



**HAL**  
open science

# Modélisation des erreurs de prévision météorologique

François Bouttier

► **To cite this version:**

François Bouttier. Modélisation des erreurs de prévision météorologique. Météorologie. Institut National Polytechnique de Toulouse, 2014. tel-03360111

**HAL Id: tel-03360111**

**<https://hal.science/tel-03360111v1>**

Submitted on 7 Oct 2021

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

**HABILITATION A DIRIGER DES RECHERCHES**  
**Institut National Polytechnique de Toulouse**  
**soutenu le 16 janvier 2014 par François Bouttier**

jury:

- Sylvain Coquillat (président du jury), professeur des universités
- Rémy Baraille (rapporteur), ingénieur
- Jean-Pierre Chaboureau (rapporteur), physicien
- Olivier Talagrand (rapporteur), directeur de recherche du CNRS
- Anthony Weaver (examineur), chercheur senior, HDR

## Synthèse du projet scientifique:

# ***Modélisation des erreurs de prévision météorologique***

présenté en vue d'une habilitation à diriger des recherches

**François BOUTTIER - janvier 2014**

## **Table des matières**

|  |    |
|--|----|
| Remerciements.....   | 4  |
| Préambule.....   | 5  |
| Partie 1 : Introduction : principes de représentation des erreurs en modélisation numérique..... | 6  |
| 1.1. Analyse de données par interpolation statistique (ou BLUE).....                             | 6  |
| 1.2. Assimilation de données par filtre de Kalman.....   | 7  |
| 1.3. Assimilation variationnelle : méthodes 3D-Var et 4D-var.....                                | 8  |
| 1.4. Modélisation de covariances statiques de grande dimension.....                              | 9  |
| 1.5. Prévision et assimilation d'ensemble.....   | 12 |
| 1.5.1. Principes de la prévision d'ensemble.....   | 12 |
| 1.5.2. Assimilation d'ensemble.....  | 13 |
| Partie 2 : Etude des erreurs d'ébauche.....  | 15 |
| 2.1. Modèles statiques d'erreurs d'ébauche.....  | 15 |
| 2.1.1. Covariances d'ébauche 'Jb ' pour la prévision globale du CEPMMT.....                      | 15 |
| 2.1.2. Covariances d'ébauche pour la prévision régionale : le 3D-Var AROME.....                  | 18 |
| 2.1.3. Perspectives sur les covariances d'ébauche statiques.....                                 | 20 |
| 2.2. Etude de la variabilité des erreurs d'ébauche.....  | 22 |
| 2.2.1. Covariances du jour dans un modèle simplifié.....   | 22 |
| 2.2.2. Covariances du jour dans l'assimilation AROME opérationnelle.....                         | 24 |
| Partie 3 : Etude des erreurs de prévision.....   | 28 |
| 3.1. Etudes diagnostiques.....   | 28 |
| 3.1.1. Covariances d'erreur de prévision dans un modèle simplifié.....                           | 28 |
| 3.1.2. Suivi de prévisions d'objets météorologiques par traitement d'images.....                 | 29 |
| 3.1.3. Sensibilité des erreurs de prévision aux observations utilisées.....                      | 33 |
| 3.1.4. Bilan sur les études diagnostiques.....   | 38 |
| 3.2. Simulation des erreurs par prévision d'ensemble.....  | 40 |
| 3.2.1. Sensibilité des ensembles aux erreurs d'analyse.....                                      | 40 |
| 3.2.2. Sensibilité des ensembles aux erreurs de modélisation.....                                | 42 |
| 3.2.3. Sensibilité des ensembles au couplage de grande échelle.....                              | 44 |
| 3.3. Perspectives sur les erreurs de prévision.....  | 46 |
| Conclusion.....  | 49 |
| Références.....  | 52 |
| Publications personnelles à comité de lecture, mentionnées dans ce mémoire.....                  | 52 |
| Autres publications mentionnées dans ce mémoire.....   | 53 |
| Publications personnelles à comité de lecture, non mentionnées dans ce mémoire.....              | 56 |
| Glossaire.....   | 57 |



## Remerciements

Les travaux décrits ici s'étendent sur plus de 20 ans, ce sont donc des centaines de collègues qu'il faudrait remercier.

Les idées et les motivations principales sont venues de discussions avec Philippe Courtier, Tony Hollingsworth, Jean Pailleux, Andrew Lorenc, Olivier Talagrand, John Derber, Pierre Gauthier, Jan Barkmeijer, Jean-François Geleyn, Philippe Arbogast, Laurent Descamps, Véronique Ducrocq, Tim Palmer, Alain Joly, ainsi que des collaborations avec Florence Rabier, Mike Fisher, Jean-Noël Thépaut, Erik Andersson, Gérald Desrozières, Loïk Berre, Yann Seity, Laure Raynaud, Olivier Nuissier.

J'ai eu la chance de (co)encadrer des thésards et stagiaires de grande valeur, parmi lesquels Martin Ehrendorfer, Fabrice Veersé, Gwenaëlle Hello, Cécile Renaudie, Olivier Caumont, Thibaut Montmerle, Yann Michel, Pierre Brousseau, Jeff Beck, Etienne Chabot, certains sont devenus de précieux collègues.

La plupart des travaux ont été suscités par les programmes de R&D en prévision numérique du CEPMMT et du CNRM à Météo-France, je remercie particulièrement leurs directions passées et présentes pour leur soutien sur les stratégies proposées, qui étaient souvent coûteuses et difficiles à comprendre pour des non-initiés. Pour utiliser les lourds outils de l'assimilation et de la prévision d'ensemble, j'ai abondamment bénéficié de soutiens logistiques sans lesquels rien n'aurait été possible, je salue chaleureusement la gentillesse et la patience des équipes informatiques du CEPMMT, du CNRM et de la DSI, l'équipe GCO, Mats Hamrud, Jan Haseler, Ryad El Khatib, Carole Labadie, Jean Maziejewski, GMAP et GMME, et l'accueil de l'équipe MICADO. Et, bien sûr, ma famille.

## Préambule

On propose, dans ce projet de recherche, une exploration des erreurs de prévision météorologiques. L'imprécision des prévisions du temps est un sujet notoire de plaisanteries populaires. Il y a pourtant des informations précieuses dans son étude : loin d'être aléatoires, les erreurs de prévision nous renseignent sur les processus qui propagent l'information dans la machine atmosphérique. Sans cette propagation, on ne pourrait pas prévoir le temps à partir des observations incomplètes dont on dispose. La théorie de l'assimilation de données enseigne que la meilleure manière d'utiliser une observation météorologique pour préparer une prévision, est de la combiner avec une connaissance précise des erreurs du système que l'on veut modéliser. On explicitera cette idée dans les contextes du filtre de Kalman et de l'assimilation variationnelle, qui se sont révélés cruciaux ces dernières années pour améliorer les prévisions météorologiques et la connaissance du fonctionnement de l'atmosphère.

Les techniques de prévision d'ensemble permettent d'aller au-delà de l'amélioration des prévisions (qui est quelquefois illusoire), en estimant l'incertitude de ces prévisions, notamment pour appréhender les risques d'événements météorologiques dangereux. Comme on le verra, assimilation et prévision d'ensemble sont devenues un couple inséparable : d'une part, les méthodes d'assimilation modernes permettent d'estimer les incertitudes d'analyse, indispensables pour comprendre la prévisibilité de l'atmosphère à courte échéance. D'autre part, la prévision d'ensemble est pratiquement la seule méthode exploitable pour représenter la variabilité spatio-temporelle des erreurs, dans les grands systèmes d'assimilation utilisés en prévision opérationnelle du temps. Après avoir établi les limites des représentations statiques des covariances d'erreur en assimilation, on s'intéressera donc dans ce projet à l'amélioration des systèmes de prévision d'ensemble aux courtes échéances (échéances de quelques heures, qui comptent en assimilation de données). Comme une boîte de Pandore, cette exploration révèle une multiplicité de sources significatives d'erreurs : sur l'analyse, dans le sol, dans les équations du modèle de prévision... On s'efforcera d'en proposer une vision globale, avec l'ambition pour le futur de construire un système stochastique complet qui ne néglige aucun type d'erreur dans l'assimilation et la prévision.

Ces problématiques s'expliquent souvent avec de belles équations. Pour fascinantes qu'elles soient, leur étude peut facilement occulter les vrais problèmes, car ces équations sont pour la plupart numériquement trop coûteuses pour être utilisées telles quelles en prévision du temps : qu'il s'agisse du filtre de Kalman, de l'assimilation variationnelle, ou de la prévision d'ensemble, la vraie difficulté réside dans le dosage entre le degré de simplification des équations, et le réalisme physique des processus pris en compte. Chaque approximation effectuée dégrade le réalisme des calculs : pour obtenir de bons résultats, il faut donc savoir modéliser les processus physiques les plus importants pour la qualité des prévisions, et en négliger d'autres pour économiser les coûts de calcul. On ne trouvera donc ici, ni théorie sophistiquée, ni analyse pointue de processus physiques, mais seulement une stratégie pragmatique destinée à adapter au mieux les théories aux réalités de l'analyse et de la prévision météorologique modernes.

Ce mémoire est organisé comme suit : après un résumé des outils mathématiques utilisés (c'est à dire : assimilation par filtre de Kalman, assimilation variationnelle, et méthodes ensemblistes), on suivra la piste des erreurs dans les systèmes de prévision : d'abord dans l'assimilation de données, en allant de la représentation la plus simple des erreurs (le **Jb** statique) à la plus compliquée (le filtre de Kalman), puis la prévision, où, après avoir examiné quelques caractéristiques des erreurs de prévision, on introduira un système aussi complet que possible de prévision d'ensemble.

# Partie 1 : Introduction : principes de représentation des erreurs en modélisation numérique

## 1.1. Analyse de données par interpolation statistique (ou BLUE)

L'assimilation de données a pour objectif l'estimation du vecteur d'état  $\mathbf{x}$  d'un système à partir d'observations. Les techniques d'assimilation les plus répandues en météorologie sont fondées sur le théorème d'**analyse par interpolation statistique optimale** (ou BLUE : Best Linear Unbiased Estimate, cf Lorenc 1986, Lorenc 2003) :

Etant donnés, à un instant d'analyse  $t$ ,

$\mathbf{y}$  un vecteur de valeurs observées que l'on souhaite analyser,

$\mathbf{x}^b$  une *ébauche* a priori de l'état atmosphérique, disponible avant de connaître les observations  $\mathbf{y}$ . Dans un système d'assimilation séquentiel, comme par exemple en prévision du temps, on tirera  $\mathbf{x}^b$  d'une prévision récente valable à l'instant  $t$  :  $\mathbf{x}^b = \mathbf{M}(\mathbf{x}^{a-})$  où  $\mathbf{M}$  est l'intégration d'un modèle de prévision jusqu'à l'instant d'analyse, et  $\mathbf{x}^{a-}$  est une analyse récente,

$\mathbf{H}$  un *opérateur d'observation*, qui est une application de l'espace des états du modèle vers celui des valeurs observées, permettant de comparer observations et modèle. En particulier,  $\mathbf{y} - \mathbf{H}(\mathbf{x}^b)$  est le vecteur des écarts à l'ébauche, ou *innovations*.  $\mathbf{H}$  est habituellement constitué d'interpolations depuis la grille du modèle vers les points d'observations, et d'opérateurs simulant les processus instrumentaux (par exemple, les codes de transfert radiatif qui simulent les radiances satellitaires à partir de profils atmosphériques modélisés),

$\mathbf{R}$  et  $\mathbf{B}$  les matrices dites 'covariances d'erreur d'observation' et 'covariance d'erreur d'ébauche' définies respectivement à l'instant  $t$  par  $\mathbf{R} = \text{cov}[\mathbf{y} - \mathbf{H}(\mathbf{x}^t)]$  et  $\mathbf{B} = \text{cov}[\mathbf{x}^b - \mathbf{x}^t]$  où  $\mathbf{x}^t$  est l'état réel (*true state*) que l'on cherche à estimer sur la grille du modèle. En pratique,  $\mathbf{R}$  se construit souvent à partir d'informations sur la qualité instrumentale des différents types d'observation,  $\mathbf{B}$  à partir de statistiques sur des innovations, ou sur des prévisions d'ensemble.

On peut alors montrer (théorème du BLUE) que l'**analyse optimale**  $\mathbf{x}^a$  à  $t$  est donnée par l'équation d'analyse suivante :

$$\mathbf{x}^a = \mathbf{x}^b + \mathbf{K}(\mathbf{y} - \mathbf{H}(\mathbf{x}^b)) \quad \text{avec} \quad \mathbf{K} = \mathbf{B}\mathbf{H}^T(\mathbf{H}\mathbf{B}\mathbf{H}^T + \mathbf{R})^{-1} \quad (1)$$

et la **covariance d'erreur d'analyse** est donnée par

$$\mathbf{A} = (\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{B}. \quad (2)$$

On peut obtenir  $\mathbf{x}^a$  et  $\mathbf{A}$  de manière mathématiquement équivalente, et souvent numériquement plus attractive, par la **technique variationnelle 3D-Var** où  $\mathbf{x}^a$  est obtenue comme le minimum de la fonction-coût suivante :

$$J(\mathbf{x}) = (\mathbf{x} - \mathbf{x}^b)^T \mathbf{B}^{-1} (\mathbf{x} - \mathbf{x}^b) + (\mathbf{y} - \mathbf{H}(\mathbf{x}))^T \mathbf{R}^{-1} (\mathbf{y} - \mathbf{H}(\mathbf{x}))$$

$\mathbf{A}$  s'obtient par la dérivée seconde, ou hessienne, de  $J$  :  $\mathbf{A} = 2 (J'')^{-1}$ . La technique variationnelle s'étend facilement à l'analyse d'une séquence d'observations (par opposition à des observations effectuées uniquement à l'instant d'analyse) en insérant un modèle de prévision dans l'opérateur  $\mathbf{H}$  : le résultat  $\mathbf{x}^a$  reste alors optimal si  $\mathbf{H}$  est toujours linéarisable, ce qui est à la base de la technique d'assimilation 4D-Var utilisée dans la plupart des grands centres météorologiques.

L'optimalité de l'analyse BLUE peut s'entendre de 2 manières :

- $\mathbf{x}^a$  est optimale au sens où elle minimise la variance d'erreur d'analyse, c'est à dire la trace de  $\mathbf{A}$  :  $\mathbf{x}^a$  a donc la plus petite erreur d'estimation possible au sens de la distance quadratique à  $\mathbf{x}^t$ . Cette optimalité est obtenue si, dans le calcul de  $\mathbf{x}^a$ , les matrices  $\mathbf{B}$  et  $\mathbf{R}$  contiennent bien les covariances requises par leur définition.
- $\mathbf{x}^a$  est, de plus, optimale au sens où elle est l'état du modèle le plus probable (celui dont la probabilité connaissant les observations et l'ébauche, autrement dit  $p(\mathbf{x} | \mathbf{y}, \mathbf{x}^b)$ , est maximale). Cette notion d'optimalité assez forte n'est démontrable que sous certaines conditions sur les lois de probabilités de  $\mathbf{y}$  et de  $\mathbf{x}^b$ . Par exemple elle est vraie si les erreurs d'observation et d'ébauche ont des distributions normales (gaussiennes). Dans la mesure où les équations du BLUE spécifient alors la loi de probabilité de  $\mathbf{x}^a$ , on peut alors dire que le BLUE résout complètement le problème de l'estimation bayésienne.

Ce théorème du BLUE n'est valable que sous certaines hypothèses :

- l'opérateur  $\mathbf{H}$  doit être linéaire(ou linéarisable, par exemple au voisinage de  $\mathbf{x}^b$ )
- les erreurs d'ébauche et d'analyse ne doivent pas comporter de biais (leurs espérances doivent être nulles), ni de corrélations entre elles.
- $\mathbf{B}$  et  $\mathbf{R}$  doivent être conformes à leurs définitions. Il faut donc, pour que l'analyse BLUE fonctionne, avoir au préalable déterminé les covariances d'erreurs d'ébauche et d'observation.

Les équations (1) et (2) constituent la phase d'analyse dans l'algorithme d'assimilation par filtre de Kalman. L'optimalité des équations du BLUE n'est en pratique qu'approximative dans les systèmes météorologiques réalistes, ne serait-ce que parce que les distributions d'erreurs ne sont pas exactement connues.

## 1.2. Assimilation de données par filtre de Kalman

En météorologie, la relative rareté des observations fait que l'analyse dépend beaucoup de  $\mathbf{x}^b$  et  $\mathbf{B}$ , dont la spécification est donc déterminante pour la qualité des analyses. C'est particulièrement vrai dans les zones mal observées. Il est donc intéressant d'utiliser un modèle numérique de prévision : étant donné un intervalle temporel  $[t-, t]$ , la *prévision numérique* sur cet intervalle est notée

$$\mathbf{x}(t) = \mathbf{M}(t-, t)\mathbf{x}(t-)$$

où  $\mathbf{M}$  est l'opérateur de prévision numérique, qui est en général non-linéaire. En pratique,  $\mathbf{M}$  est une simulation numérique formée par intégration temporelle des équations discrétisées d'évolution du fluide atmosphérique. La production d'une ébauche à  $t$  à partir d'une prévision initialisée par une analyse récente à  $t-$  se note donc :

$$\mathbf{x}^b(t) = \mathbf{M}(t-, t) \mathbf{x}^a(t-) \quad (3)$$

On peut montrer que la matrice de covariances d'erreur d'ébauche  $\mathbf{B}$  à  $t$  se déduit à l'ordre 1 de la matrice de covariances d'erreur d'analyse  $\mathbf{A}$  à  $t-$  comme suit :

$$\mathbf{B}(t) = \mathbf{D}\mathbf{M}(t-, t) \mathbf{A}(t-) \mathbf{D}\mathbf{M}^T(t-, t) + \mathbf{Q}(t-, t) \quad (4)$$

où  $\mathbf{D}\mathbf{M}$  est la différentielle de  $\mathbf{M}$  par rapport à sa condition initiale, et  $\mathbf{Q}$  est la covariance d'erreur de modélisation, définie par  $\mathbf{Q}(t-, t) = \text{cov}[ \mathbf{M}(t-, t)\mathbf{x}^t(t-) - \mathbf{x}^t(t) ]$ . La combinaison des équations (1) à (4) définit une récurrence sur les états  $\mathbf{x}$  et leurs covariances d'erreur d'estimation ( $\mathbf{B}$

pour les ébauches et  $\mathbf{A}$  pour les analyses), appelée **assimilation par filtre de Kalman étendu**. On peut montrer que le filtre de Kalman produit des analyses et prévisions optimales si les hypothèses du BLUE sont respectées, si  $\mathbf{A}$  est conforme à sa définition, et si l'opérateur  $\mathbf{M}$  est linéaire.

On va voir que l'essentiel du projet de recherche présenté ici consiste à progresser dans la compréhension et la représentation des matrices  $\mathbf{B}$ ,  $\mathbf{R}$  et  $\mathbf{Q}$ , dans deux cadres applicatifs de grande importance : l'assimilation de données, et la prévision d'ensemble.

### 1.3. Assimilation variationnelle : méthodes 3D-Var et 4D-var

Ces méthodes d'analyse exploitent la forme variationnelle du BLUE, déjà citée :

$$J(\mathbf{x}) = (\mathbf{x}-\mathbf{x}^b)^T \mathbf{B}^{-1} (\mathbf{x}-\mathbf{x}^b) + (\mathbf{y}-\mathbf{H}(\mathbf{x}))^T \mathbf{R}^{-1} (\mathbf{y}-\mathbf{H}(\mathbf{x}))$$

Le terme de gauche est conventionnellement appelé  $J_b$  (*background term*) :

$$J_b(\mathbf{x}) = (\mathbf{x}-\mathbf{x}^b)^T \mathbf{B}^{-1} (\mathbf{x}-\mathbf{x}^b)$$

Le terme de droite,  $J_o$  (*observation term*), mesure une distance aux observations. L'analyse 3D-Var consiste à faire un calcul approximatif du minimum de  $J$ , par une minimisation itérative où l'on modifie l'état modèle  $\mathbf{x}_i$  selon la récurrence suivante :

- initialisation par l'ébauche qui est la meilleure estimation *a priori* de l'analyse  $\mathbf{x}_0 = \mathbf{x}^b$ ,
- pour chaque itérand  $\mathbf{x}_i$ , on calcule la valeur de la fonction-coût  $J(\mathbf{x}_i)$  selon l'expression ci-dessus. Son gradient vaut, dans le cadre d'une norme euclidienne,

$$\text{grad}J(\mathbf{x}) = 2\mathbf{B}^{-1} (\mathbf{x}-\mathbf{x}^b) - 2\mathbf{H}^T \mathbf{R}^{-1} (\mathbf{y}-\mathbf{H}(\mathbf{x})),$$

- l'itérand  $\mathbf{x}_{i+1}$  est calculé à partir des triplets  $(\mathbf{x}_i, J(\mathbf{x}_i), \text{grad}J(\mathbf{x}_i))$ , et éventuellement de leurs valeurs aux itérations précédentes, par un algorithme de minimisation standard (par exemple un gradient conjugué, un quasi-Newton, ou une méthode de Lanczos). Un tel algorithme assure en général que  $J(\mathbf{x}_{i+1}) < J(\mathbf{x}_i)$  et  $\|\text{grad}J(\mathbf{x}_{i+1})\| < \|\text{grad}J(\mathbf{x}_i)\|$ ,

- la minimisation est arrêtée, soit lorsque  $\|\text{grad}J(\mathbf{x}_i)\| / \|\text{grad}J(\mathbf{x}^b)\| < a$ , où  $a$  est un coefficient arbitraire (en pratique,  $a$  est de l'ordre de 0.01, ce qui signifie que l'on demande à  $\mathbf{x}_i$  d'être 100 fois plus proche du minimum de  $J$  que  $\mathbf{x}^b$ , au sens de la métrique impliquée par  $J$ ), soit lorsqu'un nombre maximal arbitraire d'itérations a été effectué.

Dans les applications météorologiques concrètes, la minimisation de  $J$  est interrompue au bout de quelques dizaines d'itérations. Pour accélérer cette minimisation, on peut effectuer un changement de variable appelé *préconditionnement* :  $\mathbf{x} = \mathbf{Lz}$  ; on minimise alors la fonction  $\tilde{J}(\mathbf{z}) = (J \circ \mathbf{L})(\mathbf{z})$ , ce qui en général est en d'autant plus rapide que le ratio entre la plus grande et la plus petite valeur propre de la hessienne  $\tilde{J}''$  est proche de 1.

Deux hypothèses sont fréquemment employées en analyse variationnelle :

- *linéarisation* : si  $\mathbf{H}$  n'est pas linéaire, il faut le linéariser (par exemple au voisinage de  $\mathbf{x}^b$ ) pour calculer le gradient  $\text{grad}J$ . L'optimalité de l'analyse BLUE, et l'unicité du minimum de  $J$ , ne sont alors plus garanties. L'analyse est d'autant plus optimale que  $\mathbf{H}$  est proche de sa version linéarisée. Mais si le minimum de  $J$  n'est pas unique, il peut arriver que la linéarisation de  $\mathbf{H}$  amène à un minimum secondaire de  $J$ .

- *formulation incrémentale* : les minimiseurs les plus efficaces sont en général ceux qui

sont conçus pour des fonctions-coût strictement quadratiques. En remplaçant  $\mathbf{H}$  par son développement limité à l'ordre 1 au voisinage de  $\mathbf{x}^b$  (dans la définition de la fonction-coût, ce qui est une hypothèse plus forte que la précédente), on obtient une fonction-coût quadratique relativement facile à minimiser et dont le minimum est une approximation de l'analyse BLUE. L'avantage pratique de cette technique est que l'unicité du minimum de la fonction-coût est garantie : il n'y a pas de risque que le minimiseur conduise à un minimum secondaire. Cependant, pour obtenir une bonne approximation du minimum de  $J$ , il faut en principe effectuer des mises à jour de l'état par rapport auquel  $H$  est linéarisée : ce processus de relinéarisation est complexe, et sa convergence n'est pas garantie.

L'analyse 4D-Var peut se définir facilement comme une extension du 3DVar à un vecteur  $\mathbf{y}$  qui regroupe, non seulement les observations à l'instant d'analyse, mais une collection d'observations dans un intervalle de temps  $[t_1, t_2]$  appelé *fenêtre d'assimilation*. En général on définit  $\mathbf{x}$  et  $\mathbf{B}$  à l'instant initial  $t_1$  : la fonction-coût s'évalue alors par extension du terme de droite  $J^0$  à une somme de termes qui mesurent la distance entre la prévision issue de  $\mathbf{x}$ , et les observations à chaque instant  $t_i$  de la fenêtre. La prévision numérique  $t_1$  à  $t_i$  est notée  $\mathbf{x}_i = \mathbf{M}(t_1, t_i)$ . Elle s'implémente par intégration numérique d'un modèle de l'atmosphère, ce qui permet de définir la fonction-coût du 4D-Var :

$$J(\mathbf{x}) = (\mathbf{x} - \mathbf{x}^b)^T \mathbf{B}^{-1} (\mathbf{x} - \mathbf{x}^b) + \sum_{i=t_1 \dots t_2} (\mathbf{y}_i - \mathbf{H}_i(\mathbf{x}_i))^T \mathbf{R}_i^{-1} (\mathbf{y}_i - \mathbf{H}_i(\mathbf{x}_i))$$

où  $\mathbf{y}_i$ ,  $\mathbf{H}_i$  et  $\mathbf{R}_i$  sont les observations, les opérateurs et les covariances d'erreur d'observations à l'instant  $t_i$ . Cette fonction-coût se minimise et on peut en former une approximation comme dans le 3D-Var, en insérant l'opérateur  $\mathbf{M}$  aux endroits appropriés des équations. Une difficulté pratique du 4D-Var est qu'il faut utiliser l'opérateur  $\mathbf{DM}^T$  (le *modèle adjoint*) pour évaluer  $\text{grad}J$  au cours de la minimisation, ce qui nécessite en général un travail de codage assez lourd. La minimisation du 4D-Var est numériquement coûteuse puisqu'elle inclut le coût d'évaluation de  $\mathbf{M}$  et  $\mathbf{DM}^T$  plusieurs dizaines de fois, c'est à dire qu'il faut réaliser l'équivalent de plusieurs prévisions pour produire chaque analyse 4D-Var. Pour limiter ce coût, on peut appliquer au 4D-Var la formulation incrémentale, non seulement en linéarisant le modèle, mais aussi en restreignant l'état du modèle  $\mathbf{x}$  à un sous-espace de dimension réduite : cela réduit le coût de calcul du modèle (grâce à sa basse résolution ; on peut aussi simplifier sa physique). En 4D-Var incrémental, il faut effectuer des relinéarisations à la fois sur  $H$  et sur  $M$ , en mettant à jour la trajectoire de linéarisation.

Malgré sa lourdeur, le 4D-Var est aujourd'hui l'algorithme le plus utilisé dans les centres de prévisions météorologiques globaux, car il produit les meilleures analyses, comme le montre l'étude des prévisions issues d'analyses 4D-Var (Klinker et al 2000).

#### **1.4. Modélisation de covariances statiques de grande dimension**

L'importance des matrices de covariances dans les analyses de type BLUE nécessite de soigner leur construction. En première approximation, les erreurs d'observations peuvent être supposées non corrélées entre elles, la spécification de  $\mathbf{R}$  se ramène alors à l'estimation de variances d'erreurs d'observations pour les différents types d'instruments (la prise en compte de corrélations d'erreurs d'observation n'est généralement justifiée qu'au sein de groupe de mesures provenant des systèmes d'observation homogènes, ce qui revient à supposer que  $\mathbf{R}$  est diagonale par bloc). La spécification de  $\mathbf{B}$  est nettement plus ardue : lorsque l'état  $\mathbf{x}$  est de grande dimension, comme c'est le cas en météorologie moderne ( $x \sim 10^9$ ), cette matrice ne peut même pas être stockée explicitement ; elle va être représentée par un **modèle de covariances**, défini comme une composée d'opérateurs

linéaires élémentaires. Ce modèle de covariances  $\mathbf{B}$  doit respecter non seulement des contraintes mathématiques et numériques, mais aussi des contraintes physiques spécifiques au système analysé (ici, le fluide atmosphérique), afin de garantir que l'analyse soit un état physiquement vraisemblable :

- $\mathbf{B}$  doit être symétrique, définie positive,
- pour une utilisation en analyse variationnelle, il est souvent utile de pouvoir décomposer  $\mathbf{B}=\mathbf{L}^T\mathbf{L}$ , avec  $\mathbf{L}$  opérateur inversible (ou pseudo-inversible),
- les autocorrélations de  $\mathbf{B}$  à courte distance géographique doivent refléter la régularité spatiale des champs analysés : les distances de décorrélation doivent être du même ordre de grandeur que les échelles typiques de variabilité dans le fluide,
- les corrélations croisées entre variables doivent refléter les principaux degrés d'équilibres (ou *balances*) présents dans le fluide : équilibres hydrostatique, géostrophique, non-divergence, structures des nuages convectifs,
- les variances de  $\mathbf{B}$  doivent être réalistes, au minimum, en termes des champs météorologiques analysés, et des variables observées (variances de la matrice  $\mathbf{HBHT}$ ).

Cette liste permet de délimiter quelles approximations de  $\mathbf{B}$  sont admissibles ; si  $\mathbf{B}$  est conforme à sa définition :  $\mathbf{B}=\text{cov}[\mathbf{x}^b - \mathbf{x}^t]$ , ces contraintes sont automatiquement vérifiées.

L'approche la plus simple pour construire  $\mathbf{B}$  consiste à écrire

$$\mathbf{B} = \mathbf{SCTCS}$$

où  $\mathbf{CTC}$  est une matrice de corrélation factorisée, et  $\mathbf{S}$  est un opérateur diagonal de multiplication par des champs d'écart types d'erreur d'ébauche. Pour représenter l'opération de multiplication d'un vecteur par une matrice de corrélation dans un modèle de grande dimension, la **méthode spectrale** est fréquemment utilisée : elle consiste à construire  $\mathbf{C}$  comme le produit d'opérateurs diagonaux dans l'espace spectral (harmoniques sphériques sur la sphère, ou fonctions bi-Fourier sur un rectangle). Si l'on suppose que les corrélations sont spatialement homogènes, alors  $\mathbf{C}$  est diagonale dans l'espace spectral, et ses coefficients se déduisent facilement des spectres d'erreurs de l'ébauche. Cette technique est majoritairement employée dans les systèmes d'assimilation IFS, ARPEGE, ALADIN et AROME (Courtier et al 1998, Berre 2000, Brousseau et al 2011) en raison de la géométrie relativement simple de leurs grilles de discrétisation. La méthode spectrale peut se généraliser en multiplication par des opérateurs diagonaux dans l'espace des **ondelettes** ; cette technique est notamment employée dans IFS. Les corrélations peuvent aussi être représentées par l'application de **filtres digitaux** dans l'espace de la grille du modèle ; cette technique est employée dans le système global SSI au USA. Une dernière technique utile pour construire  $\mathbf{C}$  repose sur des opérateurs de diffusion, cette technique est utilisée dans certains systèmes d'analyse océanique.

Toutes ces méthodes s'adressent essentiellement aux corrélations horizontales, il faut ensuite les combiner avec des modèles de corrélations verticales et de corrélations entre variables, en effectuant d'autres hypothèses simplificatrices et des produits tensoriels. On décrira plus loin comment cette stratégie a été concrètement mise en oeuvre pour construire le terme  $\mathbf{Jb}$  de l'assimilation opérationnelle IFS.

Une autre approche consiste à construire un **modèle de  $\mathbf{B}$  ensembliste** : si l'on connaît un ensemble de  $p$  réalisations  $\{\mathbf{e}^b_i\}_{i=1..p}$  de l'erreur d'ébauche  $\mathbf{e}^b=\mathbf{x}^b-\mathbf{x}^t$ , alors on peut construire une matrice de covariances  $\mathbf{B}_p$  :

$$\mathbf{B}_p = \sum_{i=1 \dots p} \mathbf{e}^{\mathbf{b}_i} \mathbf{e}^{\mathbf{b}_i \mathbf{T}}.$$

Cette matrice  $\mathbf{a}$ , aux erreurs d'échantillonnage près, les mêmes covariances que  $\mathbf{B}$ . En revanche, elle n'est pas définie positive en dehors du sous-espace engendré par les  $\{\mathbf{e}^{\mathbf{b}_i}\}$ , ce qui ne permet pas de calculer une analyse bien conditionnée que dans ce sous-espace (c'est le principe de l'assimilation ETKF, ou filtre de Kalman par transformée d'ensemble). Elle souffre généralement d'erreurs d'échantillonnage, qui se manifestent par un bruit inacceptable sur les champs d'analyse si on utilise  $\mathbf{B}_p$  telle quelle dans l'équation du BLUE. On peut limiter ce problème en combinant linéairement  $\mathbf{B}_p$  avec autre un modèle de covariance, ou en convoluant  $\mathbf{B}_p$  avec une fonction empirique à support géographiquement compact, ce qui réduit le bruit d'échantillonnage et augmente le rang de  $\mathbf{B}$  (technique dite du 'produit de Schur' ou 'produit de Hadamard'), au prix d'une dégradation d'autres aspects de  $\mathbf{B}$  (Lorenç 2003).

Une fois un modèle de covariances défini, il faut le calibrer de manière statistique pour obtenir la matrice  $\mathbf{B}$  à un instant d'analyse donné. En théorie, cela nécessite de connaître la distribution de probabilité complète des erreurs d'ébauche  $\mathbf{x}^{\mathbf{b}} - \mathbf{x}^{\mathbf{t}}$  (ou, au moins, ses 2 premiers moments) à l'instant  $t$ , ce qui est impossible : pour l'estimer dans un modèle réaliste de manière ensembliste (par un échantillonnage discret), il faudrait disposer en temps réel de plusieurs milliards de réalisations de  $\mathbf{x}^{\mathbf{b}}$ . On verra dans ce projet de recherche que les variations temporelles de  $\mathbf{B}$  sont très importantes en météorologie, et qu'elles renseignent sur la prévisibilité des processus physiques modélisés. Les stratégies employées pour répondre à ce défi sont les suivantes. Il faut d'abord supposer que le modèle de covariances  $\mathbf{B}$  est statique (c'est à dire, constant dans le temps), ce qui permet d'utiliser les covariances d'un ensemble de prévisions  $\mathbf{x}^{\mathbf{b}}$ , moyennées dans le temps, pour calibrer les coefficients d'un unique modèle de covariances  $\mathbf{B}$  (partie 2.1). On va ensuite critiquer ce modèle statique de  $\mathbf{B}$  en le confrontant à des estimations plus précises du  $\mathbf{B}$ , non simplifiées par un modèle de covariances, et variables dans le temps ; c'est ce qui a été fait au cours de notre projet de recherche (partie 2.2), dans le cadre d'un modèle d'atmosphère barotrope, puis d'un modèle réaliste de l'atmosphère, AROME. Dans ce dernier cas, il est difficile de s'affranchir d'un modèle de covariances, mais il reste intéressant d'introduire une dose de variabilité temporelle en calibrant des covariances sur une période glissante, pour faire varier  $\mathbf{B}$  lentement dans le temps : c'est le " $\mathbf{B}$  du jour". Dans notre projet de recherche, cette idée a été appliquée au système d'assimilation AROME. On peut même faire varier la calibration du modèle de covariances en fonction des conditions météorologiques locales.

Pour aller plus loin dans la représentation de la variabilité de  $\mathbf{B}$ , il faut être capable de recalculer le modèle de covariances en produisant un ensemble d'ébauches à chaque analyse : c'est le principe du **filtre de Kalman d'ensemble**, dont il existe de nombreuses variantes. En théorie, c'est la meilleure stratégie pour les modèles de grande dimension, mais la production de prévisions d'ensembles étant coûteuse, la taille d'un tel ensemble est forcément limitée, ce qui crée des erreurs d'échantillonnage sur les paramètres du modèle de covariances  $\mathbf{B}$  choisi. La construction d'ensembles ayant des distributions réalistes est, en outre, une entreprise complexe (partie 3). Actuellement, la plupart des filtre de Kalman d'ensemble utilisent des modèles de covariances extrêmement simplifiés, comme le **modèle de B ensembliste** décrit ci-dessus.

Dans ce projet de recherche, un effort important a été consacré à l'amélioration des modèles de covariances : on a conçu un modèle spectral statique, et comparé différentes stratégies de calibration : avec un modèle de covariances simplifié, statique, ou avec le " $\mathbf{B}$  du jour". L'effort investi sur les prévisions d'ensemble vise à progresser vers une calibration de type filtre de Kalman d'ensemble, dans laquelle la qualité de l'ensemble est cruciale.

## 1.5. Prévision et assimilation d'ensemble

### 1.5.1. Principes de la prévision d'ensemble

L'objectif est d'échantillonner de manière discrète la loi de probabilité de l'état de l'atmosphère à un instant futur  $t^+$ , nous noterons cet état  $\mathbf{x}^+$ . La loi de probabilité est fonction des informations disponibles, qui sont typiquement les données d'un modèle de prévision  $M$ , et d'une analyse  $\mathbf{x}^a$  à l'instant présent  $t$ .

On cherche donc à échantillonner  $P(\mathbf{x}^+) = P(\mathbf{x} | M, \mathbf{x}^a)$ . Ces deux informations sont entachées d'erreurs, par exemple une analyse BLUE contient par construction une incertitude estimée par la matrice de covariances d'erreurs d'analyse  $\mathbf{A}$  définie plus haut. L'incertitude sur  $M$  peut être représentée par la matrice de covariance  $\mathbf{Q}$  des équations du filtre de Kalman. On peut en déduire une méthode simpliste de prévision d'ensemble (cf. par exemple Toth et Kalnay 1993) :

1. construire un échantillon  $\{\mathbf{x}^a_i\}$  de  $n$  variantes de l'analyse, par exemple avec un tirage selon une loi normale :  $\mathbf{x}^a_i \sim N(\mathbf{x}^a, \mathbf{A})$ ,
2. construire un échantillon  $\{M_j\}$  de  $m$  variantes du modèle de prévision  $M$ ,
3. un échantillon de  $P(\mathbf{x}^+)$  est alors fourni par l'ensemble des prévisions  $\mathbf{x}_k^+ = M_j(\mathbf{x}^a_i)$ , où les  $i, j$  sont tirés aléatoirement parmi les couples possibles  $\{M_j, \mathbf{x}^a_i\}$ , les  $\mathbf{x}_k^+$  sont appelés **membres** de la prévision d'ensemble.

Cette vision soulève de nombreuses questions pratiques. En voici une liste non exhaustive.

- Compte tenu du coût d'intégration d'un modèle météorologique, on ne peut produire que de l'ordre d'une dizaine à une centaine de prévisions. C'est tout à fait insuffisant pour échantillonner la loi de probabilité du vecteur  $\mathbf{x}^+$ , dont la dimension est de l'ordre de  $10^9$ . Même en invoquant la notion de "variété instable" pour prétendre que seul un sous-ensemble des valeurs possibles de  $\mathbf{x}$  est effectivement exploré par l'atmosphère à un instant donné, les études sur la dimensionnalité effective des modèles réalistes montrent qu'il faudrait explorer au moins plusieurs milliers de dimensions afin d'explorer l'essentiel des structures instables (Heureusement, en général on ne cherche que la distribution de paramètres scalaires de l'atmosphère, pour lesquels le bruit statistique d'un échantillonnage de quelques dizaines de membres est acceptable, au sens où il est inférieur au signal que l'on y cherche). De ce point de vue, on peut dire que la prévision d'ensemble sert surtout à évaluer des probabilités pour des paramètres météorologiques (plutôt que des probabilités de l'état atmosphérique complet).
- Le tirage aléatoire de perturbations d'une prévision aboutit en général à une sous-estimation de l'incertitude sur  $\mathbf{x}^+$ , parce que les techniques de perturbation ne sont pas encore très réalistes (c'est à dire que l'on ne sait pas échantillonner précisément les incertitudes sur le modèle de prévision et sur l'analyse); il en découle que les membres de la prévision d'ensemble sont irréaliment semblables entre eux. Une technique empirique pour maximiser la dispersion d'un ensemble est l'ajout à l'analyse de **vecteurs singuliers** du modèle (perturbations de l'analyse dont la norme croît le plus au cours de la prévision). Cette technique (Molteni et al 1996) est difficile à justifier théoriquement, mais elle est très employée car elle est généralement bénéfique pour les probabilités prévues par l'ensemble.
- En pratique, on ne sait pas produire de réalisations indépendantes du modèle, ou de l'analyse. La plupart des tirages sont construits en perturbant un système déterministe (on perturbe un modèle donné, et une analyse). Par conséquent, la prévision d'ensemble

échantillonne non pas la distribution d'un système de prévision concret, mais celle d'un système de prévision artificiellement dégradé (celui auquel on a ajouté des perturbations). Une conséquence pratique est que les erreurs quadratiques à courte échéance d'un membre de prévision d'ensemble sont, en théorie,  $\sqrt{2}$  plus grandes que celles du système de prévision non-perturbé. C'est sans importance si les erreurs évoluent de manière linéaire, mais les conséquences sur la distribution de variables dont l'évolution est très non-linéaire ne sont pas encore bien comprises.

- On ne sait généralement pas construire des variantes équiprobables d'un modèle de prévision. La priorité des équipes de R&D en modélisation est plutôt la fabrication du meilleur modèle possible, et la connaissance physique des sources d'incertitudes dans les modèles est actuellement limitée (c'est essentiellement dans les domaines des paramétrisations de la turbulence et de la convection que l'on sait caractériser une variance d'incertitude liée aux fluctuations sous-maille ; alors qu'une grande partie des erreurs de modélisation réside aussi dans les échelles résolues, dans la dynamique, et dans d'autres processus physiques). Des approches empiriques sont donc nécessaires, comme par exemple l'utilisation de versions différentes d'un modèle (méthode multiphysique, par ex. Bright et Mullen 2002, qui a l'inconvénient d'introduire des corrélations d'erreurs entre les membres de l'ensemble). On décrira plus loin une méthode semi-empirique appelée **physique stochastique**, où les équations d'un modèle sont perturbées de manière pseudo-aléatoire.
- La distribution des erreurs d'analyse est assez mal connue, malgré l'existence des équations du BLUE : d'une part ces équations sont trop coûteuses pour être évaluées sans simplification, d'autre part leurs résultats sont affectés par les approximations effectuées dans le calcul de l'analyse, notamment dans les covariances **B**. L'étude des erreurs d'analyse a été approfondie dans notre projet de recherche : dans un modèle barotrope simplifié, puis avec les vecteurs singuliers d'un modèle initialisé par une analyse variationnelle, et enfin au travers de leur effet sur un système de prévision d'ensemble quasi-opérationnel.

La notion de prévision d'ensemble peut s'étendre à un système d'assimilation. Dans ce cas, les entrées du système sont les observations, et le modèle. Les perturber en suivant leurs lois de probabilités respectives produit un ensemble d'analyses, ce qui permet de contourner en partie la difficulté citée ci-dessus : c'est la technique dite d'assimilation d'ensemble.

### 1.5.2. Assimilation d'ensemble

On considère un processus d'assimilation séquentiel 3D-Var fondé sur les équations du BLUE : à chaque cycle d'analyse,  $\mathbf{x}^a$  est le minimum de la fonction-coût

$$J(\mathbf{x}) = (\mathbf{x}-\mathbf{x}^b)^T \mathbf{B}^{-1} (\mathbf{x}-\mathbf{x}^b) + (\mathbf{y}-\mathbf{H}(\mathbf{x}))^T \mathbf{R}^{-1} (\mathbf{y}-\mathbf{H}(\mathbf{x}))$$

et l'ébauche est produite par l'équation de prévision notée  $\mathbf{x}^b = \mathbf{M}(\mathbf{x}^a)$ . Ce processus est déterminé par la séquence des observations  $\mathbf{y} \in \{\mathbf{y}_t\}_{t=0..T}$  sur une période d'assimilation  $[0..T]$  (après une période de chauffe de quelques jours, on constate que la manière dont le modèle a été initialisé lors de la première prévision n'a plus d'importance).

On construit alors un *ensemble de N assimilations* perturbées, définies chacune par le même processus, mais alimentées par des observations perturbées aléatoirement :  $\mathbf{y}_i \in \{\mathbf{y}_{t_i}\}_{t=0..T}$ , où  $i$  est l'indice de la  $i$ -ième assimilation, et  $t_i$  sa date. Ces observations perturbées sont construites en ajoutant aux  $\mathbf{y}_t$  un bruit gaussien, de covariance cohérente avec les erreurs d'observation (la matrice **R**). Le résultat est, à chaque instant, un ensemble de  $N$  analyses et prévisions :  $\{\mathbf{x}^a_i\}$  et  $\{\mathbf{x}^b_i\}$ , dont on peut montrer qu'ils échantillonnent les lois de probabilité des erreurs sur  $\mathbf{x}^a$  et  $\mathbf{x}^b$ , si le modèle est

parfait. En particulier, la covariance interne de l'ensemble des  $\{\mathbf{x}^{\mathbf{b}}_i\}$  est, à un bruit d'échantillonnage près, égale à la matrice  $\mathbf{B}$  à l'instant considéré (Desroziers et al 2009).

En pratique, les assimilations d'ensemble souffrent en général des mêmes maux que les prévisions d'ensemble, notamment un manque de dispersion lorsque les erreurs de modélisation sont négligées. Une manière simple d'y remédier consiste à effectuer des dilatations (c'est à dire des homothéties autour de la moyenne de l'ensemble, avec un facteur supérieur à 1) pour augmenter artificiellement la dispersion de l'ensemble à chaque cycle d'assimilation, en se référant aux statistiques d'écart entre modèle et observations pour optimiser le facteur de dilatation. Une méthode plus élaborée, étudiée dans notre projet de recherche, consiste à intégrer un schéma de physique stochastique dans le modèle  $M$ .

L'assimilation d'ensemble est un outil conceptuellement assez simple, qui a deux applications importantes :

- pour initialiser un système de prévision d'ensemble : l'ensemble  $\{\mathbf{x}^{\mathbf{a}}_i\}$  est, à un instant d'analyse donné, un échantillon optimal de conditions initiales pour la prévision d'ensemble démarrant à cet instant.
- pour fournir à un système d'analyse une matrice  $\mathbf{B}$  de covariances d'erreurs d'ébauche : l'ensemble  $\{\mathbf{x}^{\mathbf{b}}_i\}$  est, à un instant d'analyse donné, un échantillon optimal d'ébauches, utilisable soit pour calibrer un modèle de covariances d'ébauches, soit pour construire un modèle ensembliste de  $\mathbf{B}$ .

Ces deux aspects sont explorés dans notre projet de recherche : l'impact d'une initialisation par assimilation d'ensemble sera étudié sur la prévision d'ensemble AROME, et l'impact d'une calibration "au jour le jour" de  $\mathbf{B}$  sera étudié avec le système d'assimilation 3D-Var AROME.

## Partie 2 : Etude des erreurs d'ébauche

### 2.1. Modèles statiques d'erreurs d'ébauche

Dans cette partie on commence par l'aspect le plus fondamental de la représentation des erreurs en assimilation de données : les modèles statiques de covariances d'erreur d'ébauche  $\mathbf{B}$ . Comme expliqué en partie 1, il suffit d'un tel modèle pour commencer à bâtir un système d'assimilation de données. Historiquement, c'est sur ces modèles statiques que se sont concentrées les premières recherches pour la mise au point de systèmes modernes d'assimilation de données : des 3D-Var, puis 4D-Var, capables d'assimiler les radiances satellitaires. Les précédentes représentations de  $\mathbf{B}$  avaient été développées dans les années 80 pour des systèmes d'analyse OI (interpolations optimales avec sélection locale de données). Le passage à des techniques variationnelles, ainsi que les nouvelles exigences liées à l'assimilation des nouvelles radiances satellitaires (notamment la série TOVS, cf. Andersson et al 1994), ont imposé une profonde refonte de ces modèles de covariances : c'est le "nouveau  $\mathbf{Jb}$ " décrit ci-dessous (Derber and Bouttier 1999), que j'ai mis au point dans le système global du CEPMMT, et qui a été ensuite appliqué avec quelques modifications dans les systèmes ARPEGE et ALADIN à Météo-France, ce qui a permis le succès récent du système AROME, à la pointe mondiale en termes d'assimilation de données régionales. En effet, grâce à sa généralité vis à vis du modèle de prévision utilisé, le "nouveau  $\mathbf{Jb}$ " a pu être adapté sans difficulté à AROME malgré sa très haute résolution spatiale, et a permis d'innover dans l'assimilation opérationnelle de données à haute densité telles que les radiances géostationnaires (Montmerle et al 2006), les délais zénithaux GPS, les réflectivités et les vents radiaux Doppler observés par radar (Montmerle et Faccani 2009). Cette partie résume l'histoire de ce "nouveau  $\mathbf{Jb}$ ".

#### 2.1.1. Covariances d'ébauche ' $\mathbf{Jb}$ ' pour la prévision globale du CEPMMT

(Travail publié dans Derber et Bouttier 1999)

Des études sophistiquées, avec le filtre de Kalman ou l'assimilation d'ensemble, permettent d'examiner assez précisément les covariances d'erreurs dans les systèmes d'assimilation, et de se rendre compte de leur complexité : elles sont inhomogènes, et variables dans le temps. Idéalement, il faudrait les utiliser opérationnellement, mais les contraintes de coût numérique et de production temps réel obligent à rechercher des algorithmes plus simples, qui se concentrent sur l'essentiel : pour faire de bonnes prévisions, il faut de bonnes covariances, mais il faut aussi tenir compte des caractéristiques du modèle de prévision et du réseau d'observation. Il n'existe hélas pas encore de théorie pour définir le système d'assimilation optimal dans ces conditions ; le développement de systèmes opérationnels d'assimilation et de prévision nécessite un lourd travail d'expérimentation numérique, et du sens physique pour faire les bonnes hypothèses simplificatrices. J'ai été au coeur de deux grands projets novateurs de prévision numérique : le 4DVar IFS du CEPMMT, dont j'ai mis au point le modèle de covariances d'erreur lors de sa mise en oeuvre vers 1997, et le système AROME, dont j'ai spécifié et encadré le développement à Météo-France. Tous deux sont, encore aujourd'hui, en production et leurs performances sont mondialement réputées. Dans les deux cas, il ne s'est pas agi de théories innovantes, mais de conception raisonnée à partir d'un dosage soigneux entre complexité de mise en oeuvre, et approximations physiques. On va montrer qu'il ne s'agit là pas seulement d'ingénierie, la vision scientifique des processus physiques à respecter a été cruciale.

Le travail original sur le modèle de covariances "nouveau  $\mathbf{Jb}$ " a été réalisé entre 1995 et 2000 en tant que scientifique au CEPMMT. En 1995, le système d'analyse variationnel IFS/ARPEGE venait d'être créé, avec une analyse 3D-Var opérationnelle, et une analyse 4D-Var en cours de mise

au point. Il y avait cependant un problème de performance des deux systèmes, notamment dans les analyses tropicales, qui affectaient la qualité des prévisions globales à échéance de quelques jours. Des diagnostics avaient révélé que les corrélations verticales d'erreurs de prévision étaient beaucoup plus fines que ce que supposait le modèle d'erreur d'ébauche du 3D/4D-Var IFS. Les principes des analyses 3D-Var et 4DVar ont été rappelés en partie 1, on cite ici l'équation du 3D-Var (les aspects relatifs au  $\mathbf{Jb}$  sont inchangés en 4D-Var) avec la décomposition de la fonction-coût en deux termes :  $\mathbf{Jb}$  (la distance à l'ébauche), et  $\mathbf{Jo}$  (la distance aux observations) :

$$\begin{aligned} J(\mathbf{x}) &= (\mathbf{x}-\mathbf{x}^b)^T \mathbf{B}^{-1} (\mathbf{x}-\mathbf{x}^b) + (\mathbf{y}-\mathbf{H}(\mathbf{x}))^T \mathbf{R}^{-1} (\mathbf{y}-\mathbf{H}(\mathbf{x})) \\ &= \mathbf{Jb}(\mathbf{x}) + \mathbf{Jo}(\mathbf{x}). \end{aligned}$$

Cette équation montre la relation entre le terme  $\mathbf{Jb}$  et le modèle de covariances  $\mathbf{B}$  :  $\mathbf{Jb}(\mathbf{x}) = (\mathbf{x}-\mathbf{x}^b)^T \mathbf{B}^{-1} (\mathbf{x}-\mathbf{x}^b)$ . La première version du  $\mathbf{Jb}$  dans le système IFS reposait sur le principe suivant : à un état modèle  $x=(V,D,T,Q,ps)$  où  $V,D,T,Q,ps$  sont les champs 3D de tourbillon, divergence, température, humidité spécifique et le champ 2D de pression de surface, on associe une fonction-coût  $\mathbf{Jb}$  par pénalisation des différentes variables atmosphériques :

$$\mathbf{Jb}(x) = \alpha (V-V_b)^T B_V(V-V_b) + \beta (D-D_b)^T B_D(D-D_b) + \gamma (T-T_b)^T B_T(T-T_b) + \dots$$

où  $\alpha, \beta, \gamma$ , etc sont des coefficients scalaires de pénalisation, l'indice  $b$  indique les champs dans l'ébauche  $\mathbf{x}^b$ , et  $B_V, B_D, B_T$ , etc sont des matrices 3D de covariances d'erreur pour le tourbillon, la divergence, etc. Cette représentation équivaut à supposer que les covariances  $\mathbf{B}$  sont diagonales par bloc. L'atmosphère étant fortement géostrophique à grande échelle, il faut optimiser les valeurs des coefficients de pénalisation pour limiter les incréments de divergence (en donnant une valeur élevée à  $\beta$ ), et obtenir une analyse ayant les meilleurs équilibres multivariés possibles. Malgré son apparente simplicité, cette formulation avait trois inconvénients majeurs. D'abord, il n'y avait pas de méthode directe pour spécifier les coefficients de pénalisation. Ensuite, les diagnostics d'erreurs de prévisions montraient que les covariances d'erreurs ont une forte dépendance à l'échelle horizontale, mais comme les matrices  $B_V, B_D, B_T$  etc. devaient être spécifiées dans l'espace spectral (les ondelettes étaient mal connues à l'époque), on ne savait pas comment moduler spatialement le degré de géostrophisme, alors que l'on savait que ce dernier était faible sous les tropiques. La formulation algébrique choisie ne permettait donc pas d'obtenir des analyses physiquement correctes à toutes les latitudes. De plus, la notion de balance ainsi représentée était très simpliste par rapport à ce que montrait l'étude des modes normaux de l'atmosphère. Un troisième inconvénient de ce modèle de covariances était que la matrice  $\mathbf{B}$  impliquée par l'équation ci-dessus n'était pas facile à factoriser sous la forme  $\mathbf{B}=\mathbf{LL}^T$ , avec  $\mathbf{L}$  inversible. Ce type de factorisation est crucial pour un bon préconditionnement du 3D/4D-Var, afin d'accélérer suffisamment l'analyse pour une exploitation en temps réel.

Des idées avaient été proposées pour raffiner  $\mathbf{B}$ , notamment en remplaçant la décomposition de l'atmosphère en  $(V,D,T,ps)$  ci-dessus par une décomposition en variables dites balancées et non balancées, respectivement sous la forme  $\mathbf{x}-\mathbf{x}^b=(\mathbf{x}-\mathbf{x}^b)_{bal} + (\mathbf{x}-\mathbf{x}^b)_{unbal}$ . Cette décomposition de  $(\mathbf{x}-\mathbf{x}^b)$  aurait été calculée, par exemple par projection sur des modes normaux (Heckley et al 1992), le projeté et le résidu étant par définition les composantes balancée et non-balancée. Malheureusement cette approche revenait à complexifier de manière insupportable le modèle de covariances, puisqu'elle imposait de calculer des covariances en double exemplaire pour toutes les variables modèles : un fois pour leur projection balancée, une autre fois pour leur projection non-balancée. Par ailleurs on ignorait comment doser la pénalisation relative entre variables balancées ou non.

Sur une idée de John Derber (visiteur du service météorologique national US), une nouvelle

formulation a été tentée, avec une approche iconoclaste pour l'époque (Derber et Bouttier 1999) : elle consistait à spécifier directement la racine carrée de  $\mathbf{B}$ , en supposant arbitrairement que le tourbillon du modèle est balancé, et que l'on n'analyse que les composantes non-balancées des autres variables (divergence, température et pression de surface). Cette hypothèse très forte, à contre-courant des théories sophistiquées (voire byzantines) de l'époque sur l'initialisation par modes normaux, présentait des vertus surprenantes : d'une part, elle éliminait le problème de la factorisation sous forme  $\mathbf{B}=\mathbf{L}\mathbf{L}^T$ , puisque la forme résultante de  $\mathbf{L}$  était trivialement inversible, d'autre part elle permettait de doser facilement le degré de balance aux différentes latitudes, puisqu'il suffisait d'agir sur les variances des variables non-balancées. La contrepartie était que l'on ne pouvait s'appuyer sur aucune théorie pour définir le concept de balance dans  $\mathbf{B}$ , qui se limitait à des régressions linéaires entre variables sur des ensembles de prévisions ; comme le montre la forme de  $\mathbf{B}$  explicitée ci-dessous :

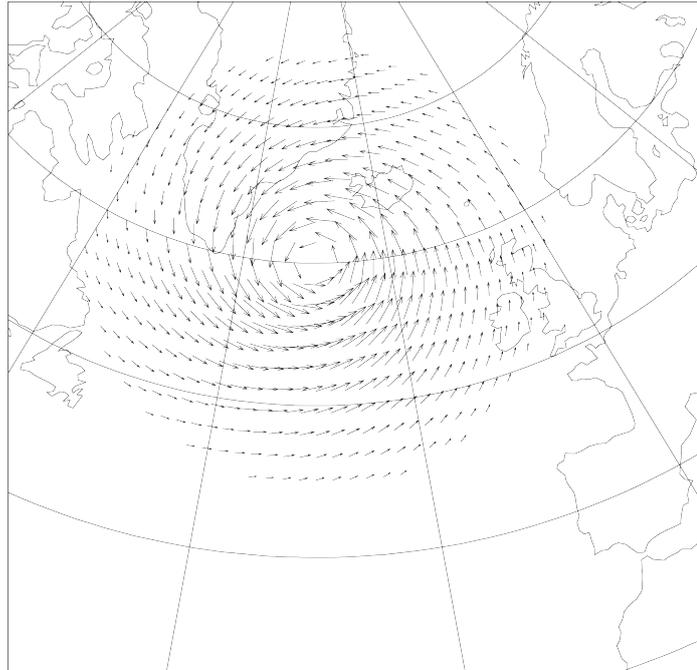
$$\mathbf{B} = \begin{pmatrix} \mathbf{I} & 0 & 0 & 0 \\ \mathcal{M} & \mathbf{I} & 0 & 0 \\ \mathcal{N} & \mathcal{P} & \mathbf{I} & 0 \\ 0 & 0 & 0 & \mathbf{I} \end{pmatrix} \begin{pmatrix} C_V & 0 & 0 & 0 \\ 0 & C_{Du} & 0 & 0 \\ 0 & 0 & C_{(T,ps)u} & 0 \\ 0 & 0 & 0 & C_q \end{pmatrix} \begin{pmatrix} \mathbf{I} & \mathcal{M}^T & \mathcal{N}^T & 0 \\ 0 & \mathbf{I} & \mathcal{P}^T & 0 \\ 0 & 0 & \mathbf{I} & 0 \\ 0 & 0 & 0 & \mathbf{I} \end{pmatrix}$$

cette matrice est de la forme  $\mathbf{B}=\mathbf{D}\mathbf{C}\mathbf{D}^T$  où  $\mathbf{D}$  est une matrice dite de "balance", définie par des opérateurs linéaires  $(M,N,P)$  qui impliquent des corrélations multivariées. Les  $(M,N,P)$  sont relativement faciles à calculer par des régressions linéaires dans l'espace spectral entre d'une part, le tourbillon  $V$ , et, d'autre part, divergence, température et pression de surface (Berre (2002) a plus tard étendu cet opérateur à l'humidité). La matrice centrale  $\mathbf{C}$  est une matrice de corrélations diagonales par bloc, facile à factoriser et à inverser, qui contient les autocorrélations du champ de tourbillon, d'humidité, des champs non-balancés de divergence, température et pression de surface. Ces champs non-balancés sont définis comme les résidus des régressions linéaires  $(M,N,P)$ . Cette formulation de  $\mathbf{B}$  repose donc sur l'hypothèse que les erreurs sur les résidus non-balancés sont statistiquement décorréliées des erreurs sur le tourbillon et l'humidité, ce qui donne sa forme diagonale par bloc à  $\mathbf{C}$ , et limite le volume de statistiques à évaluer pour construire  $\mathbf{B}$ .

Le travail réalisé dans ce projet de recherche a consisté à valider physiquement ce modèle de covariance, pour toutes les variables du modèle. Cela a révélé l'importance de la dépendance spectrale des corrélations multivariées (les grandes échelles sont plus géostrophiques que les petites, ce qui est crucial pour obtenir les bonnes corrélations entre température et vent lors de l'assimilation des radiances satellitaires), ainsi que l'importance de l'équilibre de la divergence dans les basses couches (à grande échelle, il s'agit surtout du pompage d'Ekman, à petite échelle, il s'agit de l'équilibre entre température, humidité et divergence dans les zones à convection profonde). De plus, les corrélations verticales sont, comme on l'espérait, plus fines sous les tropiques qu'aux latitudes moyennes (car la modulation latitudinale du degré de balance dans ce modèle de covariance reflète la stratification verticale du vent en présence de la force de Coriolis, un phénomène connu en mécanique des fluides sous le nom de théorème de Proudman-Taylor). Cette variabilité des corrélations entre variables était, en fait, inaccessible aux théories existantes des modes normaux, qui sont peu après tombées en désuétude, puisqu'elles s'avéraient moins utiles qu'un bon  $\mathbf{Jb}$  (aidé dans certains cas par une initialisation par filtres digitaux) pour initialiser correctement une analyse. La figure 1 montre un exemple de correction de l'analyse 3DVar du CEPMMT, caractéristique des corrélations multivariées du nouveau  $\mathbf{Jb}$ .

### new Jb - z1000 obs - L30 wind increments

→ 0.5 m/s



0.5 m/s

*Figure 1 : correction du champ de vent en basse troposphère, apportée par l'analyse 3DVar du CEPMMT en présence d'une observation de pression de surface inférieure à l'ébauche. Ce champ est proportionnel à la corrélation entre pression de surface et vent modélisée dans le nouveau Jb : cette corrélation est forte aux latitudes moyennes, et proche d'un équilibre géostrophique, mais contient une composante convergente significative lorsque l'incrément est cyclonique, ce qui approxime le processus de pompage d'Ekman dans la couche limite atmosphérique.*

Il a fallu ensuite vérifier soigneusement l'impact de cette formulation sur les performances des analyses et des prévisions du CEPMMT. Un résultat surprenant a été que ce nouveau **Jb** produisait des analyses à bien des égards moins proches des observations que des formulations plus simples. Pourtant les prévisions ainsi initialisées se sont avérées bien meilleures à courte échéance, car les observations étaient mieux spatialisées. Cette formulation de B a été rapidement adoptée dans de nombreux centres de prévision, avec des perfectionnements depuis (notamment par une prise en compte de la balance avec l'humidité, l'utilisation d'ondelettes pour modéliser les autocorrélations, et une meilleure description de la variabilité des variances), elle reste encore aujourd'hui largement utilisée dans les centres météorologiques opérationnels.

#### **2.1.2. Covariances d'ébauche pour la prévision régionale : le 3D-Var AROME**

(Travail publié dans Brousseau et al, 2011)

La mise en oeuvre d'un système d'assimilation à haute résolution pour le modèle AROME a été facilitée par la flexibilité de la formulation du **Jb** définie ci-dessus. AROME étant un modèle à domaine limité, il a fallu convertir la représentation spectrale (utilisée pour construire le modèle d'autocorrélations) depuis la géométrie sphérique vers une géométrie rectangulaire, caractérisée par des fonctions spectrales bi-Fourier. Ce travail a été effectué vers 1998 par L. Berre (Berre, 2000).

La formulation du **Jb** proprement dite se prête aisément à une représentation spectrale bi-Fourier. Il suffit de l'alimenter avec des statistiques d'erreurs de prévision AROME. La difficulté est qu'il y a une dépendance entre la manière dont les prévisions AROME sont initialisées, et les covariances d'erreur de ces prévisions, puisque ces dernières servent à calibrer le **Jb** du 3DVar qui initialise les prévisions. C'est une histoire de poule et d'oeuf ; pour amorcer le processus de calibration du **Jb** dans un nouveau système d'assimilation, il faut procéder en plusieurs étapes de complexité croissante.

- Pour disposer d'un premier ensemble de prévisions AROME, lorsque son assimilation 3D-Var n'existe pas encore, il faut fabriquer un jeu de prévisions démarrant d'analyses interpolées à partir d'un système d'assimilation préexistant, ici ALADIN-France. Ce procédé, appelé 'spin-up' (ou 'adaptation dynamique'), produit des prévisions AROME de qualité médiocre, mais suffisante pour calibrer un premier **Jb** à résolution native d'AROME : on utilise pour cela la méthode dite 'du NMC', où l'on effectue sur une longue période des statistiques de différences entre couples de prévisions AROME démarrées à quelques heures d'intervalle, et valides au même instant. Ces différences constituent une première approximation des covariances d'erreur de prévision AROME (l'hypothèse sous-jacente étant que les perturbations des prévisions AROME, excitées par les corrections successives de l'assimilation ALADIN, ont des corrélations proches de celles des erreurs de prévision).
- Les opérateurs de covariances et de balance du **Jb**, décrits à la section précédente, sont calculés à partir de ces différences entre couples de prévisions AROME. Les variances sont renormalisées par un facteur empiriquement calibré, tel que la matrice **B** impliquée par ce **Jb** ait des variances cohérentes avec les erreurs de prévision AROME à échéance 6h. Ces erreurs de prévision sont estimées par comparaison à des observations. Le **Jb** ainsi calibré permet de lancer une première version de l'assimilation 3D-Var AROME.
- On peut alors produire une nouvelle version du **Jb** AROME, en réappiquant la méthode du NMC à des couples de prévisions issues de cette première assimilation 3D-Var AROME. L'expérience acquise au CEPMMT, et dans les systèmes ARPEGE et ALADIN, montre que cela améliore l'assimilation, parce que les prévisions AROME issues d'une assimilation avec ce même modèle sont meilleures que celles produites par une méthode de spin-up à partir d'un autre modèle.
- Une troisième méthode, encore plus performante, a été ici appliquée : la calibration du **Jb** à partir de prévisions d'ensemble AROME (ce qui introduit la partie de notre projet de recherche consacrée à la prévision d'ensemble, cf. plus loin). En effet, la méthode du NMC, bien que très pratique, n'est pas théoriquement rigoureuse ; on peut montrer qu'elle ne fournirait des covariances optimales que si le gain du 3D-Var AROME était proche de l'identité divisée par 2 (c'est à dire, en première approximation, si toute la grille du modèle était couverte d'observations). La technique de prévision d'ensemble, quant à elle, fournit en théorie le meilleur **Jb** possible si elle est correctement conçue (en particulier, les covariances des différences entre membres de la prévision d'ensemble doivent être proches des covariances d'erreur de prévision AROME, multipliées par  $\sqrt{2}$  ). Historiquement, le **Jb** du 3D-Var AROME a été calibré à partir des différences entre membres d'une prévision d'ensemble AROME rudimentaire, initialisée par une assimilation d'ensemble. Les statistiques ont été calculées à partir d'un échantillon de plusieurs semaines de prévision d'ensemble AROME. On a montré (Brousseau et al, 2011) que cette méthode produit un **Jb** pour le 3D-Var AROME qui améliore les performances des prévisions AROME. C'est ainsi qu'a été construite la première version du système AROME opérationnel.

En résumé, un opérateur **Jb** performant pour AROME a été conçu grâce à un effort particulier

sur ses statistiques d'erreur de prévision. L'utilisation d'une assimilation d'ensemble dans un modèle de ce type était tout à fait novatrice à l'époque, et facilitée par la mise au point de l'assimilation d'ensemble ARPEGE par Berre et Desroziers quelques années plus tôt. Comme expliqué dans l'article de Brousseau et al (2011), l'avantage de cette approche ensembliste réside dans la production de corrélations d'erreur à haute résolution, ce qui permet à l'assimilation AROME d'exploiter à fond les systèmes d'observation à haute résolution disponibles sur la France métropolitaine : il s'agit notamment des radars, satellites géostationnaires, et réseaux automatiques de surface. Un exemple d'utilisation des données radar est montré en figure 2.

Nombreux étaient, au lancement du projet AROME, les détracteurs d'un système de prévision jugé avoir une trop forte résolution pour que l'assimilation fonctionne. Ne risquait-on pas, disait-on, d'obtenir des prévisions moins bonnes que celles d'un modèle global, parce que les petites échelles d'AROME ne contiendraient que du bruit ? Un résultat majeur de notre projet de recherche a été de prouver qu'une application rigoureuse de la théorie de l'assimilation, alliée à une utilisation ambitieuse des systèmes d'observation régionaux, permet de produire de l'information physique utile à haute résolution. En effet, c'est surtout grâce à la grande finesse de son modèle de covariances  $\mathbf{Jb}$  que le 3D-Var AROME est capable d'assimiler des phénomènes atmosphériques dont la taille peut descendre jusqu'à une vingtaine de kilomètres sur l'horizontale.

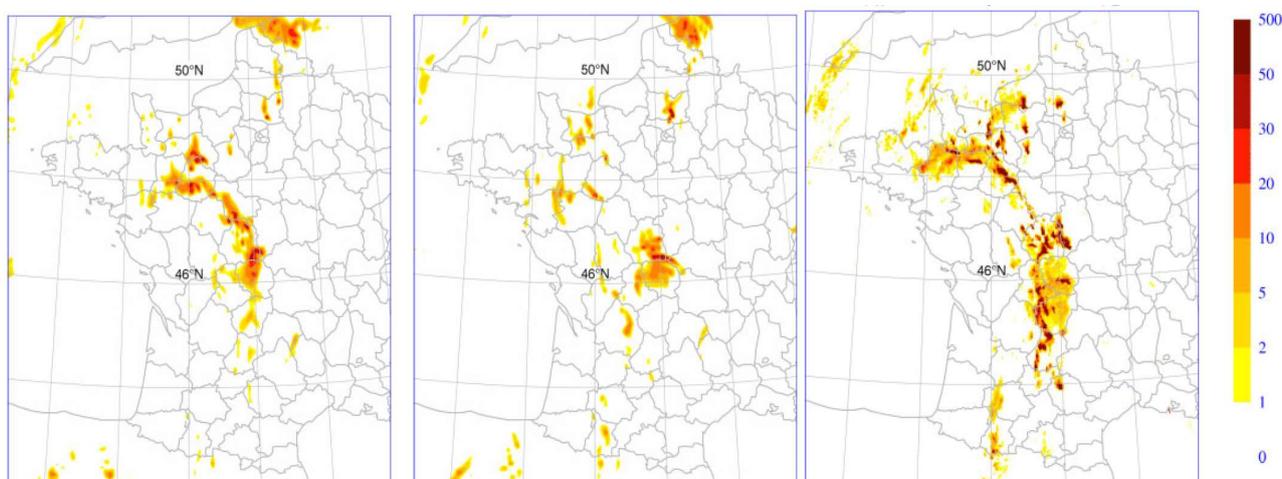


Figure 2 : Comparaison, sur une prévision de pluies convectives, de deux méthodes de calibration du  $\mathbf{Jb}$  dans l'assimilation 3D-Var AROME. Gauche : prévision de réflectivités radar avec un  $\mathbf{Jb}$  calibré par une assimilation d'ensemble AROME. Milieu : idem, avec un  $\mathbf{Jb}$  calibré par des prévisions issues d'analyses ALADIN à plus faible résolution. Droite : réflectivités radar observées, en mm/h. Cette figure montre l'intérêt de l'assimilation d'ensemble pour modéliser des covariances d'erreur (figure tirée de Brousseau et al 2011 ; cas du 25 mai 2009, 19UTC).

### 2.1.3. Perspectives sur les covariances d'ébauche statiques

On a décrit dans cette partie la genèse d'un cadre de modélisation des erreurs de prévision, adapté aux besoins de l'assimilation de données dans une large gamme d'échelles, allant du global à la modélisation de l'atmosphère à échelle kilométrique. Les points-clés de cette modélisation, destinée à construire l'opérateur  $\mathbf{B}$  (aussi appelé  $\mathbf{Jb}$ ) d'un système d'assimilation, sont:

- l'utilisation de formulations spectrales non-séparables pour représenter la dépendance des corrélations et des opérateurs de balance par rapport à l'échelle horizontale,

- l'emploi de régressions linéaires pour définir de manière objective ces opérateurs de balance,
- l'utilisation de vastes jeux de données de prévision, de préférence issus de prévisions d'ensemble, pour définir ces statistiques d'erreur.

Ces idées ont été adaptées, au départ, de propositions originales de P. Courtier et J. Derber, puis raffinées au fil des ans par de nombreux collaborateurs, notamment E. Andersson, M. Fisher, C. Fischer, L. Berre, G. Desroziers, P. Brousseau. Développées au CEPMMT et à Météo-France, elles ont été reprises dans la plupart des grands centres de prévision météorologique, notamment les consortiums ALADIN, HIRLAM, au Canada, et, avec quelques variantes, au NCEP, NCAR, UK Met Office, et même en océanographie, puisque qu'une formulation de  $\mathbf{Jb}$  proche de celle décrite ici (Ricci et al 2005) est utilisée dans le système de modélisation océanique 4D-Var Mercator.

Tout n'a pas été dit sur la modélisation des statistiques d'erreur d'ébauche. Outre le besoin de faire évoluer les statistiques d'erreur en fonction de la situation météorologique du jour, ce qui sera décrit dans la suite de ce mémoire, il serait utile de mieux prendre en compte les caractéristiques physiques des erreurs de prévision. En effet, le modèle d'erreur décrit ci-dessus est, essentiellement, homogène et isotrope, or on sait que les autocorrélations atmosphériques peuvent être anisotropes, et dépendre des conditions locales. Parmi les nombreux travaux actuels sur ce thème, on mentionnera ceux de T. Montmerle, sur la prise en compte de variations géographiques (avec un masque pour identifier les zones pluvieuses), et ceux sur l'utilisation d'ondelettes et d'opérateurs de déformation pour modéliser des covariances dans un espace plus général que la représentation spectrale, par exemple pour obtenir des variances (Raynaud et Pannekoucke 2012) ou des corrélations inhomogènes (Montmerle et Berre 2010, Varella et al 2011, Ménétrier et Montmerle 2011, Michel 2012).

## **2.2. Etude de la variabilité des erreurs d'ébauche**

### **2.2.1. Covariances du jour dans un modèle simplifié**

(Travail publié dans Bouttier, 1993)

La partie précédente portait sur les covariances statiques d'erreur d'ébauche, c'est à dire sur les statistiques d'erreur de prévision, en moyenne sur de longues périodes (typiquement, plusieurs semaines). En réalité, ces statistiques dépendent de la situation météorologique, elles sont donc différentes chaque jour (on verra plus loin comment la signature des processus dynamiques se retrouve dans les structures de covariances). Elles dépendent aussi des erreurs des analyses qui ont servi à initialiser ces prévisions, donc du réseau d'observation, et des erreurs de l'ébauche précédente : pour étudier la variabilité des covariances d'erreur, il faut prendre en compte à la fois la dynamique atmosphérique du jour, et l'évolution des erreurs d'analyse au cours du cycle d'assimilation.

Dans les prévisions météorologiques à courte échéance (moins de 48h), les erreurs d'analyse sont majoritairement responsables de la variabilité des erreurs de prévision. Comment caractériser ces erreurs d'analyse ? Leur valeur exacte est inconnue (si elle l'était, il suffirait de la soustraire pour avoir une analyse parfaite). Les erreurs d'analyse ne sont accessibles qu'au travers de leurs covariances, mathématiquement représentées par la matrice **A** de l'équation (2). Pour accéder à la structure détaillée de **A**, il faut remonter aux principes de l'analyse de données, qui reposent en météorologie moderne sur la théorie de l'interpolation statistique optimale. Cette théorie a été brièvement rappelée dans l'introduction de ce mémoire.

L'équation d'analyse fournit un moyen d'étudier la matrice d'erreurs d'analyse **A**. On a conçu dans notre projet de recherche une méthode originale pour l'estimer à moindre coût dans un contexte météorologique réaliste : une mise en oeuvre partielle du filtre de Kalman, où l'on n'utilise que les équations (2) et (4) pour calculer l'effet de l'assimilation sur les erreurs d'estimation **A** et **B** dans un modèle simplifié d'atmosphère ; les autres équations, qui servent à effectuer l'analyse et la prévision proprement dites (équations (1) et (3)) sont remplacées par les analyses et prévisions d'un modèle météorologique à haute résolution, ce qui garantit leur réalisme. En effet, les moyens de calcul disponibles ne permettent pas de calculer l'ensemble des équations du filtre de Kalman avec un modèle d'atmosphère réaliste, ce qui serait le seul moyen vraiment rigoureux d'estimer exactement les matrices **A** et **B** (il est généralement admis que pour décrire correctement la dynamique de l'atmosphère à échelle synoptique, qui contient la majeure partie des erreurs de prévision à échéance de quelques jours, il faut une résolution horizontale globale de l'ordre de 1000km, soit une variable de contrôle de taille  $10^5$  environ ; le calcul exact d'un filtre de Kalman de cette taille ne deviendra être faisable que vers 2020)

Cette méthode, appelée estimation dynamique des covariances d'erreur d'assimilation, fournit sur une longue période des informations convaincantes sur les matrices **A** et **B**. Ces dernières sont influencées par la géographie du réseau d'observations ; dans les zones relativement bien observées, comme l'Eurasie et l'Amérique du Nord, les erreurs d'analyse sont (à grande échelle) du même ordre de grandeur que les erreurs d'observation, et les erreurs de prévision à très courte échéance ont à peu près toujours les mêmes amplitudes et corrélations. Un exemple de carte d'erreurs de prévisions est présenté en figure 3. Seul, le taux de croissance d'erreur lors de la prévision dépend significativement de la situation météorologique. Dans les zones bien observées, ces corrélations horizontales d'erreur d'analyse sont à peu près homogènes et isotropes, ce qui reflète la nature essentiellement ponctuelle des observations météorologiques, et l'indépendance statistique mutuelle

de leurs erreurs.

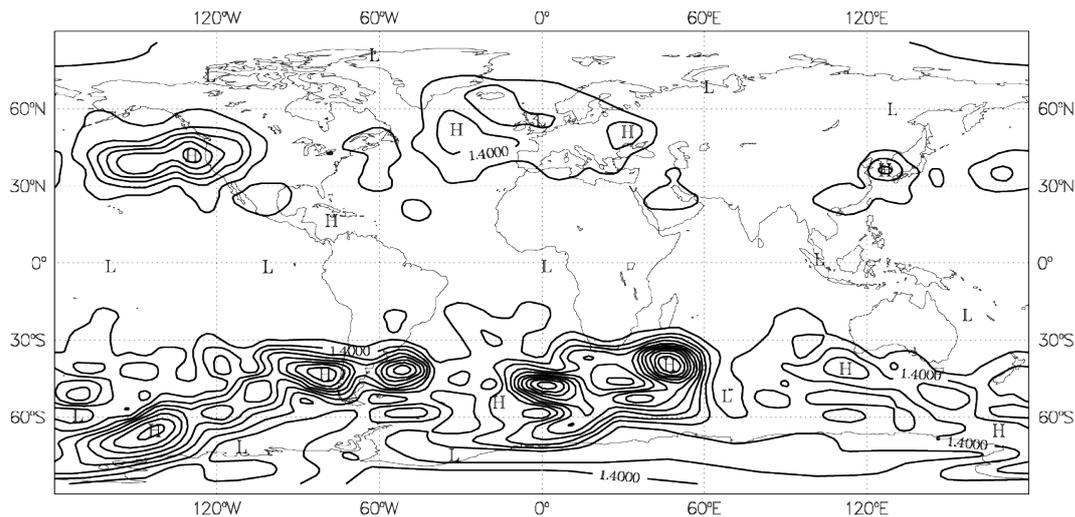


Figure 3 : écarts-types des erreurs de prévision du géopotentiel à 500hPa, à échéance 24h, obtenus par les équations du filtre de Kalman dans un modèle simplifié. Cette carte montre la présence de noyaux d'instabilité dynamique peu prévisibles le long du jet dans l'hémisphère sud, et sur les océans et côtes ouest dans l'hémisphère nord. La plus haute densité du réseau d'observation sur les continents y limite les erreurs de prévision.

Dans les zones pauvres en observations, les erreurs d'analyse ont des structures de variance et de corrélation plus complexes, analogues à celles décrites en section 4.1 : cela s'explique parce qu'il n'y a pas assez d'observations dans ces zones pour corriger les erreurs d'ébauche lors des analyses, on retrouve donc la signature des covariances de  $\mathbf{B}$  dans les erreurs d'analyse  $\mathbf{A}$ . Ces dernières dépendent fortement de la situation météorologique : les erreurs de prévision, même à très courte échéance, y varient beaucoup d'un jour à l'autre. Les conséquences pratiques sont importantes, puisque cela signifie que, pour obtenir une analyse vraiment optimale, il faudrait utiliser une matrice  $\mathbf{B}$  différente chaque jour. L'utilisation de ces covariances d'erreur d'ébauche "au jour le jour" reste un objectif difficile pour la prévision météorologique opérationnelle. Notre étude donne une idée de la structure de ces covariances d'erreurs idéales.

Cette expérimentation a aussi révélé des difficultés méthodologiques avec l'utilisation du filtre de Kalman en météorologie. Outre son coût numérique exorbitant (qui explique la priorité donnée aux techniques variationnelles dans les centres opérationnels), il fait intervenir des erreurs de modélisation dont la représentation est mal comprise, et qui a un impact important sur les résultats. Ces erreurs sont de deux types :

**Les erreurs du modèle de prévision** proprement dit, représentées par la matrice  $\mathbf{Q}$  dans l'équation (4). En première approximation, les variances de ces erreurs ont été estimées avec une méthode initialement proposée par Daley (1992), et dont le principe est le suivant : avec un échantillon d'observations sur lequel les statistiques sont supposées homogènes, on peut calculer en moyenne la variance  $v_i$  des innovations  $\mathbf{y}-\mathbf{H}(\mathbf{x}^b)$ , la variance d'erreur d'observation  $v_R$ , et la variance  $v_{MAM}$  de la matrice  $\mathbf{H} \mathbf{D}\mathbf{M}(t,t) \mathbf{A}(t) \mathbf{D}\mathbf{M}^T(t,t) \mathbf{H}^T$  qui est le terme de gauche de l'équation (4) interpolé aux points d'observation. En supposant que les erreurs d'observations ne sont pas corrélées avec les erreurs de prévision, la variance moyenne  $v_B$  de la matrice  $\mathbf{H}\mathbf{B}\mathbf{H}^T$ , qui est l'erreur moyenne d'ébauche aux points d'observation, vérifie  $v_B = v_i - v_R$ . Par ailleurs l'équation (4)

implique que  $v_B = v_{MAM} + v_Q$ , où  $v_Q$  est la variance d'erreur de modélisation ( $HQH^T$ ). Cela permet de calculer  $v_Q = v_i - v_R - v_{MAM}$  et donc d'estimer la variance moyenne d'erreur de modélisation. Une matrice  $Q$  rudimentaire a ensuite été construite avec cette variance et un modèle de corrélations homogène et isotrope. C'était à l'époque la première tentative sérieuse pour estimer objectivement l'erreur de modélisation dans un contexte d'assimilation de données. Avec suffisamment d'observations on pourrait généraliser la méthode à l'étude des corrélations d'erreur de modélisation, et de leur dépendance à la situation météorologique.

**Les erreurs du système d'analyse** traduisent le fait que l'estimation de  $A$  par l'équation (4) est, en général, trop optimiste, et se traduit par une sous-estimation importante des erreurs d'analyse au voisinage des stations d'observation. Ce phénomène, encore souvent ignoré dans les travaux sur les erreurs d'analyse, provient du non-respect des hypothèses d'optimalité de l'analyse BLUE (notamment les erreurs de spécification des matrices  $B$  et  $R$ ). On a montré que, lorsque le processus d'analyse n'est pas optimal, ce qui est presque toujours le cas en pratique, il faut calculer  $A$  non pas avec l'équation  $A = (I-KH)B$  mais avec une équation plus générale :

$$A = (I-KH)B(I-KH)^T + KRK^T \quad (5),$$

Cette équation s'obtient en multipliant  $x^a = x^b + K(y - H(x^b))$  par sa transposée et en prenant l'espérance du résultat. Elle suppose qu'erreurs d'ébauche et d'observation sont non corrélées entre elles, mais elle ne fait aucune hypothèse sur l'optimalité du calcul de l'analyse  $K$ . Avec des hypothèses réalistes sur la manière dont  $K$  est calculée dans un contexte opérationnel, l'équation (5) aboutit dans notre étude à des variances d'erreur d'analyse nettement plus élevées qu'avec l'équation  $A = (I-KH)B$ . L'analyse peut être non-optimale à cause de simplifications numériques effectuées dans le calcul de l'analyse (notamment un manque de résolution), ou du non-respect des hypothèses du BLUE, par exemple la présence de biais instationnaires dans le modèle de prévision. Dans notre cadre de travail (un modèle barotrope), l'étude des statistiques d'écart aux observations prouve que l'équation  $A = (I-KH)B$  produisait des résultats incorrects, même lorsque les variances de  $B$  sont correctement spécifiées. L'utilisation de l'équation  $A = (I-KH)B(I-KH)^T + KRK^T$  produit quant à elle un système à peu près fiable d'estimation des erreurs d'analyse et d'ébauche, si l'on estime soigneusement les variances de  $R$ . Ces travaux ont été publiés dans un article (Bouttier, 1994).

Lors de ce travail, les contraintes de calcul ne permettaient d'utiliser qu'un modèle très simple : un modèle barotrope (à 1 seul niveau) non-divergent de l'atmosphère globale, à 2000km de résolution. Il n'était donc pas possible de démontrer expérimentalement que la matrice  $B$  "au jour le jour" améliorait effectivement l'analyse opérationnelle et les prévisions qui en découlent. Depuis, différentes variantes de filtre de Kalman d'ensemble et d'ensembles d'assimilations ont été développées ; il devient alors possible d'appliquer ce travail à des systèmes d'assimilation plus réalistes, et de critiquer les hypothèses qui y sont faites sur  $Q$  et sur l'optimalité du système d'analyse. C'est ce qui a été fait - en partie - dans le système AROME, comme expliqué dans la suite.

## 2.2.2. Covariances du jour dans l'assimilation AROME opérationnelle

(Travail publié dans Brousseau et al 2012)

AROME est un modèle régional de l'atmosphère, caractérisé par sa haute résolution (maille de 2,5km, dynamique non-hydrostatique) et sa capacité à assimiler des observations régionales à haute densité par la technique 3D-Var expliquée ci-dessus : les principales spécificités de cette assimilation sont l'utilisation des humidités et vent radar, radiances géostationnaires, observations de surface, et la présence d'un cycle d'assimilation de 3 heures. Malgré le changement d'échelle, on retrouve les mêmes problèmes d'assimilation que dans les modèles globaux : en effet, bien

qu'AROME fonctionne sur un territoire riche en observations (l'Europe de l'ouest), il simule une large gamme de phénomènes météorologiques, dont certains sont de petite taille, comme les tours convectives ou les bancs de brouillard. Il n'y a donc pas toujours suffisamment d'observations pour contraindre les analyses et les prévisions à rester proches de la réalité. La manière dont le système d'assimilation affecte les prévisions est souvent subtile, et dépend de la situation météorologique du jour.

En régime forcé par les échelles synoptiques, par exemple au voisinage des dépressions actives ou des grands fronts, quasiment tous les aspects de la prévision AROME sont déterminés par les grandes échelles, qui sont forcées aux limites latérales et supérieure du modèle par le modèle global ARPEGE. Dans ce cas, AROME produit essentiellement une adaptation à échelle fine, par son relief et sa physique des surfaces continentales à haute résolution. En régime peu forcé, ce qui est fréquent lors d'orages estivaux diurnes, c'est le contraire : les détails du couplage à ARPEGE ont peu d'importance, et c'est la physique interne d'AROME, notamment sa capacité à simuler la convection profonde, qui va structurer la prévision. Le développement de la convection diurne est très sensible aux conditions initiales de la prévision (donc à l'analyse), en particulier à la présence d'hétérogénéités dans la couche limite, et au champ 3D d'humidité. Un mauvais placement initial des zones précipitantes peut compromettre la prévision. Certains phénomènes combinent les deux concepts : lors des épisodes cévenols, la prévision de très fortes pluies sur le sud-est de la France peut être sensible à la fois au forçage synoptique et aux conditions initiales à mésoéchelle.

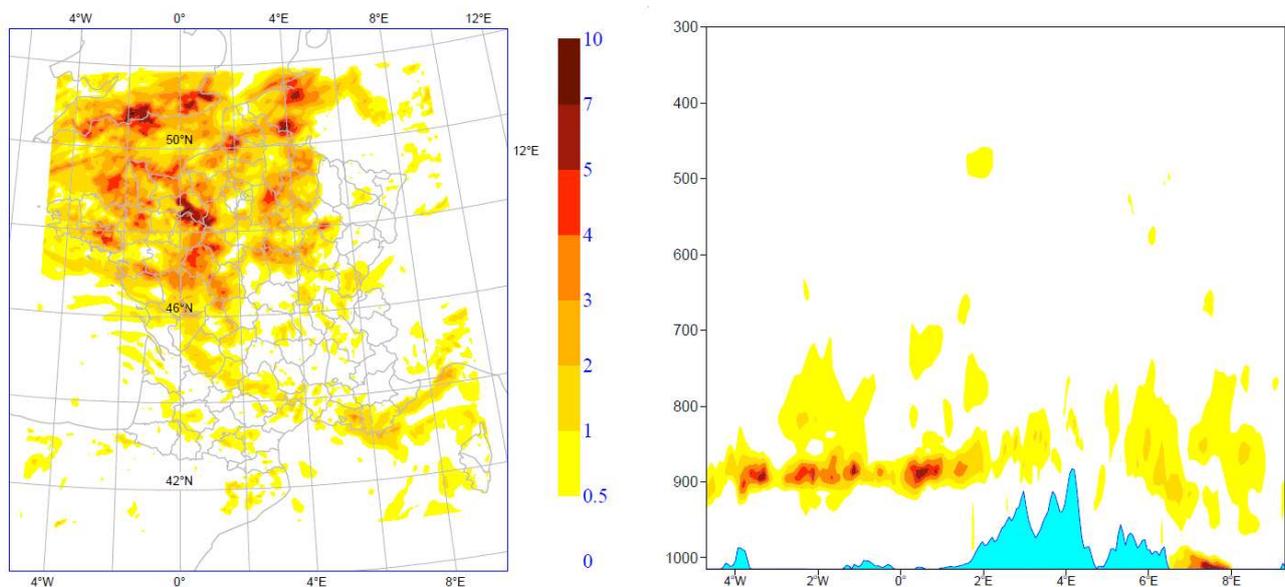
La sensibilité des prévisions régionales au type de temps et aux conditions initiales justifie de modéliser les effets de la variabilité météorologique dans le 3D-Var AROME, via la matrice  $\mathbf{B}$ . Pour cela, il faut estimer les covariances d'erreur de manière évolutive dans l'assimilation. Une technique proche de celle utilisée au paragraphe précédent a été utilisée : il s'agit de simuler le comportement des erreurs de prévision au voisinage d'une assimilation de référence. La dimension du modèle AROME étant trop grande pour appliquer rigoureusement les équations (2) et (4), on a utilisé une approximation supplémentaire du filtre de Kalman, la méthode Monte-Carlo, sous forme d'une "assimilation d'ensemble". Cette technique, développée essentiellement par Loïk Berre et Gérald Desroziers (Desroziers et al 2009) avec le modèle ARPEGE, puis adaptée par Pierre Brousseau pour le modèle AROME, a été expliquée en introduction.

L'assimilation d'ensemble AROME utilisée comporte 8 assimilations 3D-Var, qui sont dilatées, c'est à dire que les prévisions y subissent des homothéties empiriques autour de leur moyenne, afin de représenter les effets des erreurs de modélisation (procédé analogue à la matrice  $\mathbf{Q}$  de l'équation 4 pour  $\mathbf{B}$  ; un effet algébriquement similaire peut être obtenu sur les analyses en jouant sur les variances de  $\mathbf{R}$  dans l'équation (5), pour représenter empiriquement les suboptimalités de l'analyse). Les différences entre les ébauches de cet ensemble  $\{\mathbf{x}^{bi}\}$  permettent d'estimer une matrice de covariances  $\mathbf{B}$ . Cette matrice est représentée sous forme d'un modèle statistique de covariance qui est symétrique, défini positif, et présente les mêmes variances, corrélations mono- et multivariées que l'ensemble des  $\{\mathbf{x}^{bi}\}$ . Cette utilisation d'un modèle statistique détruit une partie de l'information contenue dans les  $\{\mathbf{x}^{b}\}$ , mais garantit que l'analyse utilise une matrice  $\mathbf{B}$  définie positive et raisonnablement débarrassée des erreurs d'échantillonnage. Cette matrice  $\mathbf{B}$  est différente chaque jour, et plus proche de la matrice exacte (celle du filtre de Kalman) qu'une estimation climatologique (c'est à dire statique) .

Ce système expérimental permet de retrouver des résultats analogues au modèle simplifié : le  $\mathbf{B}$  produit par l'assimilation d'ensemble dépend bien de la situation météorologique. Les variances d'erreur de prévision sont plus fortes en régimes perturbés, car le modèle de prévision contient alors des instabilités dynamiques qui amplifient rapidement les erreurs initiales d'analyse. De fortes variances sont aussi associées aux zones à forts gradients spatiaux, comme les nuages stratiformes (figure 4). Les corrélations d'erreur dépendent, elles aussi, de la situation, elles ont des portées

horizontales plus grandes en régime anticyclonique qu'en régime perturbé. Les corrélations verticales sont d'autant plus lisses que les processus de mélange sont actifs (figure 5). Ces résultats ressemblent, pour leur partie horizontale, à ceux obtenus dans le modèle barotrope. La nouveauté est que l'on peut ici tester en vraie grandeur l'impact de ce **B** "au jour le jour" par rapport à un **B** climatologique, sur les performances des prévisions AROME à haute résolution : dans les analyses 3D-Var AROME, le **B** "au jour le jour" modifie les poids des observations, et la manière dont elles sont spatialisées (ce qui est cohérent avec les modification des variances et corrélations dans **B**). Cela produit des prévisions AROME dont les scores objectifs (distances aux observations jusqu'à 30h d'échéance) sont meilleurs, ce qui est un signe d'amélioration du système d'assimilation.

Ce travail a été publié par Brousseau et al (2012). On a donc réussi à adapter la théorie du filtre de Kalman à un cadre quasi-opérationnel, susceptible d'améliorer les prévisions opérationnelles. Cette valorisation sera effective d'ici quelques années, lorsque l'assimilation d'ensemble AROME deviendra opérationnelle. Outre l'estimation de **B**, l'assimilation d'ensemble présente l'intérêt de produire des ensembles d'analyses, dont on montrera l'intérêt plus loin pour la prévision d'ensemble.



*Figure 4 : distribution spatiale des variances d'erreur d'ébauche de température le 23 février 2008 à 12h TU. Les plus fortes variances sont associées à une couverture de nuages stratiformes, dont la structure varie légèrement entre les membres de l'assimilation d'ensemble AROME (échelle de couleurs en degrés C). gauche : coupe horizontale à 900hPa, droite : coupe verticale entre les coins NW et SE de la figure de gauche. (Figure tirée de Brousseau et al 2011)*

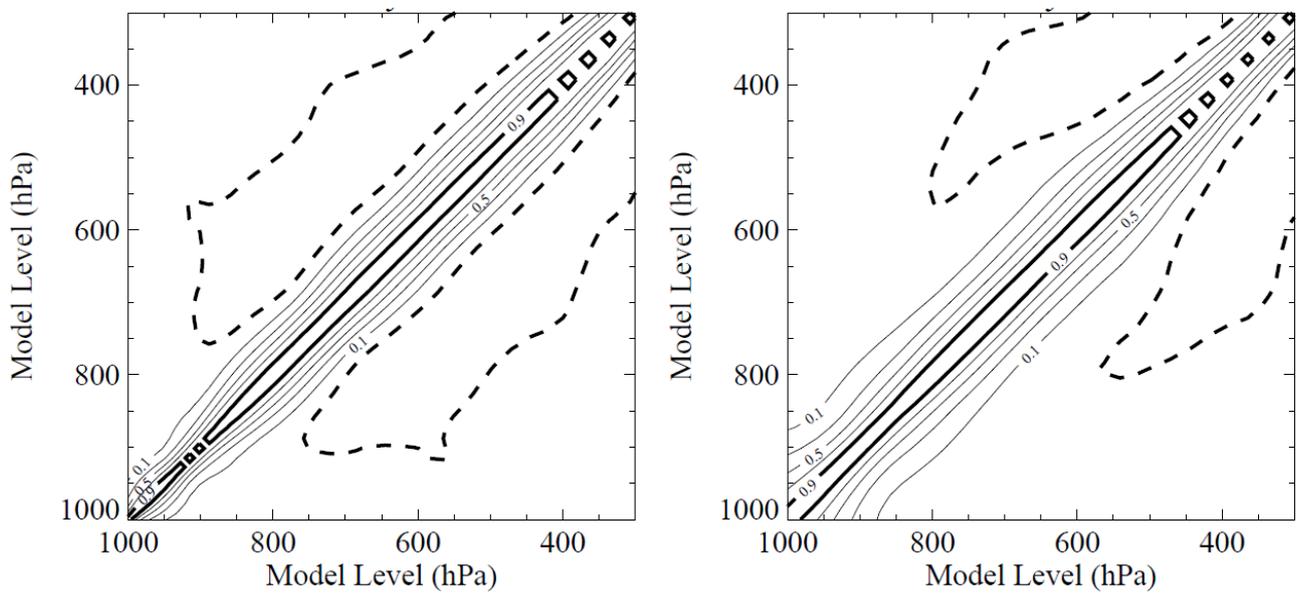


Figure 5 : matrices de corrélations verticales d'erreur d'ébauche de température, en moyenne sur la métropole, diagnostiquées sur 2 journées distinctes : les 23 février et 4 mars 2008 à 12h TU. La première est dominée par des conditions anticycloniques, la seconde est dominée par de la convection profonde. La coordonnée est l'indice vertical de grille du modèle, converti en pression d'une atmosphère standard (isolignes en pointillés : valeurs négatives). La figure montre que la convection profonde induit des corrélations verticales plus lisses en basse couches. (Figure tirée de Brousseau et al 2011)

## Partie 3 : Etude des erreurs de prévision

Même à quelques heures d'échéance, la qualité des prévisions varie beaucoup d'un jour à l'autre. Ce phénomène a été expliqué par la théorie du chaos formulée par E. N. Lorenz (1963) : dans un système dynamique instable comme l'atmosphère, toute erreur même infime sur la condition initiale d'une prévision peut être amplifiée au point de rendre cette prévision inutilisable. Ce processus est très variable suivant les jours, les régions ou les paramètres considérés : la plupart des prévisions formulées dans les bulletins météorologiques s'avèrent exactes. D'autres se révèlent approximatives, ou complètement erronées. On sait maintenant que l'on ne fera jamais de prévision météorologique toujours parfaite ; on pourra seulement améliorer au fil des années la qualité moyenne des prévisions, à force de perfectionner les modèles de prévision numériques, les systèmes d'observation, et les calculateurs des centres météorologiques. Chaque amélioration, même infime, des prévisions a une grande valeur pour la société, que ce soit en termes d'économies, de confort, ou de sécurité.

### 3.1. Etudes diagnostiques

#### 3.1.1. Covariances d'erreur de prévision dans un modèle simplifié

Les erreurs de prévision sont donc à peu près inévitables. Il est pourtant possible de les étudier, et même d'en tirer parti : loin d'être un bruit blanc, elles ont, comme on va le voir, une riche structure spatio-temporelle. Leurs amplitudes et leurs corrélations nous renseignent les processus physiques d'amplification d'erreur dans les modèles numériques. C'est ce que l'on a montré avec une décomposition de l'équation du Filtre de Kalman dans un modèle simplifié de l'atmosphère à grande échelle (Bouttier 1993). Cet outil mathématique révèle l'influence des ondes de Rossby, de la diffusion et des instabilités hydrodynamiques dans la propagation et la croissance des erreurs. L'équation de prévision des erreurs dans le filtre de Kalman s'écrit sous la forme matricielle :

$$\mathbf{B} = \mathbf{D} \mathbf{M} \mathbf{A} \mathbf{D} \mathbf{M}^T + \mathbf{Q}$$

qui est l'équation (4) expliquée dans l'introduction de ce mémoire :  $\mathbf{A}$  et  $\mathbf{Q}$  sont les matrices de covariance d'erreurs dans l'état initial de la prévision et dans l'évolution du modèle,  $\mathbf{D} \mathbf{M}$  est un opérateur (*modèle linéaire tangent*) qui représente l'évolution approximative des erreurs au cours d'une prévision numérique, et  $\mathbf{B}$  est la matrice de covariance d'erreurs de la prévision (cette prévision est appelée "ébauche" dans le cadre d'une assimilation de données séquentielle, mais l'équation est valable pour toute prévision dont les erreurs sont linéarisables). Cette équation est très complexe, car elle met en jeu un nombre énorme de coefficients et d'intégrations du modèle de prévision : la calculer exactement aurait un coût calcul astronomique. En négligeant  $\mathbf{Q}$  et en diagonalisant  $\mathbf{A}$  (mise sous la forme  $\mathbf{A} = \mathbf{S} \mathbf{C}^T \mathbf{C} \mathbf{S}$ , avec  $\mathbf{S}$  diagonale), l'écart-type d'erreur de prévision  $\sigma_d$  d'un paramètre en un point défini par la forme linéaire  $\mathbf{d}^T$  s'écrit plus simplement comme la norme d'un vecteur transformé par une séquence d'opérateurs linéaires :

$$\sigma_d = \| \mathbf{C} \mathbf{S} \mathbf{D} \mathbf{M}^T \mathbf{d} \|$$

cela s'interprète physiquement en examinant les opérateurs de droite à gauche :

- $\mathbf{d}$  représente le point où l'on regarde la prévision, c'est le vecteur tel que  $\mathbf{d}^T \mathbf{x}$  est la valeur du paramètre d'intérêt dans l'état  $\mathbf{x}$ , ( $\mathbf{d}$  est habituellement le vecteur des poids d'interpolation du paramètre en un point géographique)
- $\mathbf{D} \mathbf{M}^T$  est une transformation du modèle de prévision (c'est le *modèle adjoint*) qui fournit la carte de la *sensibilité de  $\mathbf{d}$  à la condition initiale* de la prévision ; son examen montre la

signature des phénomènes physiques en jeu ;

- **S** est une modulation d'amplitude de cette sensibilité par les erreurs sur la condition initiale du modèle,
- **C** est un lissage spatial par les corrélations de ces erreurs, que l'on peut supposer gaussiennes homogènes isotropes en première approximation.

Les processus responsables des erreurs de prévision peuvent donc s'identifier par l'examen des structures de sensibilité adjointe associée, si la matrice **A** n'est pas trop complexe. Cette liaison entre filtre de Kalman et modèle adjoint est exploitée dans les systèmes d'assimilation modernes (analyse variationnelle 4D et filtres de Kalman d'ensemble) pour traiter les observations, car elle permet d'associer les observations météorologiques aux structures d'erreur de prévision les plus probables : en combinant les observations du jour avec la prévision la plus récente, cela permet de définir au mieux la condition initiale pour un modèle de prévision numérique. Cette technique est appelée *fonctions de structures dépendantes de la situation (flow-dependent structure functions)*, ou en jargon fonctions de structure "du jour", ce qui équivaut à faire une interpolation adaptative des observations sur la grille du modèle de prévision numérique. Un exemple de fonction de structure très affectée par la situation météorologique locale est présenté en figure 6. Cette étude a été publiée dans un article (Bouttier, 1993).

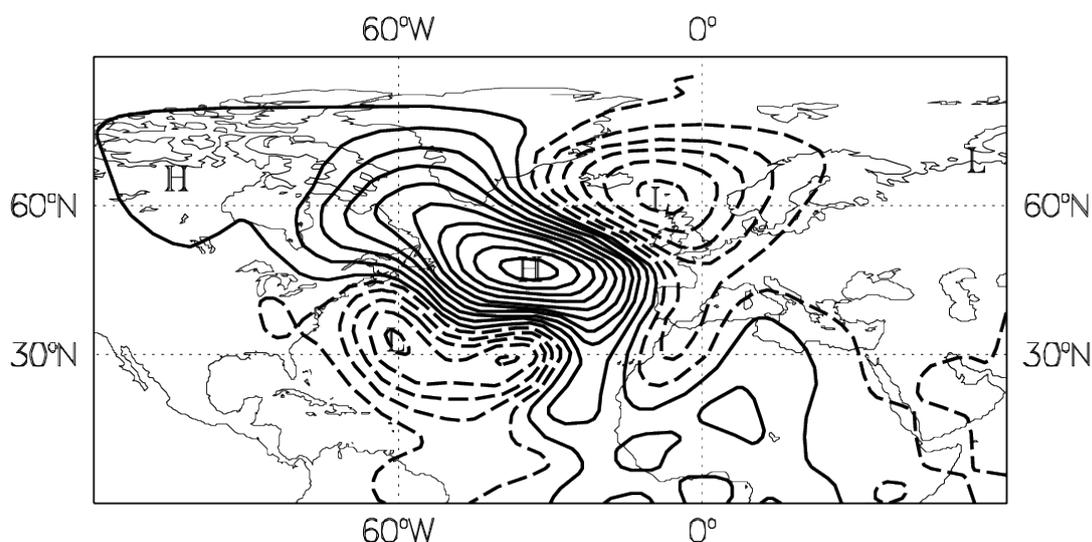


Figure 6 : exemple de fonction d'autocorrélation d'erreurs de prévision, influencée par la situation météorologique locale. Il s'agit de l'autocorrélation horizontale du géopotential à 500hPa par rapport au point marqué H au centre de la figure. Les pointillés indiquent la présence de lobes négatifs, caractéristiques de la présence d'une onde synoptique instable le long d'un jet. (Figure tirée de Bouttier, 1993)

### 3.1.2. Suivi de prévisions d'objets météorologiques par traitement d'images

(Travail publié dans Michel et Bouttier, 2006.)

La méthode précédente vise à caractériser la croissance des erreurs de prévision météorologiques, par des processus linéaires représentés dans le modèle adjoint DMT. Il serait intéressant de pouvoir étudier ces erreurs dans un cadre qui ne ferait plus d'hypothèse de linéarisation. C'est l'objectif de nombreux outils qui ont été développés pour identifier des objets météorologiques sur des images produites par radar ou par satellite. Dans certains centres, dont

Météo-France, des techniques sophistiquées de correction des prévisions numériques ont été mises au point, par correction manuelle du champ de tourbillon potentiel d'altitude. Leur principe repose sur la comparaison entre imagerie satellitaire (images infrarouge sensibles à la vapeur d'eau près de la tropopause), et imagerie synthétique simulée par des modèles numériques à l'aide de codes de transfert radiatif : si l'image satellite simulée à partir des champs du modèle est spatialement décalée par rapport à l'image observée, alors on considère que les champs dynamiques du modèle (vent, température) sont eux aussi décalés. La correction manuelle du tourbillon potentiel est un moyen pratique de modifier l'état initial du modèle numérique pour le rapprocher de l'image satellite, tout en respectant les relations physiques qui existent dans la nature entre les champs tridimensionnels de vent et de température.

L'idée de comparer imageries observées et prévues est alléchante, car la quantité d'information contenue dans les systèmes modernes d'imagerie atmosphérique est très riche. Cependant, pour l'appliquer à grande échelle, que ce soit pour caractériser objectivement les erreurs de prévision ou pour alimenter un système d'assimilation de données, il faut en faire un processus automatique, ce qui nécessite trois opérations non-triviales :

- la production d'images synthétiques en sortie de modèle, avec une qualité comparable aux imageries observées. C'est devenu possible grâce à des opérateurs d'observation perfectionnés qui permettent de comparer les modèles avec des mesures télédétections. On citera RTTOV pour la simulation de radiances satellitaires (Saunders 1999), et les simulateurs radar (cf. par exemple Caumont et al 2006). Les performances de ces simulateurs dépendent fortement du réalisme physique des modèles, notamment la représentation explicite de la distribution 3D des hydrométéores, et de la qualité instrumentale des imageurs. Dans l'étude présentée ici, les performances spectrales de l'imageur SEVIRI des satellites Météosat Seconde Génération ont grandement facilité l'application de RTTOV, par rapport aux imageurs Météosat de la génération précédente.
- l'extraction d'objets météorologiques significatifs dans les images observées et prévues. Dans cette étude, on s'est intéressé aux intrusions froides à proximité des jets d'altitude, car elles sont généralement associées à des anomalies de tourbillon potentiel (Rosting et al 1996). Ces objets sont définis comme des maxima locaux du champ de radiance dans un canal donné (l'image "vapeur d'eau" IR 6,2microns ; les objets sont précisément définis comme des groupes de pixels connexes entourant chacun un maximum local de radiance). Pour les identifier de manière fiable, il faut appliquer de traitement d'image : les intrusions sèches proprement dites sont des zones connexes du champ de radiances, les jets sont des squelettes (autrement dit, des lignes de maxima) sur le champ de vitesse du vent du modèle. Pour améliorer la détection et réduire les artefacts dus aux zones sèches sans intérêt dynamique, ces techniques d'extraction ont été associées à des critères de cohérence spatio-temporelle, qui consistent à ne retenir que les intrusions sèches qui restent visibles durant plusieurs heures consécutives. Les objets suivis sont donc des "trajectoires" d'intrusions sèches, chacune étant caractérisée par une séquence de positions sur des images successives. On peut les caractériser à chaque instant par leur taille ou leur radiance maximale. Cette étape est semblable à l'identification des dépressions tropicales sur les images satellitaires dans les grands centres de prévision cyclonique.
- la comparaison entre intrusions froides détectées sur l'imagerie satellitaire d'une part, et sur l'imagerie synthétique d'autre part. Comme on compare des objets, et non les images elles-mêmes, la définition d'une distance entre images n'est pas triviale. Il se peut qu'un objet existe sur l'image satellitaire et pas dans le modèle, ou vice versa. Il faut donc définir des couples (intrusion observée, intrusion prévue) et imposer que leur distance mutuelle ne soit pas trop grande. On peut alors étudier l'erreur de prévision des intrusions sèches en termes

d'erreur de positionnement, et d'erreur de température pour chaque couple ainsi identifié.

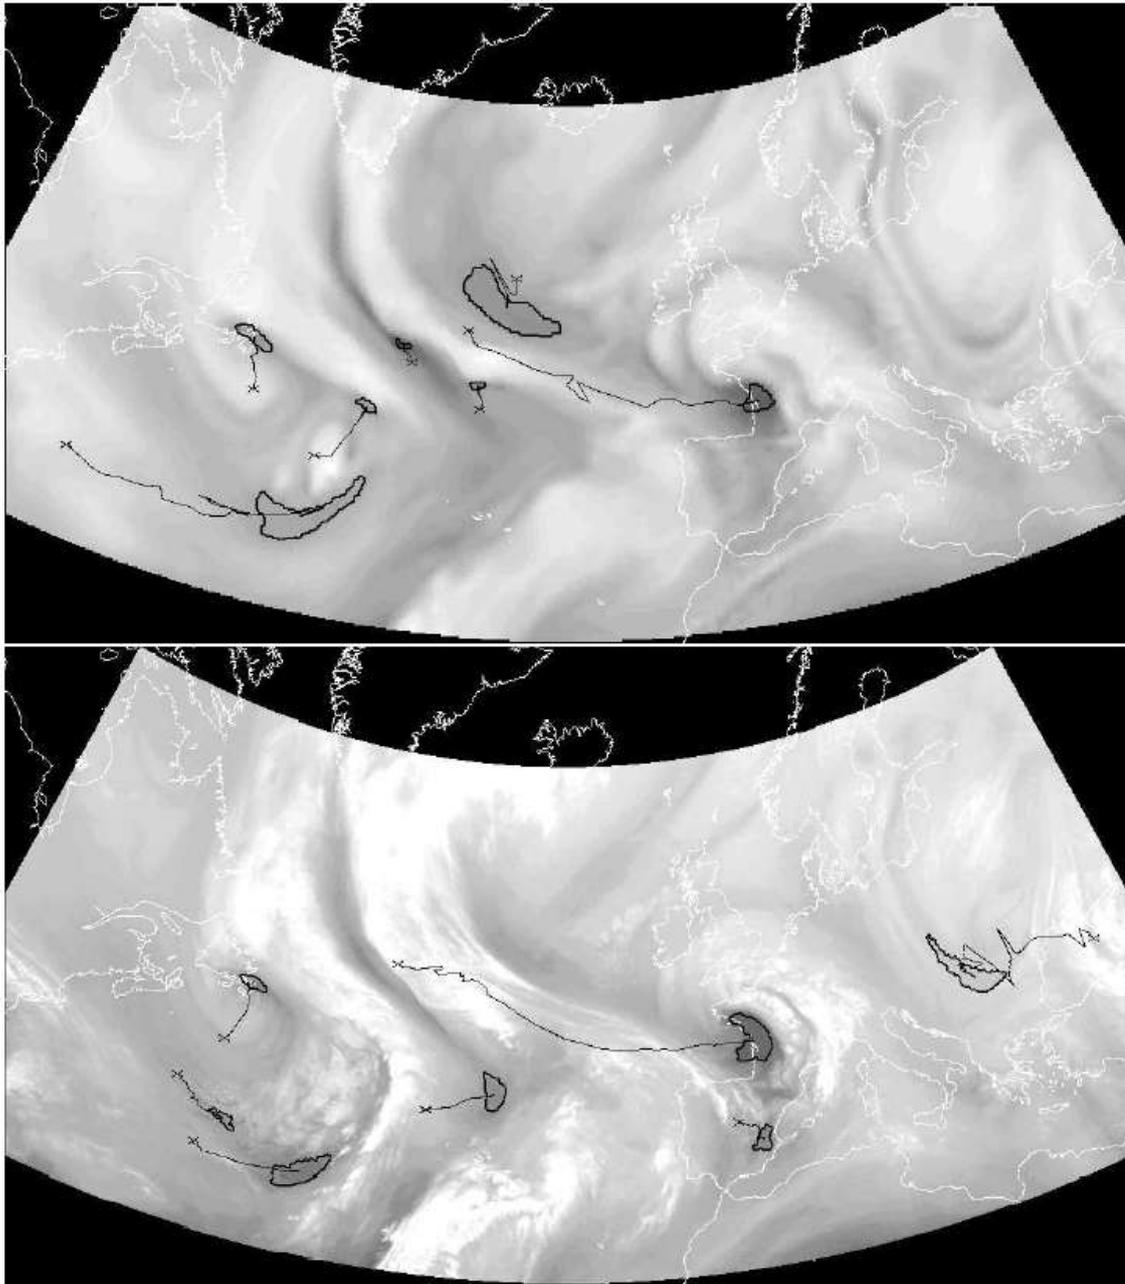
Ce processus, assez complexe, a été mis en oeuvre avec le modèle ARPEGE dans le cadre de la thèse de Yann Michel, et publié dans un article (Michel et Bouttier 2006). Un exemple de son application dans un cas particulier est montré en figure 7. On a pu montrer qu'il permettait de caractériser un nombre significatif de cyclogénèses d'altitude intenses sur l'Atlantique Nord, et qu'il y avait une relation statistique entre, d'une part, la température de brillance, et, d'autre part, le champ de tourbillon potentiel dans les intrusions sèches simulées. Cela suggère, et c'est un résultat nouveau, qu'il est possible de corriger le champ de tourbillon potentiel d'altitude des modèles à partir des images des satellites géostationnaires, ce qui revient à exploiter ces derniers à une résolution beaucoup plus élevée (~7km) que l'utilisation qui en est faite en assimilation opérationnelle. (Par exemple, la densité d'assimilation des radiances SEVIRI dans le système AROME est actuellement limitée à une cinquantaine de kilomètres). On pourrait imaginer par exemple, lorsqu'un décalage spatial important est identifié entre modèle et observation, d'assimiler dans l'analyse 4DVar deux pseudo-observations de tourbillon potentiel, l'une pour combler la dépression préexistante dans le modèle (si elle existe), l'autre pour en créer une nouvelle à la bonne place. Cette technique exploite à fond la théorie de la dynamique du tourbillon potentiel d'altitude, et ne nécessite pas de calcul complexe de covariances d'erreur comme le nécessite le filtre de Kalman, puisque la structure des corrections de l'analyse provient de la distribution des pseudo-observations.

**Perspectives :** ce travail a eu lieu à la suite des tempêtes de 1999 sur la France, qui avaient suscité un grand engouement pour la correction manuelle des tempêtes hivernales dans les modèles numériques. Pour l'application opérationnelle de la méthode décrite, il restait à automatiser la construction de pseudo-observations de tourbillon potentiel à partir d'objets identifiés sur l'imagerie. Une étude a révélé ensuite que la relation entre radiance et tourbillon n'était qu'approximative, car les radiances sont sensibles aux propriétés atmosphériques sur une couche assez épaisse, où vent, température et humidité ne sont pas barotropes. Par conséquent, bien que le traitement d'images soit utile pour détecter des erreurs de prévisions dans l'espace des radiances, il est difficile d'en déduire une correction précise dans l'espace du champ de tourbillon potentiel. Par ailleurs, la relation mathématique entre tourbillon potentiel et altitude de la tropopause (qui est à la base de l'analyse subjective des images satellitaires en canal vapeur d'eau) n'est pas aussi simple que ce qui est suggéré dans les publications sur des études de cas (par ex. Georgiev 1999). Il s'est donc avéré difficile d'obtenir un impact robuste d'une correction de tourbillon potentiel par ce procédé. La correction manuelle du champ de tourbillon potentiel est d'ailleurs progressivement tombée en désuétude dans les grands centres météorologiques, parce qu'au fil des années la qualité des prévisions numériques à courte échéance s'est beaucoup améliorée : dans les modèles opérationnels globaux, il est devenu très rare qu'une erreur majeure de prévision d'altitude à l'échelle synoptique puisse être visuellement identifiée à des échéances inférieures à 24h. Il est donc difficile de montrer objectivement que des corrections empiriques, manuelles ou non, du champ de tourbillon potentiel améliorent les prévisions de manière statistiquement robuste.

Un autre domaine d'application du traitement d'image à l'assimilation est en vogue actuellement : il concerne le repositionnement des structures convectives à échelle fine (de l'ordre de la dizaine de kilomètres) dans des modèles météorologiques régionaux à haute résolution, où la convection profonde est explicitement simulée. Brewster (2003) a testé une méthode de repositionnement dynamique de supercellules à partir d'imagerie radar dans le modèle WRF. Le groupe espagnol AEMET étudie actuellement l'effet de déformations (*morphing*) des champs d'analyse du modèle AROME, ces déformations étant calculées à partir de méthodes d'appariement par flux optique entre champs du modèle et champs observés par satellite dans des zones convectives. Dans les deux cas, le but est de positionner précisément les cellules convectives dans la

condition initiale d'un modèle de prévision numérique, car l'assimilation brute d'observations, même à haute résolution, ne semble pas encore capable d'analyser l'atmosphère aux échelles les plus fines représentées par le modèle. Cette idée est à la base du sujet de doctorat actuel de Raphaël Legrand, dont je suis membre du comité de thèse.

La difficulté des méthodes de repositionnement est, comme on l'a constaté dans notre étude, de spécifier une correction multivariée des champs du modèle à partir d'un décalage spatial identifié dans l'espace des observations. Lorsque les champs analysés ne sont pas suffisamment cohérents dans l'espace, ou ne respectent pas les équilibres thermodynamiques qui prévalent au sein des nuages convectifs, l'expérience montre que le modèle "oublie" assez vite les corrections apportées par l'analyse, et les prévisions ne sont pas significativement modifiées. Montmerle et Berre (2010) ont montré que les covariances d'erreurs d'ébauche sont, dans les systèmes précipitants, assez différentes des covariances moyennes utilisées par les systèmes d'assimilation actuellement opérationnels à mésoéchelle. Par exemple, pour créer un nuage d'orage (qui est un phénomène plutôt facile à observer dans les zones couvertes par des radars météorologiques), il ne suffit pas de saturer une colonne d'atmosphère ; il faut aussi que le profil vertical de température, d'hydrométéores, le cisaillement de vent, les propriétés de l'environnement, etc, soient propices à une évolution réaliste de cet orage dans le modèle. Il faut donc améliorer les fonctions de structure des systèmes d'assimilation pour que ces méthodes puissent fonctionner. Cela nous ramène à notre projet d'améliorer les covariances du système d'assimilation. D'ici quelques années, il est probable que les systèmes d'assimilation à mésoéchelle seront suffisamment performants pour assimiler, non seulement des données observées brutes comme c'est le cas actuellement, mais aussi des objets météorologiques tels que des orages, bancs de brouillard, fronts de rafales, etc. qui sont visibles sur les imageries, mais non directement assimilables à la résolution observée.



*Figure 7 : application de la procédure d'identification des intrusions froides en altitude, sur une prévision du modèle numérique ARPEGE (en haut) et sur une image satellitaire (en bas, composite GOES+METEOSAT). Les contours fermés sont les intrusions froides, les lignes ouvertes sont leurs trajectoires au cours des heures précédentes.(Figure tirée de Michel et Bouttier 2006)*

### **3.1.3. Sensibilité des erreurs de prévision aux observations utilisées**

(Travail publié dans Bouttier et Kelly 2001, et dans Brousseau et al 2013)

Bien que passionnante, l'étude des algorithmes d'assimilation et des modèles de covariances d'erreur ne doit pas faire oublier que le but ultime de ces travaux est l'amélioration des prévisions météorologiques. Il est donc important de contrôler que les améliorations théoriques apportées aux systèmes d'assimilation se traduisent bien par une capacité accrue à utiliser les observations.

Ironiquement, cet aspect du problème a reçu relativement peu d'attention jusqu'à présent, et notre compréhension de l'utilisation des observations en assimilation est encore très limitée. Schématiquement, il existe deux approches du problème :

- mesurer directement l'impact de modifications du système d'observation utilisé par un système d'assimilation, cet impact étant mesuré par des variations de scores de prévisions. Cette approche, appelée Observing System Experiment (OSE), est détaillée ici. Elle prend en compte toute la complexité du système d'assimilation et de prévision, y compris les non-linéarités, les hypothèses de calcul, et l'évolution des erreurs au cours du cycle d'assimilation. Elle est rigoureuse, mais très coûteuse, et j'ai eu la chance de pouvoir effectuer au CEPMMT la première OSE en vraie grandeur avec un système 4D-Var.
- mesurer indirectement cet impact à travers le calcul de diagnostics de sensibilité de fonctions des prévisions, par rapport aux valeurs observées dans un système d'assimilation donné. Différents types de diagnostics ont été proposés, ils consistent tous à mesurer l'impact marginal de chaque observation (ou de groupes d'observations prédéfinis) dans chaque analyse sur une période donnée, et à cumuler ces impacts sur de longues périodes pour obtenir des informations statistiques sur l'impact de différents types d'observations. La plupart reposent sur des hypothèses de linéarité de l'analyse, voire des prévisions, par rapport aux valeurs observées. Certaines supposent que l'analyse est statistiquement optimale (notamment, qu'elle est optimale au sens du BLUE). L'approximation la plus critiquable est sans doute l'absence de prise en compte de l'évolution des erreurs au cours du cycle d'assimilation : dans un système d'assimilation réel, une observation donnée influe, non seulement sur l'analyse effectuée au même instant, mais aussi sur les analyses suivantes. L'impact de ces hypothèses étant mal compris, on ne sait pas trop quelles conclusions pratiques on peut ou non tirer des résultats obtenus. Ces méthodes suscitent pourtant un grand engouement du fait de leur relative souplesse d'utilisation ; l'une d'elles a été testée dans le système 3DVar AROME, comme expliqué à la fin de cette partie.

La première étude a été une expérience OSE dans le système d'assimilation 4D-Var du CEPMMT. L'objectif était de comprendre comment la mise en oeuvre récente de l'algorithme 4D-Var (par opposition à l'ancien 3D-Var), et d'une nouvelle version du modèle de covariances d'erreurs d'ébauche Jb (celui que j'ai développé en section 2.1), modifiaient l'efficacité d'utilisation des observations dans les prévisions du CEPMMT. Une OSE sur une version plus ancienne du système du CEPMMT, effectuée quelques années plus tôt (Andersson et al 1991, avec une technique d'interpolation optimale), servait de référence. Notre nouvelle OSE consistait en 6 semaines d'assimilation et de prévision du système opérationnel du CEPMMT, réparties sur plusieurs saisons, dans lesquelles étaient simulés différents scénarios de modification du réseau d'observation assimilé : suppression des radiances TOVS, des vents satellitaires SATOB, radiosondes, avions, et bouées notamment. L'utilité de chacun de ces segments du réseau d'observation était mesurable par la dégradation correspondante des scores de prévisions.

Le plus difficile dans une OSEs est d'obtenir des impacts sur les scores qui soient significatifs : avec une période de test limitée, on ne peut en pratique montrer d'impact que sur de larges zones (hémisphères extratropicaux, ou zone intertropicale). Lorsque l'on n'observe pas d'impact de la suppression d'un type d'observation, cela ne signifie pas que les stations correspondantes soient inutiles, mais plutôt que leur impact ne s'est pas manifesté au cours de la période de test effectuée. Il faut donc se garder d'en tirer des conclusions hâtives sur le rapport coût/bénéfice des réseaux d'observations météorologiques. A contrario, la présence d'un impact robuste au cours d'une OSE est une preuve indubitable de la valeur d'un système d'observation (par analogie, s'il n'y a aucun incendie sur une période donnée dans un quartier où une caserne de pompiers est installée, cela ne suffit pas à démontrer que les pompiers y sont inutiles, mais si un

incendie y survient, il est facile d'argumenter que la présence de pompiers présente un intérêt). Ici, on a pu démontrer la grande valeur des radiosondages et des radiances satellitaires (il s'agissait surtout à l'époque des ATOVS en ciel clair, cf. figure 8), y compris dans les zones peuplées de l'hémisphère nord. L'utilité des SATOB, assez critiqués à l'époque à cause de leur faible impact, a pu être démontrée pour les zones tropicales. Ces résultats, publiés en 2001, ont été largement repris dans les études stratégiques sur l'évolution des systèmes d'observations météorologiques à grande échelle (notamment à l'OMM et dans les agences spatiales), jusqu'à leur mise à jour suivante par le CEPMMT en 2004 (Kelly et al 2004) afin de tenir compte de l'évolution incessante des réseaux d'observation. Ce type de travail, bien que conceptuellement simple, présente donc une grande importance socioéconomique, notamment pour prouver que les programmes de satellites météorologiques sont de l'argent bien dépensé. Scientifiquement, le résultat clé a été que la complexification des fonctions de structure dans le système d'assimilation (c'est à dire la révision du Jb et le passage du 3D-Var au 4D-Var) a beaucoup amélioré l'utilisation des radiances satellitaires. En effet, ces radiances ne fournissent qu'une information à basse résolution spatiale, et quasiment limitée au champ de température : elles permettent d'améliorer l'analyse du fluide atmosphérique, mais uniquement si la méthode d'assimilation comporte les bons couplages statistiques entre variables (notamment entre la masse et le vent à différentes échelles). A la même époque, l'impact des radiances ATOVS dans des systèmes d'assimilation plus rudimentaires (par exemple en France, au Canada ou en Allemagne) était très limité: ce travail d'OSE a donc aidé à motiver l'adoption de meilleures techniques d'assimilation dans la communauté météorologique.

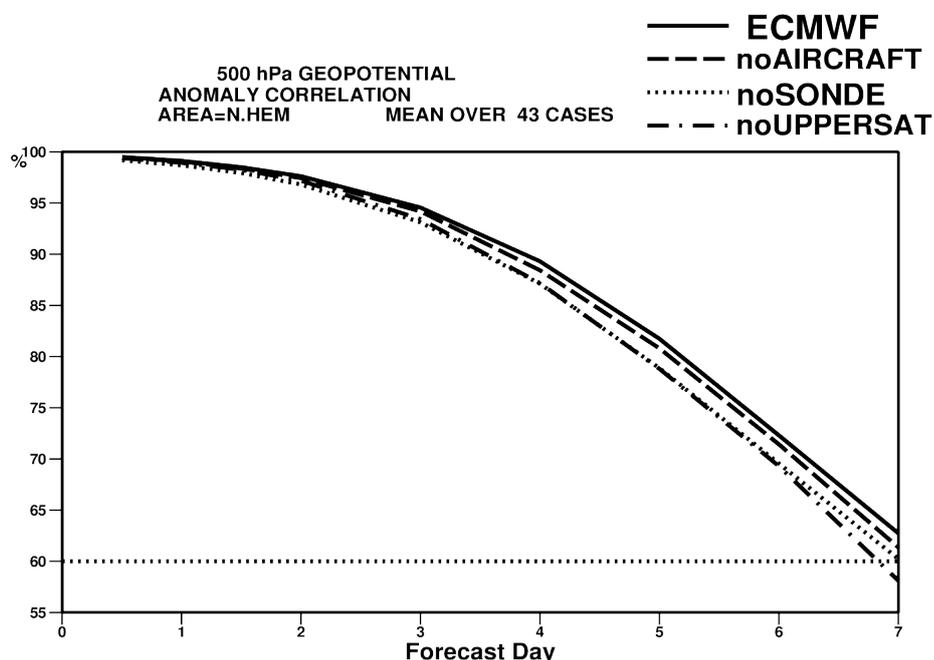


Figure 8 : Illustration de l'impact des observations sur les prévisions du CEPMMT au cours d'une expérience OSE 4D-Var. Le graphique montre l'évolution du score du modèle (anomalie moyenne de corrélation du géopotential à 500hPa ; la prévision est d'autant meilleure que ce score est élevé) en fonction de l'échéance de prévision, avec le même système d'assimilation/prévision, mais différentes configurations du réseau d'observation : réseau complet (courbe 'ECMWF'), réseau sans avions, sans radiosondes, sans radiances ni vents satellitaires (courbes noAIRCRAFT, noSONDE, noUPPERSAT, respectivement). La conclusion est que les radiosondes et les satellites sont les systèmes d'observation les plus importants pour la qualité des prévisions sur l'hémisphère

nord, et qu'ils ont à peu près le même poids. (Figure tirée de Bouttier et Kelly, 2001)

Une étude plus récente sur l'impact des observations a été menée dans le cadre du système de prévision régional AROME. Le coût numérique très élevé de ce système n'a pas jusqu'à présent permis d'y effectuer une OSE d'envergure. L'impact des observations régionales y étant combiné avec celui des observations globales (c'est à dire, assimilées à grande échelle par le système ARPEGE qui fournit ses conditions aux limites à AROME), il faudrait de très longues périodes de test pour étudier l'impact de petits sous-réseaux régionaux, puisque leur impact sur la qualité des prévisions est atténué par la présence des conditions aux limites à grande échelle. De plus, il faudrait que ces OSE AROME contiennent un grand nombre d'évènements météorologiques à fort impact, qui permettent de montrer l'intérêt de la haute résolution d'AROME. En attendant qu'un tel système de test soit à portée, il est intéressant d'explorer l'impact relatif de différents types d'observations régionales à l'aide d'outils plus approximatifs, mais aussi plus flexibles, que des OSEs.

La méthode retenue pour étudier l'impact des observations dans AROME est le 'diagnostic *a posteriori* de réduction des variances d'erreur' (Desroziers et al 2005). Cette technique consiste à calculer, au cours de l'analyse, la réduction de variance d'estimation, c'est à dire la variation de trace des matrices de covariances d'erreur :  $\text{Tr}(\mathbf{B}) - \text{Tr}(\mathbf{A})$ . Cette quantité peut être estimée à un coût numérique faible, à condition de faire trois hypothèses :

- que l'analyse est un BLUE optimal, ce qui permet d'utiliser l'identité  $\mathbf{A} = (\mathbf{I} - \mathbf{K}\mathbf{H})\mathbf{B}$  , donc  $\text{Tr}(\mathbf{B}) - \text{Tr}(\mathbf{A}) = \text{Tr}(\mathbf{K}\mathbf{H}\mathbf{B})$  ;
- que les perturbations finies des observations, appliquées dans une assimilation d'ensemble (cf. partie 1.5), produisent des perturbations d'analyses qui en dépendent à peu près linéairement ;
- que la quantité  $\text{Tr}(\mathbf{K}\mathbf{H}\mathbf{B})$  peut s'estimer par une méthode de Monte Carlo, sous forme de la moyenne de  $\eta^T \mathbf{H}\mathbf{K}\eta$ , où  $\eta$  est une variable aléatoire gaussienne, avec un bruit d'échantillonnage qui devient raisonnable à partir de quelques jours d'assimilation d'ensemble AROME (le caractère "raisonnable" signifie que le bruit d'échantillonnage doit être en moyenne inférieur aux impacts d'observations que l'on cherche à identifier)

Ce diagnostic de réduction de variance peut se restreindre à des sous-ensembles du réseau d'observation, et à des paramètres, niveaux et longueurs d'ondes spécifiques de l'état du modèle, en insérant des opérateurs de projection à des endroits appropriés du calcul. Cela permet d'extraire une foule d'informations sur la sensibilité du système d'assimilation AROME aux observations (si l'on a foi dans les hypothèses invoquées). Par exemple, on peut montrer que ce sont les avions et les radars qui ont le plus d'impact sur l'analyse d'altitude, alors que les réseaux de surface ont une influence prépondérante sur les basses couches. L'influence des radars est plus forte lorsqu'il pleut, puisque les vents radar doppler ne sont, en France, observables qu'en présence de pluie. Les radars fournissent l'essentiel de l'information à échelle fine (à une résolution meilleure qu'une cinquantaine de kilomètres), car ils sont les seuls à avoir une couverture spatiale adéquate. L'impact des radiances satellitaires est modeste, malgré leur nombre élevé, probablement parce qu'elle ne sont pour l'instant assimilées qu'à une résolution assez faible (moins bonne que la résolution instrumentale). Un exemple de résultat de cette méthode est présenté en figure 9.

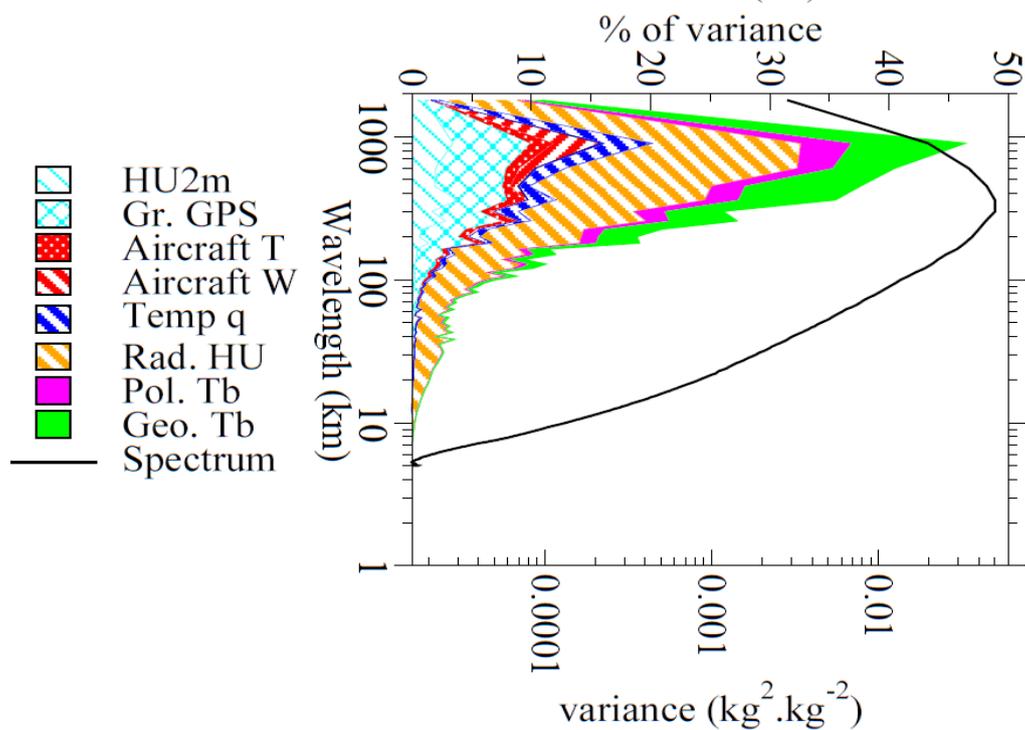


Figure 9 : dépendance à l'échelle horizontale de l'impact des différents types d'observation assimilés sur l'analyse 3DVar AROME de l'humidité spécifique à 800hPa, en moyenne sur plusieurs jours, mesurée par le diagnostic Tr(KHB). Les types d'observation listés en légende sont, respectivement : réseau de surface, délais zénithaux GPS sol, observations par avion de température et de vent, humidités des radiosondages, humidités déduites des réflectivités radar, radiances ( $T_b$ ) des satellites en orbite polaire et géostationnaire. La largeur des plages de couleur est proportionnelle à l'impact. Cette figure montre que les observations les plus importantes pour ce paramètre sont, à grande échelle, les humidités de surface, les GPS, les radars et les radiances géostationnaires. Seuls les radars apportent de l'information à échelle fine, et encore, très en deçà de la variance totale d'erreur (courbe noire). (Figure tirée de Brousseau et al 2013)

Ce diagnostic, initialement développé dans le système ARPEGE, a donc été appliqué à AROME et les résultats ont été acceptés pour publication (Brousseau et al 2013). On peut débattre de son intérêt pour établir la valeur précise des différents réseaux d'observations, puisqu'il dépend d'hypothèses d'optimalité du système d'assimilation. C'est cependant un outil assez fin pour distinguer l'impact des différents types d'observation, ce qui est particulièrement intéressant pour valider des modifications du système d'assimilation. Par exemple, un défi actuel est l'amélioration de l'utilisation des réflectivités radar, par exemple en rendant les covariances d'erreur d'ébauche  $\mathbf{B}$  du 3D-Var plus sensibles à la présence de nuages précipitants, ou en incluant les hydrométéores dans le vecteur d'état  $\mathbf{x}$  assimilé dans AROME. En principe, ces développements devraient permettre d'augmenter la sensibilité actuelle de l'analyse aux réflectivités radar, donc *a priori* d'améliorer les prévisions si la mesure est de bonne qualité. Des travaux similaires sont en cours pour l'assimilation des radiances nuageuses.

### 3.1.4. Bilan sur les études diagnostiques

On a vu trois types différents de diagnostics : les covariances d'erreur de prévision, qui renseignent sur l'amplitude et les structures spatiales des erreurs dans un cadre linéarisé ; les erreurs

de déplacement d'objets, qui sont adaptées aux structures cohérentes y compris lorsque leur évolution est non-linéaire ; et l'influence des observations sur les analyses et les prévisions, qui permettent de compléter notre vision de la propagation d'information en prévision météorologique : en effet il n'est pas très utile de comprendre comment évoluent les erreurs dans la prévision, si l'on ignore quelles observations permettent de les corriger. On constate en fait que même des observations abondantes (comme les radiances) peuvent s'avérer inutiles si le système d'assimilation n'est pas adapté à leur utilisation. La connaissance des structures d'erreur de prévision permet de comprendre si ces faiblesses proviennent d'un manque de variabilité spatio-temporelle des covariances d'erreur d'ébauche. Cela permet ensuite d'orienter les recherches en assimilation pour améliorer l'utilisation des observations. Cette méthode de travail suit un schéma itératif :

- la sensibilité des analyses et prévisions aux observations permet d'identifier quelles observations ont ou non de l'importance pour la prévision. Les diagnostics *a posteriori* de l'analyse, et les OSEs, fournissent des mesures respectivement linéaires et non-linéaires de cette sensibilité.
- les structures d'erreurs de prévision permettent d'identifier si la distribution des différents réseaux d'observation, et les corrélations d'erreur d'ébauche modélisées dans les systèmes d'assimilation, sont appropriées pour corriger ces erreurs dans l'assimilation. Les diagnostics de covariance d'erreur, et d'erreur de déplacement, informent respectivement sur des aspects linéaires et non-linéaires de ce problème ; la présence de fortes erreurs de déplacement étant intuitivement un signe que des techniques exclusivement linéaires (comme le 3D-Var) auront a priori peu de chances de fonctionner.

L'existence d'une compatibilité entre fonctions de structures de l'assimilation, et structures des erreurs de prévision, est une condition nécessaire mais non suffisante pour pouvoir corriger ces erreurs. Il faut aussi disposer de réseaux d'observation dont la couverture spatiale et temporelle soit suffisante. Lorsque l'on trouve une forte sensibilité de l'analyse ou des prévisions à des observations qui sont en petit nombre, cela suggère que la priorité n'est pas tant d'améliorer le système d'assimilation, que de déployer plus d'observations. Dans AROME, c'est le cas des humidités troposphériques d'altitude : le fort impact des humidités de radiosondages (rapporté à leur nombre) indique que, comme montré dans d'autres études par des procédés indépendants, la priorité pour la prévision à mésoéchelle est de d'alimenter l'assimilation avec nouvelles mesures d'humidité à haute résolution. Cela pourrait se faire, par exemple, en développant les mesures par avion, en utilisant mieux les réflectivités radar 3D, ou en extrayant de l'information contenue à haute résolution verticale dans les radiances satellitaires.

### 3.2. Simulation des erreurs par prévision d'ensemble

Toutes les études ci-dessus visaient à améliorer les prévisions météorologiques. Mais elles ont aussi montré la nature complexe des erreurs de prévision : quelle que soit la qualité de l'assimilation et du modèle de prévision, il subsiste toujours une incertitude sur la prévision, qui peut varier en fonction de la situation, soit parce que l'atmosphère est plus ou moins prévisible, soit parce que l'on n'a pas su utiliser correctement les observations pour réduire cette incertitude. Dans le cas fréquent où l'information recherchée est, non pas la valeur la plus probable d'un paramètre météorologique prévu, mais la probabilité qu'il atteigne un certain seuil, la prévision déterministe ne répond qu'en partie aux besoins. Par exemple, lorsque l'on organise un pique-nique en situation d'orages épars, la valeur de pluie la plus probable est souvent zéro, mais la probabilité de recevoir une averse peut être un facteur important à connaître. Il faut pour cela effectuer des prévisions probabilistes, ce qui nécessite en pratique d'effectuer des prévisions d'ensemble (à l'exception des paramètres pour lesquels la climatologie constitue une prévision meilleure que les prévisions d'ensemble).

L'autre motivation importante pour faire de la prévision d'ensemble est qu'il s'agit d'un ingrédient clé des systèmes d'assimilation modernes (filtres de Kalman ou ensembles d'assimilation). La prévision d'ensemble est en effet la seule méthode viable pour obtenir des covariances d'erreur d'ébauche (terme  $\mathbf{B}$  ou  $\mathbf{Jb}$  des équations d'analyse) qui dépendent de la situation météorologique. Bien que l'assimilation de données et la prévision d'ensemble soient souvent considérées comme des disciplines distinctes, la qualité de la prévision d'ensemble sera *in fine* déterminante pour les performances de l'assimilation qui l'utilisera.

La technique de la prévision d'ensemble a été exposée en partie 1.5. On a cherché dans ce projet à comprendre et améliorer ses principaux aspects :

- la sensibilité des erreurs de prévision par rapport aux erreurs d'analyse,
- l'impact des erreurs de modélisation,
- le choix des couplages de grande échelle dans un modèle à aire limitée de type AROME.

#### 3.2.1. Sensibilité des ensembles aux erreurs d'analyse

(Travail publié dans Barkmeijer et al 98)

La première étude, sur les erreurs initiales, a été effectuée au CEPMMT avec le modèle IFS global. A l'époque, la prise en compte des erreurs initiales dans la prévision d'ensemble EPS du CEPMMT reposait entièrement sur la perturbation de l'analyse déterministe par les vecteurs singuliers du modèle de prévision. Le calcul des vecteurs singuliers consistait à estimer, par une méthode itérative de Lanczos, les 30 vecteurs propres  $\mathbf{x}$  associés aux plus grandes valeurs propres  $\lambda$  dans l'équation  $\mathbf{A} \mathbf{D} \mathbf{M}^T \mathbf{D} \mathbf{M} \mathbf{x} = \lambda \mathbf{x}$ , où  $\mathbf{D} \mathbf{M}$  est le modèle de prévision linéarisé, avec une physique simplifiée et une résolution réduite, linéarisé sur 48h ;  $\mathbf{A}$  est une matrice diagonale dans l'espace spectral, qui représente la norme énergie totale linéarisée. L'initialisation de l'EPS consistait à ajouter à l'analyse déterministe des combinaisons linéaires de ces vecteurs singuliers pour former les conditions initiales des 50 membres de l'EPS. Cette méthode avait l'avantage de maximiser la dispersion à moyenne échéance des prévisions de l'EPS (en fixant la dispersion des perturbations initiales à une valeur supposée cohérente avec la variance des erreurs d'analyse), ce qui était un avantage pragmatique à une époque où le principal défaut des ensembles était leur manque de dispersion (dans un ensemble statistiquement optimal, la variance des prévisions est égale à la

somme des erreurs quadratiques de la prévision moyenne de l'ensemble, et des erreurs d'observation). L'inconvénient était son manque de justification scientifique : rien ne prouve que ces vecteurs singuliers sont statistiquement distribués comme les erreurs de prévision à courte échéance.

Notre tentative pour rendre ces perturbations initiales plus rigoureuses a consisté à modifier la définition des vecteurs singuliers, pour qu'ils représentent les plus grands vecteurs propres de la matrice de covariances d'erreur de prévision à courte échéance (48h). Avec ce choix, les perturbations de l'ensemble résultant génèrent, sous hypothèse de linéarité des erreurs de prévision, la meilleure approximation possible des variances et covariances d'erreur de prévision. Mathématiquement ce résultat est obtenu si l'on remplace l'opérateur  $\mathbf{A}$  dans l'expression précédente par la matrice de covariances d'erreurs d'analyse (la matrice  $\mathbf{A}$  de l'équation (2) du BLUE). Numériquement, comme on n'a pas directement accès à  $\mathbf{A}$ , on l'approxime de la manière suivante :

- on fait l'hypothèse que  $\mathbf{A}^{-1}$  est bien approximé, à un facteur près, par la hessienne de l'analyse 3D-Var du CEPMMT (c'est à dire, la dérivée seconde  $\mathcal{J}''$  de la fonction-coût du 3D-Var). Selon la théorie du BLUE, c'est vrai si les covariances d'erreur d'ébauche et d'observation ( $\mathbf{B}$  et  $\mathbf{R}$ ) sont correctement modélisées dans le 3D-Var, et si l'opérateur d'observation  $\mathbf{H}$  est linéarisable.
- l'équation définissant les vecteurs singuliers devient alors  $\mathbf{M}^T \mathbf{M} \mathbf{x} = \lambda \mathbf{A}^{-1} \mathbf{x}$ , où l'on ne sait en général pas inverser  $\mathbf{A}^{-1}$  ; la méthode de Lanczos doit donc être remplacée par une autre méthode itérative plus complexe et coûteuse, appelée méthode de Davidson.

Sous ces hypothèses, l'inspection des vecteurs singuliers obtenus révèle l'influence des covariances d'erreur d'analyse  $\mathbf{A}$ , sur les erreurs de prévision à courte échéance. Ceci généralise, dans un modèle à haute résolution, les résultats obtenus en section 3.1 avec le filtre de Kalman complet et un modèle plus simple. Il apparaît que  $\mathbf{A}$  diffère de la norme énergie, d'une part à cause de l'effet lissant du terme  $\mathbf{Jb}$  du 3D-Var, qui était statique à l'époque, d'autre part à cause de la réduction de variance à grande échelle apportée par les observations (Figure 10). Cette étude a montré l'importance des erreurs d'analyse pour la prévision d'ensemble à courte échéance ; elle n'a cependant pas pu être utilisée opérationnellement, à cause de son coût numérique, et des déficiences du  $\mathbf{Jb}$  employé à l'époque : un  $\mathbf{Jb}$  statique, même très bien conçu, contient des corrélations spatiales trop lisses pour représenter au jour le jour les zones à croissance d'erreur rapide. Cela inhibe l'identification des modes à croissance d'erreur rapide par les vecteurs singuliers utilisant la hessienne. Il faudrait utiliser la hessienne d'un 3D-Var ou 4D-Var dont les covariances d'erreur d'ébauche varient au jour le jour (comme décrit en partie 2.2) pour éviter cet effet du  $\mathbf{Jb}$  statique, qui est encore plus pénalisant pour la prévision d'ensemble que pour l'assimilation de données.

Une solution élégante à ce problème sera apportée quelques années plus tard grâce au développement des ensembles d'assimilation (expliqués en 1.5.2), qui fournissent une information au jour le jour sur les erreurs d'analyse, sous une forme ensembliste directement utilisable pour initialiser une prévision d'ensemble : cela évite de manipuler la hessienne du 3D-Var, qui est techniquement complexe, et cela se généralise trivialement au 4D-Var. L'intérêt de cette représentation ensembliste des erreurs de prévision sera montré à la fois dans des cadres idéalisés (Descamps et Talagrand 2007), et dans des systèmes de prévision d'ensemble en vraie grandeur. En particulier, j'ai étudié l'influence de diverses stratégies d'initialisation de la prévision d'ensemble AROME, en comparant le démarrage des prévisions à partir d'une assimilation unique, par rapport à l'utilisation d'un ensemble d'assimilations, ce qui a montré l'écrasante supériorité de cette dernière méthode (Vié et al 2011, Vié et al 2012). D'après nos travaux récents, l'utilisation d'un ensemble d'assimilations AROME apparaît supérieure à d'autres méthodes d'initialisation répandues dans la communauté de prévision d'ensemble à domaine limité (ces méthodes sont l'utilisation d'ensembles d'assimilations globales à faible résolution, de conditions initiales d'une prévision d'ensemble globale, ou de *breeding* ["perturbations entretenues"]). Les ensembles d'assimilations sont

maintenant utilisés pour initialiser les prévisions d'ensembles globales du CEPMMT et de Météo-France. Cela laisse ouvertes deux questions potentiellement importantes pour l'avenir :

- dans quelle mesure la hessienne du 3D-Var ou du 4D-Var est-elle une bonne approximation des covariances d'erreur d'analyse ? Cette approximation est abondamment utilisée dans les diagnostics de sensibilité aux observations.
- la représentation des covariances d'erreur de prévision dans les ensembles d'assimilation est de rang très faible (de l'ordre de 10) ; y manque-t-il des informations cruciales pour leur utilisation comme modèles d'ébauche en assimilation de données ? (à ce sujet, les problèmes d'échantillonnage statistiques ont commencé à être étudiés, par exemple dans Raynaud et Pannekoucke (2012)).

On se propose d'étudier dans l'avenir ces deux questions à l'aide de scores ensemblistes appliqués aux analyses et aux prévisions à très courte échéance dans les ensembles d'assimilation (ce point sera développé dans la conclusion du présent rapport). Cela devrait permettre de diagnostiquer l'adéquation entre la distribution de ces ensembles, et la densité de probabilité des erreurs d'analyse et de prévision.

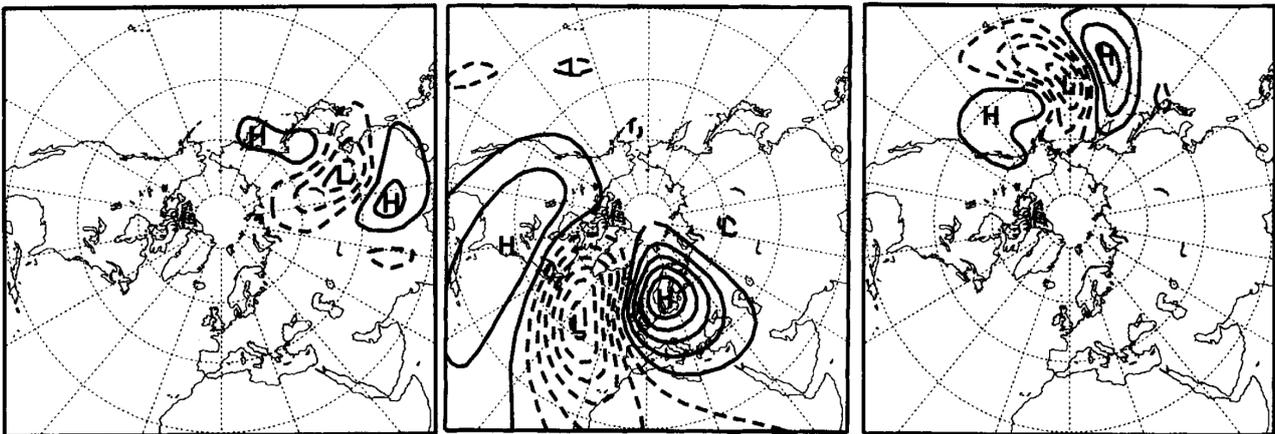


Figure 10 : comparaison du principal vecteur singulier initial le 1 novembre 1995 à 0h TU, optimisé sur 24h dans le modèle IFS, avec comme norme initiale, la norme énergie totale (gauche), la norme impliquée par le  $J_b$  du 3D-Var (milieu), la norme impliquée par la hessienne du 3D-Var (droite). La figure montre que l'effet lissant du  $J_b$  augmente l'échelle spatiale des vecteurs singuliers, et que l'introduction d'observations (en majorité sur les continents) les déplace préférentiellement sur les océans. Les isolignes montrent la fonction de courant (intervalle  $5.10^{-8}SI$ ), les valeurs négatives sont indiquées par les pointillés. (Figure tirée de Barkmeijer et al, 1998)

### 3.2.2. Sensibilité des ensembles aux erreurs de modélisation

(Travail publié dans Bouttier et al 2012)

La seconde étude, sur les erreurs de modélisation, a été menée avec le modèle AROME : comment y représenter les erreurs de modélisation ? La stratégie retenue dans plusieurs centres opérationnels, par exemple à Météo-France avec le modèle global ARPEGE, est de simuler les erreurs de modélisation en modifiant les paramétrisations physiques des membres de l'ensemble. C'est l'approche 'multiphysique'. Elle n'est pas viable en pratique dans AROME, qui ne contient à ce jour qu'un seul jeu de paramétrisations utilisables : y développer plusieurs paramétrisations significativement différentes les unes des autres, et néanmoins de qualité proche, représenterait un travail énorme, non seulement pour leur mise au point, mais aussi à long terme pour leur

maintenance au fil des évolutions futures du modèle. Par ailleurs, l'approche multiphysique pose des problèmes de fond, parce que les différences entre prévisions utilisant plusieurs physiques sont surtout des biais (c'est à dire, des différences systématiques, souvent dépendantes du type de temps, et du cycle diurne). Rien ne garantit que ces biais impliquent les mêmes structures de corrélation entre prévisions d'un ensemble multiphysique, que dans les erreurs de prévision proprement dites. Cela signifie - et c'est ce que disent souvent les prévisionnistes qui regardent les prévisions d'ensemble au jour le jour - que la dispersion d'un ensemble multiphysique, même si elle implique des variances de prévisions de scalaires réalistes en chaque point, provient souvent de différences stéréotypées entre prévisions. L'information apportée par la technique multiphysique semble donc assez pauvre. On a étudié la faisabilité d'une approche plus générale, en développant un schéma de physique stochastique pour l'ensemble AROME.

La physique stochastique utilisée dans AROME est, dans sa première version, assez simple : elle consiste à fabriquer (à l'aide de chaînes de Markov et de normalisations des spectres) des champs 2D de scalaires pseudo-aléatoires, dont les corrélations spatiales (homogènes isotropes) et temporelles (processus autorégressif AR1) sont prescrites. Ces scalaires définissent, dans chaque colonne du modèle, une modulation multiplicative de toutes les tendances physiques du modèle AROME, cette modulation valant typiquement de 50% à 150% (elle est d'amplitude plus faible près du sol et du sommet du modèle, afin d'éviter d'y créer des flux trop irréalistes). Cette physique stochastique ne touche pas aux équilibres internes entre tendances prédites par la physique AROME (puisque à l'ordre 1, on respecte les équilibres entre tendances de vent, température, humidité), mais on considère qu'il y existe une incertitude relative, de l'ordre de quelques dizaines de %, sur les tendances du modèle. Cette formulation est souvent critiquée pour son apparente absence de base physique, certains prônant des schémas stochastiques plus profondément insérés dans les paramétrisations physiques. Souvent, ceux qui ont travaillé sur l'amélioration de schémas de paramétrisations sont réticents à ce que l'on "corrompe" leurs sorties avec des nombres aléatoires. Mais il faut être lucide sur le fait que les architectures mêmes des modèles numériques actuels (avec des définitions assez simples de la particule modélisée, une séparation nette entre physique et dynamique, et une vision rigoureuse du rôle de chaque paramétrisation), sont très simplistes par rapport à ce qui se passe dans la nature (même si ces simplifications sont incontournables pour organiser les travaux de développement des modèles). L'optimalité de ces architectures n'est pas forcément claire, et beaucoup de processus importants ne semblent pas correctement modélisés. Il est donc logique de placer la représentation des erreurs de modélisation à l'extérieur des paramétrisations physiques, et de ne faire qu'un minimum d'hypothèses sur la structure de ces erreurs, puisque par définition on ne connaît pas leur nature exacte (on pourrait aller encore plus loin et considérer que la dynamique du modèle devrait elle aussi être perturbée, mais c'est techniquement beaucoup plus compliqué à cause des contraintes de stabilité et de coût numérique). Cette approche a été poursuivie avec succès par le CEPMMT (Buizza et al 1999) dans un cadre assez différent, celui de la prévision à longue échéance et à grande échelle : selon eux, aucun schéma stochastique sophistiqué n'a réussi à faire significativement mieux que celui considéré ici.

En pratique, les paramètres de la physique stochastique AROME (son amplitude et les portées des corrélations d'erreur) ont été réglés de manière empirique, afin d'obtenir un compromis entre la dégradation des prévisions que cela implique, et la dispersion supplémentaire que la physique stochastique injecte dans l'ensemble. La meilleure configuration consiste à utiliser des portées assez longues (quelques centaines de kilomètres dans l'espace, et 8h de corrélation temporelle). Il ne s'agit donc ni d'ajouter des biais systématiques, ni de créer du bruit de petite échelle : les erreurs de modélisation les plus importantes pour les prévisions semblent d'échelle assez grande, et ne sont pas constantes. Injecter ces erreurs améliore l'ensemble des scores ensemblistes, notamment leur fiabilité (la cohérence climatologique entre probabilités prévues et les fréquences observées), cf. figure 11, et leur résolution (c'est à dire, leur valeur économique pour un processus simple de prise

de décision). C'était la première fois que l'utilité de la physique stochastique avait été observée dans des ensembles à échelle convective. Cette étude a donné lieu à une publication (Bouttier 2012).

Ce travail a ouvert de multiples portes dans le domaine encore peu exploré des physiques stochastiques, en voici deux qui seront explorées ces prochaines années :

- comment identifier les situations météorologiques où les erreurs de modélisation sont plus ou moins fortes, afin de moduler l'amplitude des perturbations stochastiques du modèle ? Intuitivement, une physique stochastique trop active va dégrader inutilement les prévisions lorsque le modèle est de bonne qualité, alors qu'elle devrait être plus forte lorsque la prévision est affectée par des processus mal modélisés (comme les couches limites stables, les enclumes de nuages convectifs, ou la transition nuage/ciel clair). Il faudrait s'appuyer sur de vastes jeux d'observations (par exemple, les réflectivités radar 3D) et sur des techniques avancées d'analyse statistique, pour identifier des signatures de l'erreur de modélisation dans les erreurs de prévision.
- quelle est la relation entre physique stochastique et assimilation de données ? Intuitivement, la présence de corrélations d'erreur de modélisation va affecter les corrélations d'erreur d'ébauche. La difficulté est qu'une partie des corrélations d'erreur d'ébauche provient de la croissance chaotique des erreurs (Bouttier 1993), qui existe même en l'absence d'erreur de modélisation. Il faut donc séparer les deux types de corrélations d'erreur (celle qui est chaotique, et celle qui est liée à la modélisation). Pour y voir plus clair, il serait utile de développer des scores pour les *corrélations* d'erreur de prévision (par exemple à l'aide de scores probabilistes multivariés, cf. McLean Sloughter et al 2013), qui ont jusqu'à présent été peu étudiées.

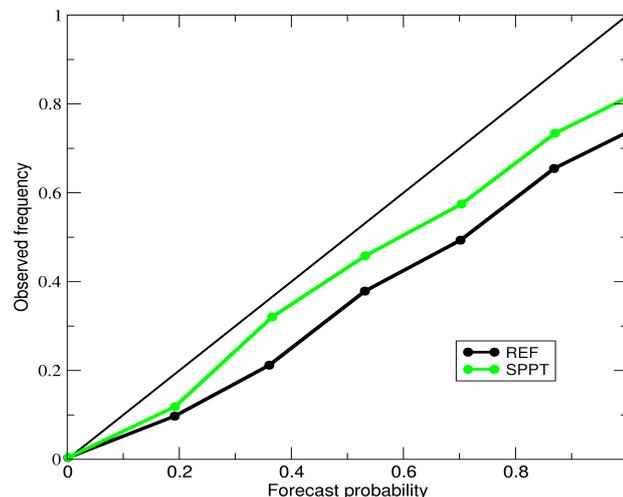


Figure 11 : impact de l'introduction de la physique stochastique sur la prévision probabiliste des précipitations cumulées en 6h, sur la France et sur une période de test de 42 jours. Le graphique est un 'diagramme de fiabilité', c'est à dire une représentation de la correspondance entre probabilités prévues et fréquences observées d'un dépassement de seuil. Le système de prévision d'ensemble est d'autant meilleur que son diagramme de fiabilité est proche de la diagonale. La figure montre que l'introduction de la physique stochastique (courbe verte par rapport à la courbe noire) améliore nettement la fiabilité des précipitations prévues. (Figure tirée de Bouttier 2012)

### 3.2.3. Sensibilité des ensembles au couplage de grande échelle

(Travail publié dans Vié et al 2012)

La troisième étude a porté sur l'influence du couplage de grande échelle dans les prévisions d'ensemble à domaine limité AROME. On sait (par ex. Vié et al 2011) que les prévisions à domaine limité sont sensibles à la qualité des prévisions à grande échelle auxquelles elles sont couplées. La sensibilité des performances probabilistes d'un ensemble à ce couplage est moins évidente. Par exemple, le système de prévision d'ensemble régional du service météorologique allemand, appelé COSMO-DE-EPS, est couplé à 4 modèles déterministes globaux, alors que celui du UK Met Office, appelé MOGREPS-UK, est couplé à un seul système de prévision d'ensemble global. Le système italien COSMO-LEPS est lui couplé à une classification des prévisions d'ensembles EPS du CEPMMT. Le choix du couplage est-il important ? Un résultat important établi dans Vié et al (2012) est que le couplage à un ensemble global est très supérieur au couplage à un modèle unique (figure 12), aussi bien pour la prévision des précipitations méditerranéennes extrêmes, qu'en termes de scores probabilistes moyens sur de longues périodes. Ce n'était pas évident a priori puisque les scores des membres de l'ensemble global sont moins bons que ceux du modèle déterministe global (en particulier, la résolution de l'ensemble global est nettement plus faible). La conclusion, qui rejoint les travaux sur la physique stochastique, est qu'il est plus important, dans un ensemble régional, de perturber toutes les sources d'erreur (y compris dans le couplage de grande échelle) que d'utiliser le meilleur coupleur possible. A partir de seulement quelques heures d'échéance de prévision, même avec un grand domaine de prévision (celui du modèle AROME-France s'étend sur environ 2000x2000km<sup>2</sup>), l'influence du coupleur sur les prévisions d'ensemble est très importante.

On peut alors se demander s'il y a moyen de faire encore mieux que l'utilisation brute d'un ensemble global pour définir les conditions aux limites d'un ensemble régional. Comme les ensembles régionaux sont de plus petite taille que les ensembles globaux (à cause de leur coût numérique), on dispose d'une certaine liberté dans le choix du sous-ensemble des membres globaux qui seraient effectivement utilisés par la prévision d'ensemble régionale. Dans COSMO-LEPS (Marsigli et al 2005), une technique de classification est utilisée pour maximiser la dispersion de l'ensemble régional, en sélectionnant les membres coupleurs les plus dissemblables les uns des autres. Cette technique a été testée dans l'ensemble AROME par Nuissier et al (Nuissier et al 2012) : différentes techniques de classification sont possibles, en termes de métrique utilisée (c'est à dire, avec quels paramètres et échéances mesure-t-on la dissemblance entre deux prévisions) et d'algorithme de classification (classification K-means, ou classification hiérarchique par lien complet). J'ai moi-même testé une classification qui maximise la variété des paramétrisations physiques utilisées dans l'ensemble coupleur PEARP .

A l'heure actuelle, il est difficile de montrer que ces techniques de sélection de coupleurs produisent de meilleurs ensembles qu'une sélection aléatoire des membres coupleurs. On peut simplement dire que, lorsqu'un épisode de fortes précipitations survient, une classification ciblée sur la zone permettra de prévoir de plus fortes précipitations (puisque la classification va à coup sûr sélectionner au moins un membre proche des précipitations maximales prévues par l'ensemble global). D'un point de vue théorique, si les membres de l'ensemble global sont équiprobables (ce qui est presque toujours le cas en pratique), les sélectionner de manière aléatoire produira généralement un ensemble équiprobable de prévisions à domaine limité. Les sélectionner de manière orientée, par exemple par classification, tendra à rompre ce caractère équiprobable, souvent en privilégiant les membres coupleurs qui sont loin du centre de l'ensemble. Cela peut être un avantage si les ensembles (coupleur ou couplé) ont tendance à être sous-dispersifs, puisque cela revient à augmenter artificiellement la dispersion de l'ensemble constitué par les membres sélectionnés. Le développement des ensembles tendant, au fil des années, à produire des ensembles dont la dispersion est aussi correcte que possible (c'est à dire, cohérente avec les erreurs de prévisions),

l'utilisation d'une classification peut donc avoir des effets négatifs : par exemple, si l'on sélectionne systématiquement les membres qui prédisent de fortes pluies, on va corrompre la prévision de ces événements en créant des fausses alarmes. Il reste donc à inventer une méthodologie de classification qui préserve les qualités statistiques des ensembles utilisés. Il se peut que la solution optimale consiste à utiliser les ensembles ainsi créés comme des échantillonnages non équiprobables de la loi de probabilité prévue, en considérant que les membres appartenant à des classes plus peuplées que les autres (dans l'ensemble coupleur) ont plus de chance que les autres de se produire.

Intuitivement, on peut peut-être ainsi améliorer l'échantillonnage statistique d'événements extrêmes, en s'arrangeant pour que, même avec un ensemble de petite taille, on ait toujours au moins un membre de l'ensemble qui prévoit cet événement. Mais il reste à prouver objectivement que cela permet de mieux prévoir sa probabilité qu'un échantillonnage équiprobable. La question est cruciale pour la prévision des événements à fort impact, et elle sera ardue, car il faudra pour y répondre effectuer des tests sur de longues périodes (des dizaines de cas indépendants) avant d'obtenir des réponses statistiquement significatives.

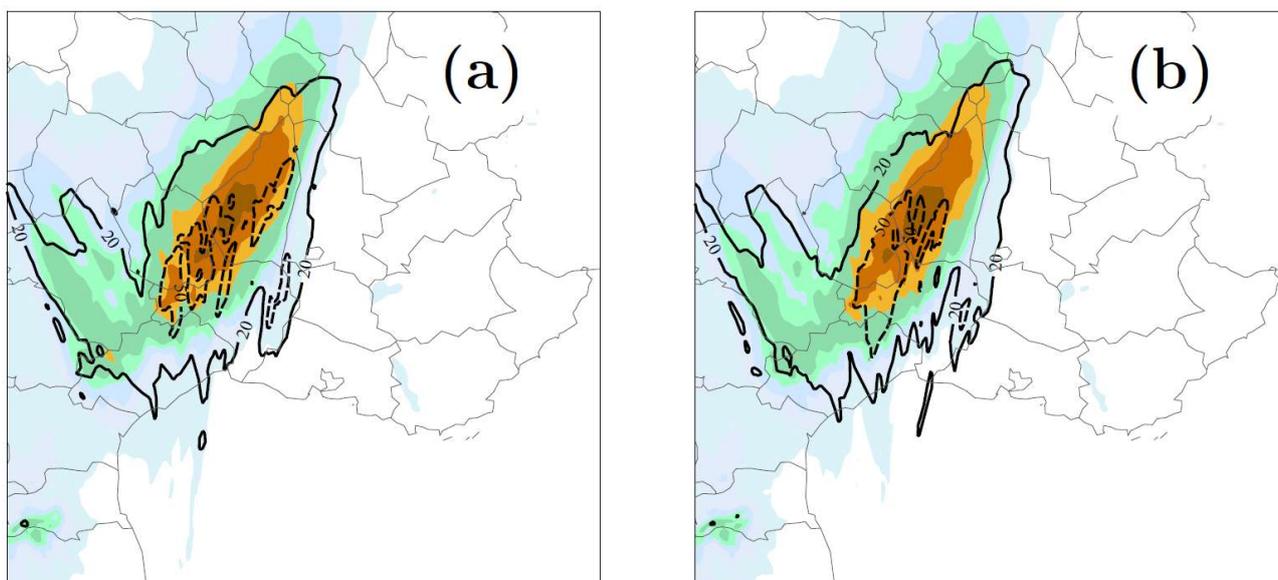


Figure 12 : précipitations accumulées sur les dernières 24h sur le SE de la France, le 2 novembre 2008 à 12h TU, lors d'un épisode cévenol, prévues par 2 versions de la prévision d'ensemble Arome. Gauche : ensemble perturbé par le seul couplage de grande échelle, droite : ensemble perturbé en plus par la condition initiale. Couleurs : précipitations moyennes de l'ensemble, en mm. Isolignes : écart-type de l'ensemble. La figure montre que, relativement à la moyenne, la variabilité de l'ensemble se situe surtout au sud-est de la zone de fortes précipitations, donc en amont. La comparaison des deux figures montre que l'essentiel de l'information probabiliste est, sur ce cas particulier et à cette échéance, déterminé par l'adaptation locale du forçage de grande échelle, et que l'incertitude sur la condition initiale a peu d'importance. (Figure tirée de Vié et al 2012)

### 3.3. Perspectives sur les erreurs de prévision

Nous avons déjà conclu sur l'étude diagnostique des erreurs de prévision et leur sensibilité aux observations. Les diagnostics sont intéressants pour comprendre les erreurs de prévision, mais cela ne débouche pas forcément sur des améliorations des prévisions ; développer des diagnostics

toujours plus complexes n'a donc de sens que dans la mesure où ils servent à quelque chose. On peut bien sûr imaginer que certains diagnostics n'ont pas encore prouvé leur utilité parce qu'ils n'ont pas suffisamment été étudiés, et qu'il faudrait les travailler encore plus. Les diagnostics de sensibilité aux observations ont probablement un bel avenir, malgré les hypothèses parfois discutables sur lesquels ils reposent, car ils aident à comprendre comment optimiser les réseaux d'observation pour la prévision numérique. Il serait intéressant de développer aussi des diagnostics des faiblesses des systèmes d'assimilation ou des modèles : comment optimiser un modèle de covariances d'erreur d'ébauche ? Quelles sont les paramétrisations physiques et les situations météorologiques pour lesquelles les erreurs de modélisation sont les plus pénalisantes ?

Un début de réponse à cette dernière question est que les diagnostics d'erreurs de prévision sont surtout limités par des problèmes d'échantillonnage statistique : leur interprétation est souvent contrainte par (a) le nombre d'observations disponibles (pour comparer les états de modèle à la réalité), et (b) la longueur des périodes de diagnostics nécessaires pour échantillonner une variété suffisante de types de temps et de réalisations indépendantes des erreurs de prévision : cela peut nécessiter un travail lourd de réanalyses sur plusieurs années pour étudier des événements à fort impact. Sur cette question d'échantillonnage, les prévisions d'ensemble ont un potentiel scientifique intéressant, car elles fournissent plusieurs réalisations quotidiennes des erreurs de prévision possibles. Cela peut permettre d'étudier ces dernières sur des périodes relativement courtes.

La prévision d'ensemble est un outil complexe, mais puissant pour étudier des questions-clés de prévision du temps. Cela justifie que l'on y consacre des efforts importants pour améliorer ses performances. La prévision d'ensemble peut être vue comme une technique de diagnostic des erreurs de prévision. On a décrit dans ce mémoire les 3 composants essentiels d'une prévision d'ensemble performante, ils soulèvent chacun des questions scientifiques ardues :

- la représentation des incertitudes sur les conditions initiales : on a montré qu'il fallait impérativement utiliser un système qui modélise la variabilité spatio-temporelle des erreurs d'analyse, et que les ensembles d'assimilations sont un outil prometteur pour cela, puisqu'ils permettent de court-circuiter une grande partie des difficultés liées à la manipulation des grandes matrices de covariances du filtre de Kalman ;
- les erreurs de modélisation : leur étude a longtemps été occultée dans la communauté par l'amplification dynamique des erreurs par des processus chaotiques. Comme on l'a vu dans ce projet de recherche à propos du filtre de Kalman, de l'analyse variationnelle et des ensembles d'assimilation, les erreurs de modélisation suscitent un intérêt croissant, car maintenant que l'on atteint les limites de ces méthodes, il subsiste dans les prévisions des erreurs importantes qui ne peuvent pas s'expliquer par l'amplification chaotique des erreurs sur la condition initiale. La technique de la physique stochastique est un outil prometteur pour progresser dans ce domaine, à condition de progresser sur la dépendance de son réglage par rapport à différents types de temps, puisqu'il est probable que les erreurs de modélisation sont d'amplitude variable en fonction de la situation météorologique.
- le couplage d'un ensemble régional à un ensemble de grande échelle : il est maintenant établi que la qualité de ce dernier est cruciale pour les prévisions d'ensemble à échelle fine. L'intérêt de sélectionner de manière non-aléatoire les coupleurs utilisés fait actuellement question, c'est un sujet intuitivement important pour la prévision à haute résolution des événements à fort impact.

Un quatrième thème important, transversal à toutes ces questions, est la méthodologie de validation des prévisions d'ensemble. C'est un problème semblable à la validation des covariances d'erreur d'analyse ou de prévision : il s'agit de valider des quantités statistiques prédites (comme une variance, une corrélation ou une probabilité de dépasser un seuil) avec des observations. Le nombre

élevé de publications récentes sur les scores ensemblistes montre que ces questions ne sont pas encore mûres. Elles contiennent deux grandes difficultés : (a) comment rassembler suffisamment d'observations pour valider ces statistiques prédites, et (b) quelles métriques utiliser dans les comparaisons entre observations et statistiques prédites. Ces difficultés sont liées, puisque certaines métriques nécessitent un nombre irréaliste d'observations pour être calculées, il y a donc un compromis à trouver entre l'intérêt théorique des différentes métriques, et le nombre d'observations qu'elles nécessitent pour produire des informations pratiques. On rejoint ici les préoccupations identifiées plus haut sur les diagnostics d'erreur de prévision et de sensibilité aux observations. Il semble que ces difficultés méthodologiques vont constituer le frein principal à la progression future des outils de planification des réseaux d'observation et des systèmes de prévision d'ensemble. On y voit aussi des difficultés déontologiques, puisqu'en pratique :

- on assiste à une prolifération de diagnostics et de scores, souvent plus motivés par la volonté de multiplier les publications que d'apporter quelque chose d'utile à la communauté scientifique : lorsqu'un nouveau diagnostic est proposé, on ne comprend pas toujours ce qu'il a de mieux que des diagnostics plus anciens et souvent plus intelligibles ;
- certains de ces diagnostics et scores probabilistes sont très compliqués et contiennent des hypothèses plus ou moins explicites, qui les rendent propices aux manipulations. Des scores très abscons sont souvent utilisés comme indicateurs de performance de systèmes opérationnels, ou pour valider des modifications de réseaux d'observation. En particulier, l'utilisation de climatologies ou de filtres spatiaux dans les scores cache souvent des dépendances suspectes à la définition précise de ces climatologies et filtrages;
- les difficultés liées à l'échantillonnage conduisent souvent les auteurs, soit à se cantonner à des études de cas où il est impossible de démêler l'anecdotique du général, soit à afficher des statistiques dont la significativité n'a pas été correctement évaluée, soit à considérer que des résultats sont solides dès que l'application d'un test statistique a montré qu'ils étaient significatifs sur un échantillon arbitrairement choisi.

Le caractère souvent complexe et arbitraire des diagnostics ensemblistes est un frein notable à leur utilisation pratique, que ce soit pour communiquer avec des usagers non-spécialistes, ou même pour en tirer des conclusions sans ambiguïté pour le développement des systèmes de prévision d'ensemble. Il n'est pas bon de trop raisonner sur des diagnostics dépourvus de rapport clair avec l'intérêt des usagers (par exemple les diagrammes de fiabilité). Il faut développer une vision globale et unificatrice de la validation des systèmes de modélisation probabilistes au sens large, en particulier ceux qui estiment les statistiques d'erreur des analyses, des ébauches ou des prévisions. Notre projet pour l'avenir, détaillé en conclusion du présent rapport, consistera à appliquer des diagnostics clairs (comme le CRPS, le diagramme de rang, le ROC ou la valeur économique) de manière unifiée dans les mondes de l'assimilation et de la prévision d'ensemble. Ce projet présente des défis spécifiques, comme la représentation des erreurs d'observation, des biais, et l'habillage probabiliste des prévisions d'ensemble, mais il devrait permettre d'y voir plus clair dans les priorités de développement des systèmes de prévision actuels.

## Conclusion

Nous avons exploré divers aspects des erreurs d'ébauche et de prévision. Les premières sont un cas particulier des secondes : en assimilation de données les ébauches sont habituellement des prévisions à quelques heures d'échéance. La distinction vient essentiellement de ce que les erreurs d'ébauche sont utilisées sous forme de covariances d'erreur pour assimilation, alors que les erreurs de prévision sont utilisées comme telles, pour caractériser les performances des prévisions, leur sensibilité aux observations, ou pour estimer la loi de probabilité des prévisions, par exemple le risque d'occurrence d'un phénomène météorologique.

Malgré les différences de formalisme, les deux concepts (covariances d'ébauche et erreurs de prévision) sont étroitement enchevêtrés, parce qu'une bonne représentation des erreurs d'ébauche est importante pour améliorer les analyses et les prévisions météorologiques. Le développement des techniques de prévision d'ensemble sera un outil clé pour atteindre cet objectif. Plusieurs questions de fond, comme la représentation des erreurs de modélisation, et la validation statistique des probabilités prévues, sont transversales et pèsent fortement sur les deux domaines d'activités.

Certains diront que tout cela, "ce n'est pas de la science, c'est de la technique". Certes, assimilation et prévision d'ensemble sont techniquement complexes et mobilisent d'énormes ressources de calcul. Mais il y a plus. Ces domaines posent des questions auxquelles de nombreux modélisateurs de l'atmosphère se sont heurtés sans le savoir, comme M. Jourdain faisait de la prose. Il y a d'abord l'utilisation des observations. Même s'il est tentant de faire de la modélisation numérique dans des cadres idéalisés, seule la comparaison aux observations permet de prouver que les travaux réalisés ont un sens physique. C'est un travail ingrat : les observations sont entachées d'erreurs compliquées, elles ne permettent pas de valider tout ce que fait le modèle, et les phénomènes météorologiques intéressants sont souvent mal observés, ce qui oblige à travailler en moyenne sur de longues périodes. Mais il y a de nombreuses opportunités de mieux utiliser les observations pour améliorer les systèmes de prévision numérique. En partie 3.1, on a montré qu'au-delà du calcul d'écart entre prévisions et observations scalaires, les observations satellitaires pouvaient identifier des objets météorologiques, comparables aux objets prévus par les modèles numériques. En partie 2.1, on a montré l'importance de la structure spatiale des corrélations d'erreurs de prévision, qui contient une grande richesse structurale liée aux processus physiques responsables de ces erreurs.

L'utilisation d'observations pour valider les prévisions d'ensemble, vue en partie 3.2, montre la difficulté de prouver que des idées théoriques améliorent réellement un système de prévision. Par exemple, sélectionner des prévisions en fonction de leur capacité à prévoir un épisode de fortes pluies est intuitivement une bonne méthode pour minimiser les non-détections de cet événement. Mais il est actuellement impossible de prouver que cette technique est objectivement bénéfique. Le travail sur la physique stochastique montre mieux la subtilité du lien entre améliorations des modèles et qualité des prévisions : bien que le développement des paramétrisations soit généralement considéré comme un domaine scientifiquement noble de la science météorologique, il est frappant que les dégrader par des perturbations aléatoires rend, sous certains aspects, les prévisions plus réalistes.

L'incertitude des analyses est un autre problème souvent négligé en modélisation. La prévision numérique de certains phénomènes est peu sensible à l'état initial du modèle, mais dans la majorité des cas, à grande comme à petite échelle, la précision de l'analyse est déterminante pour la qualité de ces prévisions. La relation entre observations assimilées, qualité des analyses et qualité des prévisions est au coeur de notre projet de recherche. Intuitivement, on aimerait (1) que les

observations soient intelligemment utilisées pour initialiser des structures météorologiques les plus réalistes possibles dans les analyses, (2) que l'on soit prévenu lorsqu'il n'a pas été possible d'analyser, et donc de prévoir, certains phénomènes météorologiques (une analyse peut être compromise par un manque d'observations, ou par des faiblesses algorithmiques du système d'analyse et de prévision). C'est cette idée physique que nos recherches visent à concrétiser. En particulier, la construction de terme  $J_b$  évolue au fil des années, d'abord sous forme de corrélations et de balances statiques, puis avec des ensembles qui le rendent dépendant des conditions météorologiques. Cette évolution tend à rendre compte de manière automatisée de structures de phénomènes tels que les couches limites, les systèmes convectifs précipitants, le couplage entre différentes échelles atmosphériques, le couplage entre basses couches et convection, ou les précipitations méditerranéennes intenses (rares mais à détecter sans faille). La caractérisation de ces processus sous forme de modèles de covariances efficaces sera essentielle pour faire de meilleures prévisions météorologiques.

Quelle suite donner à ce projet ? Certaines questions soulevées ici sont déjà étudiées par de nombreux scientifiques, ne serait-ce qu'à Météo-France et au CEPMMT. L'importance de la variabilité des erreurs d'analyse et d'ébauche est maintenant reconnue dans la communauté météorologique. Sa modélisation est une priorité dans la plupart des centres opérationnels de prévision. A Météo-France, un système novateur d'assimilation ensembliste globale ARPEGE a été installé il y a quelques années, suivi peu après par le CEPMMT avec son modèle IFS. Un ensemble d'assimilation régional AROME sera prochainement mis en service à Météo-France. Ces ensembles d'assimilations seront des véhicules essentiels pour développer de meilleurs systèmes d'assimilation, en introduisant une information riche sur la variabilité spatio-temporelle des erreurs d'ébauche (ce qui aidera via le terme  $J_b$  les systèmes 3D- et 4D-Var à assimiler nuages, brouillards et précipitations). Ils serviront aussi à améliorer les systèmes de prévision d'ensemble, en fournissant un échantillonnage performant des erreurs d'analyse. Cela permettra d'améliorer les prévisions d'ensemble à très courte échéance, ce qui ouvrira la voie à des *prévisions immédiates probabilistes* (prévisions à quelques heures d'échéance), et à de meilleures *prévisions des probabilités de phénomènes dangereux* (pluies intenses et orages notamment). On a l'ambition de rendre la prévision d'ensemble AROME assez performante pour produire des covariances d'ébauche réalistes lors de phénomènes précipitants (ce qui soulève des questions spécifiques d'échantillonnage statistique de structures nuageuses spatialement intermittentes). Cela devrait permettre à l'assimilation AROME d'analyser, et donc de prévoir, de manière plus réaliste les orages et les systèmes précipitants à échelle très fine, l'idée étant de combiner ces covariances d'ébauche avec des observations à haute résolution (radars et satellites).

Au-delà de cet objectif impérieux d'améliorer les prévisions météorologiques, la réalisation d'un système performant d'assimilation et de prévision d'ensemble à échelle fine permettra d'étudier des problèmes scientifiques actuellement hors d'atteinte. En effet, un échantillonnage réaliste de la loi de probabilité des prévisions atmosphérique permettrait de mieux comprendre la sensibilité des prévisions à leurs conditions initiales et aux observations utilisées. En théorie, cela devrait permettre d'identifier des priorités d'amélioration des réseaux d'observation, par exemple pour le déploiement d'observations ciblées lors de campagnes de mesures. On pourrait imaginer, lors de campagnes de mesures ou peu avant l'occurrence d'un phénomène météorologique exceptionnel, de produire des prévisions d'ensemble contenant des centaines de membres, afin d'échantillonner très précisément la loi de probabilité des prévisions. Une calibration de plus en plus précise des physiques stochastiques, ancrée par de vastes jeux d'observations sur de longues périodes du passé, devrait permettre de mieux identifier les principales sources d'erreurs de prévision dans les modèles météorologiques. En effet, savoir quelle amplitude donner à une physique stochastique - où à toute forme de représentation de l'erreur de modèle - revient à savoir où, quand et comment naissent les pires erreurs de prévision, ce qui permettrait d'identifier les priorités d'améliorations dans les

modèles.

Pour concrétiser cette vision, il faut continuer à développer les schémas de physique stochastique, en y incluant une vaste palette de sources d'incertitude de modélisation, comme les surfaces, les processus dynamiques ou l'interface physico-dynamique, ainsi que la dépendance de ces incertitudes au contexte météorologique, comme le type de nuage dominant, la présence d'inversions, etc... Cela devrait être possible avec un travail approprié de validation des systèmes de prévision d'ensemble qui cible différents processus, afin de tirer au clair le rôle des différents composants du modèle et types de temps dans la croissance des erreurs de prévision. L'utilisation d'une physique stochastique assez complète dans la prévision d'ensemble d'une situation particulière, pourrait permettre d'identifier les sensibilités de cette prévision à différents processus physiques et aux erreurs d'analyses. Cela constituerait un outil de travail très intéressant pour comprendre et améliorer les prévisions numériques.

## Références

### **Publications personnelles à comité de lecture, mentionnées dans ce mémoire**

(par ordre chronologique)

**Bouttier**, F., 1993: The dynamics of error covariances in a barotropic model. *Tellus*, 45A, 408-423.

**Bouttier**, F., 1994: A dynamical estimation of error covariances in an assimilation system. *Mon. Wea. Rev.*, 122, 2376-2390.

Barkmeijer, J., M. van Gizjen and F. **Bouttier**, 1998: Singular vectors and the analysis error covariance metric. *Quart. J. Roy. Met. Soc.*, 124A, 1695-1713. (*publication réalisée en tant que coencadrant du séjour post-doctoral de M. van Gizjen*)

Derber, J. and F. **Bouttier**, 1999: A reformulation of the background error covariance in the ECMWF global data assimilation system. *Tellus*, 51A, 195-222.

**Bouttier**, F. and G. Kelly, 2001: Observing system experiments with the ECMWF data assimilation system. *Quart. J. Roy. Met. Soc.*, 127, 1469-1488.

Michel, Y. et F. **Bouttier**, 2006: Automated tracking of dry intrusions on satellite and synthetic water vapour imageries. *Quart. Jour. Roy. Met. Soc.*, 132, 2257-2276. (*publication réalisée en tant qu'encadrant de thèse de Y. Michel*)

Brousseau, P., L. Berre, F. **Bouttier** and G. Desroziers, 2011: Background-error covariances for a convective scale data-assimilation system: AROME-France 3D-Var. *Quart. Jour. Roy. Meteor. Soc.*, 137: 409-422. doi:10.1002/qj.750. (*publication réalisée en tant que codirecteur de thèse de P. Brousseau*)

Brousseau, P., L. Berre, F. **Bouttier** and G. Desroziers, 2012: Flow-dependent background-error covariances for a convective scale data assimilation system. *Quart. Jour. Roy. Meteor. Soc.*, 138, 310-322. doi: 10.1002/qj.920 (*publication réalisée en tant que codirecteur de thèse de P. Brousseau*)

**Bouttier**, F., B. Vié, O. Nuissier and L. Raynaud, 2012: Impact of stochastic physics in a convection-permitting ensemble. *Mon. Wea. Rev.*, 140, 3706-3721. doi: <http://dx.doi.org/10.1175/MWR-D-12-00031.1> (*travail personnel réalisé au cours de l'encadrement de thèse de B. Vié*)

Vié, B., G. Molinié, O. Nuissier, V. Ducrocq, **F. Bouttier** and E. Richard, 2012: Hydro-meteorological evaluation of a convection-permitting ensemble prediction system for Mediterranean heavy precipitating events. *Nat. Hazards Earth Syst. Sci.*, 12, 2631-2645. doi:10.5194/nhess-12-2631-2012 (*publication réalisée en tant qu'encadrant de thèse de B. Vié*)

Brousseau, P., G. Desroziers, **F. Bouttier** and B. Chapnik, 2013: A posteriori diagnostics of the impact of observations on the AROME-France convective-scale data-assimilation system. *Quart. Jour. Roy. Meteor. Soc.*, sous presse. (*publication réalisée en tant qu'encadrant de thèse de P. Brousseau*)

## **Autres publications mentionnées dans ce mémoire**

Andersson, E., A. Hollingsworth, G. Kelly, P. Lönnberg, J. Pailleux and Z. Zhang, 1991: Global observing system experiments on operational statistical retrievals of satellite sounding data. *Mon. Wea. Rev.*, **119**, 1851-1864.

Andersson, E., J. Pailleux, J.-N. Thépaut, J. R. Eyre, A. P. McNally, G. A. Kelly, and P. Courtier, 1994: Use of cloud-cleared radiances in three/four-dimensional variational data assimilation. *Quart. J. Roy. Met. Soc.*, **120**, 627-653.

Berre, L., 2000: Estimation of synoptic and mesoscale forecast error covariances in a limited area model. *Mon. Wea. Rev.*, **128**, 644-667.

Brewster, K., 2003: Phase-correcting data assimilation and application to storm-scale numerical weather prediction. Part I: Method Description and Simulation Testing. *Mon. Wea. Rev.*, **131**, 480–492. doi: [http://dx.doi.org/10.1175/1520-0493\(2003\)131<0480:PCDAAA>2.0.CO;2](http://dx.doi.org/10.1175/1520-0493(2003)131<0480:PCDAAA>2.0.CO;2)

Bright, D. and S. Mullen, 2002: Short-Range Ensemble Forecasts of Precipitation during the Southwest Monsoon. *Wea. Forecasting*, **17**, 1080-1100. doi: 10.1175/1520-0434(2002)017.

Buizza, R., M. Miller and T. Palmer, 1999: Stochastic representation of model uncertainties in the ECMWF ensemble prediction system. *Quart. J. Roy. Met. Soc.*, **125**, 2887-2908.

Caumont, O., V. Ducrocq, G. Delrieu, M. Gosset, J.-P. Pinty, J. Parent du Châtelet, H. Andrieu, Y. Lemaître, and G. Scialom 2006: A radar simulator for high-resolution nonhydrostatic models. *J. Atmos. Oceanic Technol.*, **23**, 1049–1067. doi: <http://dx.doi.org/10.1175/JTECH1905.1>

Courtier, P., E. Andersson, W. Heckley, D. Vasiljevic, M. Hamrud, A. Hollingsworth, F. Rabier, M. Fisher, and J. Pailleux, 1998: The ECMWF implementation of three-dimensional variational assimilation (3D-Var). I: Formulation. *Quart. J. Roy. Met. Soc.*, **124**, 1783–1807.

Daley, R., 1992: Estimating model-error covariances for application to atmospheric data assimilation. *Mon. Wea. Rev.*, **120**, 1735–1746. doi: [http://dx.doi.org/10.1175/15200493\(1992\)120<1735:EMECFA>2.0.CO;2](http://dx.doi.org/10.1175/15200493(1992)120<1735:EMECFA>2.0.CO;2)

Desroziers, G., P. Brousseau and B. Chapnik, 2005: Use of randomization to diagnose the impact of observations on analyses and forecasts. *Quart. J. Roy. Met. Soc.*, **131**, 2821–2837.

Desroziers G., L. Berre, V. Chabot and B. Chapnik, 2009: A posteriori diagnostics in an ensemble of perturbed analyses. *Mon. Wea. Rev.*, **137**, 3420-3436. doi:10.1175/2009MWR2778.1.

Ehrendorfer, M. and F. **Bouttier**, 1998: An Explicit Low-resolution Extended Kalman Filter: Implementation and Preliminary Experimentation. *ECMWF Research Dept. Tech. Memorandum no.259*. Available at <http://www.ecmwf.int/>

Georgiev, C., 1999: Quantitative relationship between METEOSAT water vapour data and positive vorticity anomalies: a case study over the Mediterranean. *Meteor. Appl.*, **6**, 97-109.

Heckley, W., P. Courtier, J. Pailleux, and E. Andersson, 1992: The ECMWF variational analysis: General formulation and use of background information. In *Workshop on Variational Assimilation, with special emphasis on Three-dimensional Aspects, 9-12 November 1992*, 49-94, Shinfield Park, Reading. Available at <http://www.ecmwf.int/>

Kelly, G., A. McNally, J.-N. Thépaut and M. Szyndel, 2004: Observing System Experiments of all main data types in the ECMWF operational system. In *Proc. of the Third WMO Workshop on the Impact of Various Observing Systems on NWP*, Alpbach, Austria, 9–12 March 2004.

Lorenc, A., 2003: The potential of the ensemble Kalman filter for NWP—a comparison with

4D-Var. *Quart. Jour. Roy. Meteorol. Soc.*, **129**, 3183–3203. doi: 10.1256/qj.02.132

Lorenç, A. 1986. Analysis methods for numerical weather prediction. *Q. J. R. Meteorol. Soc.* **112**, 1177–1194.

Lorenz, E., 1963: Deterministic non-periodic flow. *J. Atmos. Sci.*, **20**, 130-141.

Klinker, E., F. Rabier, G. Kelly and J.-F. Mahfouf, 2000: The ECMWF operational implementation of four-dimensional variational assimilation. III: Experimental results and diagnostics with operational configuration. *Quart. Jour. Roy. Met. Soc.*, **126**, 1191–1215. doi: 10.1002/qj.49712656417

Marsigli, C., Boccanera, F., Montani, A. and Paccagnella, T. 2005. The COSMO-LEPS mesoscale ensemble system: validation of the methodology and verification. *Nonlin. Proc. Geophys.*, **12**, 527-536.

McLean Slaughter, J., T. Gneiting and A. Raftery, 2013: Probabilistic wind vector forecasting using ensembles and Bayesian model averaging. *Mon. Wea. Rev.* e-view, doi: <http://dx.doi.org/10.1175/MWR-D-12-00002.1>

Ménétrier, B. and T. Montmerle, 2011: Heterogeneous background-error covariances for the analysis and forecast of fog events. *Quart. Jour. Roy. Met. Soc.*, **137**, 2004–2013. doi: 10.1002/qj.802

Michel, Y., 2012: Estimating deformations of random processes for correlation modelling in a limited area model. *Quart. Jour. Roy. Met. Soc.*, e-view, doi: 10.1002/qj.1978

Molteni, F., R. Buizza, T. Palmer, and T. Petroliaçis, 1996: The ECMWF ensemble prediction system: methodology and validation. *Quart. J. Roy. Met. Soc.*, **122**, 73-119.

Montmerle, T. and L. Berre, 2010: Diagnosis and formulation of heterogeneous background-error covariances at the mesoscale. *Quart. J. Roy. Met. Soc.*, **136**, 1408–1420. doi: 10.1002/qj.655

Montmerle, T., F. Rabier and C. Fischer, 2006: Respective impact of polar orbiting and geostationary satellite observations in the Aladin/France NWP system. *Quart. Jour. Roy. Met. Soc.*, **133**, 655-671.

Montmerle, T. and C. Faccani, 2009: Mesoscale assimilation of radial velocities from Doppler radar in a pre-operational framework. *Mon. Wea. Rev.*, **137**, 1939–1953.

Nuissier, O., B. Joly, B. Vié and V. Ducrocq, 2012: Uncertainty on Lateral Boundary Conditions in a convection-permitting ensemble: A strategy of selection for Mediterranean heavy precipitation events. *Nat. Hazards Earth Syst. Sci.*, **12**, 2993-3011. doi:10.5194/nhess-12-2993-2012

Raynaud, L. and O. Pannekoucke, 2012: Sampling properties and spatial filtering of ensemble background-error length-scales. *Quart. J. Roy. Met. Soc.* e-view. doi: 10.1002/qj.1999

Ricci, S., A. T. Weaver, J. Vialard, P. Rogel, 2005: Incorporating State-Dependent Temperature–Salinity Constraints in the Background Error Covariance of Variational Ocean Data Assimilation. *Mon. Wea. Rev.*, **133**, 317–338. doi: <http://dx.doi.org/10.1175/MWR2872.1>

Rosting, B., J. Sunde and K. Midtbo, 1996: Monitoring of NWP models by use of satellite data. *Meteor. Appl.*, **3**, 331-340.

Saunders R., M. Matricardi and P. Brunel, 1999: An improved fast radiative transfer model for assimilation of satellite radiance observations. *Quart. J. Roy. Met. Soc.*, **125**, 1407-1425.

Toth, Z., and E. Kalnay, 1993: Ensemble forecasting at NMC: The generation of perturbations. *Bull. Amer. Meteor. Soc.*, **74**, 2317-2330.

Varella, H., Berre, L. and G. Desroziers, 2011: Diagnostic and impact studies of a wavelet formulation of background-error correlations in a global model. *Quart. J. Roy. Met. Soc.*, **137**: 1369–1379. doi: 10.1002/qj.845

Vié, B., O. Nuissier and V Ducrocq, 2011: Cloud-resolving ensemble simulations of Mediterranean heavy precipitating events: uncertainty on initial conditions and lateral boundary conditions. *Mon. Wea. Rev.*, **139**, 403-423.

## **Publications personnelles à comité de lecture, non mentionnées dans ce mémoire**

**Bouttier**, F., J.-F. Mahfouf and J. Noilhan, 1993: Sequential assimilation of soil moisture from atmospheric low-level parameters. Part I: Sensitivity and calibration studies. *Jour. Appl. Meteor.*, 32, 1335-1351.

**Bouttier**, F., J.-F. Mahfouf and J. Noilhan, 1993: Sequential assimilation of soil moisture from atmospheric low-level parameters. Part II: Implementation in a mesoscale model. *Jour. Appl. Meteor.*, 32, 1352-1364.

Rabier, F., A. McNally, E. Andersson, P. Courtier, P. Undén, J. Eyre, A. Hollingsworth and F. **Bouttier**, 1998: The ECMWF implementation of three-dimensional variational assimilation (3D-Var). Part II: structure functions. *Quart. J. Roy. Met. Soc.*, 124, 1809-1829.

Järvinen, H., E. Andersson and F. **Bouttier**, 1999: Variational assimilation of time sequences of surface observations with serially correlated errors. *Tellus*, 51A, 469-488.

**Bouttier**, F., 2001: The use of profiler data at ECMWF. *Meteorologische Zeitschrift*, 10, no.6, 497-510, Dec 2001.

Hello G. and F. **Bouttier**, 2001: Using adjoint sensitivity as a local structure function in variational data assimilation. *Nonlinear Processes in Geophysics*, 8, (6), 467-483. (*publication réalisée en tant que coencadrant de thèse de G. Hello*)

Stoffelen, A., G.-J. Marseille, F. **Bouttier**, D. Vasiljevic, S. de Haan and C. Cardinali, 2006: Doppler Wind Lidar observation system simulation experiment. *Quart. Jour. Roy. Met. Soc.*, 132, 1927-1948.

**Bouttier**, F., 2007: Arome, avenir de la prévision régionale. *La Météorologie*, 8e série, no. 58, 12-20, août 2007.

Richard E., C. Flamant, F. **Bouttier**, J. Van Baelen, C. Champollion, S. Argence, J. Arnault, C. Barthlott, A. Behrendt, P. Bossert, P. Brousseau, J.-P. Chaboureau, U. Corsmeier, J. Cuesta, P. Di Girolamo, M. Hagen, C. Kottmeier, P. Limnaios, F. Masson, G. Pigeon, Y. Pointin, F. Tridon, Y. Seity et V. Wulfmeyer, 2009: La campagne COPS: genèse et cycle de vie de la convection en région montagneuse, *La Météorologie*, 8e série, no.64, 32-42, février 2009.

Rotach MW, Ambrosetti P, Ament F, Appenzeller C, Arpagaus M, Bauer HS, Behrendt A, **Bouttier** F, Buzzi A, Corazza M, Davolio S, Denhard M, Dorninger M, Fontannaz L, Frick J, Fundel F, Germann U, Gorgas T, Hegg C, Hering A, Keil C, Liniger MA, Marsigli C, McTaggart-Cowan R, Montani A, Mylne K, Ranzi R, Richard E, Rossa A, Santos-Muñoz D, Schär C, Seity Y, Staudinger M, Stoll M, Volkert H, Walser A, Wang Y, Werhahn J, Wulfmeyer V, Zappa M: 2009, MAP D-PHASE: Real-time Demonstration of Weather Forecast Quality in the Alpine Region, *Bull Amer Meteor Soc*, **90** (9), 1321-1336, doi:10.1175/2009BAMS2776.1

Seity, Y., Brousseau, P., S. Malardel, G. Hello, P. Bénard, F. **Bouttier**, C. Lac and V. Masson, 2011: The AROME-France convective scale operational model. *Mon. Wea. Rev.*, **139**, 976-991. doi: 10.1175/2010MWR3425.1 (*publication réalisée en tant qu'encadrant des travaux de Y. Seity, et codirecteur de thèse de P. Brousseau*

*soffice* )

## Glossaire

- 3D-Var : méthode d'assimilation séquentielle de données, dont les analyses utilisent une méthode variationnelle (la variable de contrôle contient les champs 3D du modèle)
- 4D-Var : méthode d'assimilation variationnelle d'observations, distribuées dans une fenêtre temporelle.
- ALADIN : système de prévision numérique régional utilisé principalement en Europe et en Afrique du nord, techniquement similaire à AROME.
- AROME : système de prévision numérique régional comprenant un modèle non-hydrostatique de l'atmosphère destinée aux résolutions horizontales de l'ordre de kilomètre, et un système d'assimilation 3D-Var adapté ("Applications de la Recherche à l'Opérationnel à Mésoéchelle"). AROME est le principal système de prévision régional opérationnel à courte échéance de Météo-France depuis 2008.
- ARPEGE : système de prévision numérique global comprenant un modèle hydrostatique de l'atmosphère, pourvu d'une maille variable pouvant atteindre localement des résolutions de l'ordre de 10km, ainsi qu'un système d'assimilation 4D-Var ("Action de Recherche Petite Echelle Grande Echelle"). ARPEGE est le système de prévision global opérationnel de Météo-France depuis 1993.
- CEPMMT : Centre Européen de Prévision Météorologique à Moyen Terme, organisme météorologique international situé à Reading, Grande-Bretagne.
- COSMO-DE-EPS : système de prévision d'ensemble à domaine limité du service météorologique allemand.
- COSMO-LEPS : système de prévision d'ensemble à domaine limité du service météorologique italien ARPA-SIM (Bologne).
- EPS : système de prévision d'ensemble du CEPMMT (Ensemble Prediction System).
- IFS : système de prévision numérique global comprenant un modèle hydrostatique de l'atmosphère et un système d'assimilation 4D-Var ("Integrated Forecast System"). IFS est le système de prévision opérationnel du CEPMMT depuis 1995. Le logiciel IFS englobe les logiciels utilisés par les systèmes ARPEGE, ALADIN et AROME.
- **Jb** : partie d'un système d'analyse 3D-Var ou 4D-Var assurant la représentation des covariances d'erreurs de l'ébauche (matrice notée **B** dans ce mémoire). En pratique, **Jb** intervient dans la fonction-coût 3D/4D-Var comme terme quadratique mesurant la distance à l'ébauche.
- MOGREPS-UK : système de prévision d'ensemble à domaine limité du service météorologique britannique (Met Office Global and Regional Ensemble Prediction System, United Kingdom domain)
- OMM : Organisation Météorologique Mondiale.
- SEVIRI : radiomètre imageur embarqué à bord des satellites de classe METEOSAT-2 d'EUMETSAT ("Spinning Enhanced Visible and Infrared Imager").

- SSI : spectral space initialization. Système d'analyse variationnel utilisé notamment au National Center for Environmental Prediction (NCEP, USA).