Sigma_m)$$



- 1 Introduction - Problématique
- 2 Modèles et inférence statistique
- 3 Problèmes et défis
- 4 Conclusion**

# Conclusions

- Un grand nombre de modèles et méthodes statistiques utilisées en sciences du climat.
- De nombreux défis :
  - climat : estimation du réchauffement induit par les GES dans le passé,
  - stats : gestion de la grande dimension, modélisation spatio-temporelle, quantification d'incertitude / design.
- Cela ne concerne pas que la température moyenne globale.
- Autres interactions entre climat et statistiques, notamment théorie des valeurs extrêmes, attribution d'événements singuliers.