



INSTITUT NATIONAL DE L'ENVIRONNEMENT INDUSTRIEL ET DES RISQUES

Retour d'expérience en prévision

Rapport final

Laboratoire Central de Surveillance de la
Qualité de l'Air

Convention n°42/99

Laure MALHERBE
Unité Modélisation et Analyse Economique pour la gestion des
Risques (MECO)

Direction des Risques Chroniques (DRC)

Janvier 2001

Retour d'expérience en prévision

Rapport final

Laboratoire Central de Surveillance de la
Qualité de l'Air

Janvier 2001

LAURE MALHERBE

Ce rapport comporte 40 pages (hors couverture et annexes).

	Rédaction	Vérification	Approbation
NOM	Laure MALHERBE	Michel NOMINE	Martine RAMEL
Qualité	Direction des Risques Chroniques	Direction des Risques Chroniques	Direction des Risques Chroniques
Visa			

TABLE DES MATIERES

1. RESUME	3
2. GLOSSAIRE.....	4
3. INTRODUCTION.....	5
3.1 Contexte et objectifs.....	5
3.2 Généralités sur la prévision.....	5
3.3 Présentation du document.....	6
4. PRÉVISION DES CONCENTRATIONS	6
4.1 Méthodes empiriques.....	7
4.2 Modèles statistiques	7
4.2.1 Généralités	7
4.2.2 Modèles additifs linéaires	7
4.2.3 Modèles non linéaires	9
4.2.4 Méthode CART	11
4.2.5 Réseaux de neurones	13
4.3 Modèles déterministes.....	14
4.4 Logique floue	16
5. PRÉVISION DU DÉPASSEMENT DES SEUILS.....	17
5.1 Dépassement des seuils : les méthodes de prévision.....	17
5.2 La performance des modèles.....	21
6. PREVISION DE L'INDICE ATMO	24
6.1 Calcul et prévision de l'indice ATMO.....	24
6.2 Qualité des prévisions	28
7. BILAN DES EXPÉRIENCES, DIFFICULTES DE LA PREVISION	28
7.1 Bilan des expériences dans les AASQA.....	28
7.2 Quelques difficultés de la prevision	29
7.2.1 Les données d'entrée.....	29
7.2.2 Echelle de la prévision.....	29
8. COMPARAISON AVEC LES EXPÉRIENCES EUROPEENNES.....	30
8.1 Choix des modèles de prévision	30
8.2 Critères de performance des modèles.....	32
9. ETUDES STATISTIQUES SUR LES PARTICULES	33
9.1 Modèles récepteurs.....	34
9.1.1 Chemical mass balance model.....	34
9.1.2 Modèles multivariés	35
9.1.3 Méthode de régression multiple.....	35
9.2 Méthode de classification automatique	36
10. CONCLUSION	37
11. RÉFÉRENCES.....	38
12. LISTE DES ANNEXES	40

1. RESUME

Au-delà de la mesure et du suivi de la pollution atmosphérique, la prévision prend une place toujours plus grande dans les missions des Associations Agréées de Surveillance de la Qualité de l'Air. Depuis quelques années, de plus en plus d'associations mettent progressivement en place des techniques numériques de prévision, souvent en partenariat avec des universités. L'INERIS s'est proposé de compléter les premiers éléments recueillis sur ce sujet à l'occasion d'une enquête en 1999, et d'étudier de manière plus approfondie les différentes approches adoptées par les associations, et les performances des modèles constatées jusqu'à ce jour.

Actuellement, les méthodes de prévision concernent presque exclusivement l'ozone. Elles sont destinées à anticiper les concentrations maximales journalières d'une part et le dépassement des seuils d'autre part. Si les techniques employées se révèlent très variées, quelques observations d'ensemble se dégagent, à savoir :

- la prédominance des modèles statistiques, généralement simples et rapides d'utilisation, par rapport aux modèles déterministes, souvent plus coûteux en données d'entrée et en temps de mise en œuvre;
- la part importante que continue de jouer l'expertise humaine (en particulier dans le choix des variables à considérer, et dans la prévision de l'indice ATMO);

Le caractère opérationnel des modèles est souvent trop récent pour que les performances puissent être comparées. Les premières applications donnent la plupart du temps des résultats satisfaisants. Les modèles statistiques ont toutefois tendance à sous-estimer les fortes concentrations à cause du manque d'épisodes de pollution dans les données d'apprentissage. Une étude des expériences européennes fait ressortir les mêmes difficultés, et montre l'intérêt de combiner plusieurs approches, y compris l'expertise humaine.

Une meilleure connaissance de l'incertitude des variables (notamment météorologiques), le passage d'une approche locale à une approche régionale, et l'extension des modèles aux polluants de l'indice ATMO, en particulier les particules PM₁₀, constituent les principaux axes de développement en matière de prévision.

2. GLOSSAIRE

Biais : moyenne des prévisions - moyenne des observations

CART : Classification and Regression Tree

corr (obs/prévi) : corrélation entre valeurs observées et calculées par le modèle

EMQ : erreur moyenne quadratique

$f(\varepsilon)$: distribution de l'erreur

$\varepsilon=g(\text{obs})$: erreur de prévision en fonction de l'observation

$J \rightarrow J$: prévision du matin pour l'après-midi

$J \rightarrow J+1$: prévision du jour pour le lendemain

NO_2 : dioxyde d'azote

O_3 : ozone

PM_{10} : particules de diamètre aérodynamique $< 10 \mu\text{m}$

PS: particules en suspension

SO_2 : dioxyde de soufre

$[\text{NO}_2]$: concentration de dioxyde d'azote

$[\text{O}_3]$: concentration d'ozone

CRAN: Centre de Recherche en Automatique de Nancy

EEA: European Environment Agency

EERIE: Ecole pour les Etudes et la Recherche en Informatique et Electronique

GREQAM: Groupement de Recherche en Economie Quantitative d'Aix-Marseille

LG2IP: Laboratoire de Génie Informatique et d'ingénierie de Production de l'Ecole des Mines d'Alès, basé à l'EERIE, Nîmes

LISA: Laboratoire Interuniversitaire des Systèmes Atmosphériques

LMC/IMAG: Laboratoire de Modélisation et Calcul / Institut d'Informatique et Mathématiques Appliquées de Grenoble

LMD: Laboratoire de Météorologie Dynamique

3. INTRODUCTION

3.1 CONTEXTE ET OBJECTIFS

Les AASQA sont de plus en plus sollicitées sur des questions de prévision, que celle-ci concerne l'apparition de pics d'ozone et de poussières ou la qualité globale de l'air. La prévision a pour principal objectif d'anticiper le dépassement des seuils réglementaires de pollution, afin que les autorités puissent lancer des procédures d'alerte et prendre des mesures de réduction des émissions.

Un retour d'expérience en modélisation, réalisé par l'INERIS et l'École des Mines de Douai en 1999 (Rouïl, Wroblewsky, 1999), a montré l'intérêt des techniques numériques pour répondre à de telles questions. Vu l'enjeu que représente la prévision en matière d'information et de santé publique, l'INERIS s'est proposé d'approfondir ce sujet et de rendre compte plus précisément des démarches entreprises par les AASQA et des résultats obtenus à ce jour.

Un questionnaire rédigé conjointement par le MATE, l'ADEME et l'INERIS, a été communiqué à l'ensemble des Associations. Il s'articule autour de trois thèmes:

- prévision des concentrations ;
- prévision des dépassements de seuils ;
- prévision de l'indice ATMO.

A titre d'information, il est donné en annexe de ce document.

La synthèse des réponses recueillies fait pour l'essentiel l'objet du présent document. Tout en rapportant la diversité des expériences, il s'agit de dégager et si possible de confronter les principales approches dans le domaine de la prévision.

3.2 GENERALITES SUR LA PREVISION

19 sur 36 associations ont répondu au questionnaire. Parmi elles, cinq ne se sont pas encore engagées dans une démarche de prévision numérique de la qualité de l'air :

- par manque de moyens : il s'agit de petites structures (ESPOL, AREMARTOIS) qui attendent un retour d'expérience sur ce thème, et envisagent d'adopter une démarche analogue à celle des réseaux voisins (dans le cadre d'un partenariat en ce qui concerne AREMARTOIS)
- par manque d'historique, en ce qui concerne les données de concentration (AMPASEL, ATMO Champagne-Ardennes) ;
- parce qu'elles ont privilégié d'autres axes de développement, tels que la mise en place de leur réseau de mesure (ATMO Picardie).

Les approches adoptées par les autres se révèlent très diverses : méthodes statistiques, déterministes, logique floue, avec une nette prédominance des premières.

En modélisation statistique, la caractérisation de la pollution se fonde uniquement sur une analyse des états, c'est-à-dire des concentrations observées et des paramètres qui lui sont corrélés. Les techniques utilisables sont nombreuses : régression linéaire, non linéaire, ou logistique, réseaux de neurones, méthodes de classification. En modélisation déterministe, la caractérisation des événements de pollution se fonde sur les causes et les

mécanismes, et nécessite une connaissance des sources d'émission et des paramètres météorologiques.

L'emploi de modèles déterministes semble plutôt relever d'un choix scientifique et d'une volonté de mieux appréhender les phénomènes : meilleure compréhension de l'origine et des mécanismes de la pollution, apport d'une information cartographique (AIR PARIF, ASPA).

Le choix de méthodes statistiques procède en revanche de considérations plus variées:

- facilité de compréhension et d'utilisation ;
- résultats prometteurs obtenus notamment par d'autres réseaux ;
- possibilité de faire appel à des compétences locales ;
- coût limité.

3.3 PRESENTATION DU DOCUMENT

Par souci de clarté, le rapport aborde successivement (parties 4, 5, 6) les trois grands thèmes du questionnaire : prévision des concentrations, prévision du dépassement des seuils, prévision de l'indice ATMO, bien que ceux-ci s'avèrent généralement très liés. Pour chacun d'eux, les expériences des associations -telles que décrites dans les réponses au questionnaire- sont groupées par approche, et les performances des modèles analysées et comparées.

La partie 7 dresse le bilan de ces expériences et aborde deux problèmes spécifiques à la prévision : l'incertitude des données, et l'échelle du domaine de prévision.

Les deux dernières parties élargissent le champ de l'étude sur la prévision de la qualité de l'air aux démarches adoptées par les autres pays européens (partie 8) et au thème des particules qui tend à se développer (partie 9).

4. PREVISION DES CONCENTRATIONS

Ce chapitre synthétise l'expérience des réseaux dans le domaine de la prévision des concentrations. Il s'agit de mettre en évidence les raisons qui ont présidé au choix d'une méthode, et la spécificité des modèles mis en place par les AASQA. Des caractéristiques tant qualitatives que quantitatives sont étudiées, notamment:

- la nature et les critères de sélection des variables;
- la durée de l'historique d'apprentissage et de test;
- le coût de développement et de fonctionnement des modèles;
- les résultats obtenus.

Une attention particulière est portée au contrôle qualité des modèles et à l'évaluation de leurs performances.

La description technique des méthodes employées n'est pas abordée dans ce document. Elle fait l'objet d'une étude approfondie, *Bilan de l'existant en matière de prévision statistique des pics de pollution*, réalisée pour le LCSQA par Guillas, Rhomari et Zhang (2000).

4.1 METHODES EMPIRIQUES

Les prévisions empiriques se fondent généralement sur l'*expertise humaine* et tiennent largement compte des prévisions météorologiques. Il n'est pas dans notre propos d'approfondir ce point, puisque notre travail concerne les techniques numériques de prévision. L'expertise humaine cependant est souvent mise à contribution pour garantir la pertinence de modèles plus sophistiqués et la vraisemblance des résultats.

Parmi les méthodes empiriques, il convient également de citer les *modèles de persistance*. Le plus simple d'entre eux consiste à prévoir pour le lendemain la concentration maximale du jour. Les modèles de persistance font uniquement intervenir les données de concentration du polluant d'intérêt, sans introduire de variable exogène. Aucune association ne semble y avoir recours en tant qu'outils de prévision. La persistance peut néanmoins servir de base à l'élaboration d'un modèle statistique plus poussé (AIRLOR AIRAQ) ou de point de comparaison pour évaluer la performance d'un modèle (AIRPARIF) (cf §IV.2).

4.2 MODELES STATISTIQUES

4.2.1 Généralités

Nombreuses sont les associations qui ont développé ou développent, souvent avec l'appui de partenaires universitaires, des modèles statistiques de prévision. La prévision des pics d'ozone constitue généralement une priorité, même si beaucoup d'associations souhaitent élargir la modélisation à d'autres polluants (ceux qui interviennent notamment dans le calcul de l'indice ATMO : NO₂, SO₂, PM₁₀).

La modélisation statistique est fondée sur la recherche de corrélations entre la concentration d'un polluant (prédicte) et diverses variables (prédicteurs). Elle comprend généralement les étapes suivantes :

- sélection de prédicteurs pertinents;
- phase d'apprentissage (de construction) du modèle, à partir de données représentatives des conditions dans lesquelles se fera la prévision;
- test (validation) du modèle sur de nouvelles données.

Il existe de nombreuses techniques statistiques possibles (méthodes de régression et de classification, réseaux de neurones). Malgré différentes études comparatives (Comrie, 1997; Cobourn & al, 2000) la supériorité de l'une d'entre elles n'a pas encore été démontrée. Le choix d'une méthode semble plutôt déterminé par les compétences spécifiques des partenaires de l'AASQA.

Si la construction d'un modèle statistique peut exiger des connaissances poussées, son utilisation routinière n'en est pas moins rapide et aisée, ce qui contribue au succès de cette approche.

4.2.2 Modèles additifs linéaires

Ils portent exclusivement sur l'ozone (AIRAQ, AIRLOR), et ont été choisis pour leur rapidité de mise en place (AIRAQ), suite à leurs performances relativement probantes après le test de plusieurs techniques. Le manque de résultats obtenus jusqu'à ce jour (à cause du développement récent de ces modèles) empêche de tirer des conclusions

définitives sur leur efficacité et leur fiabilité. Les premières applications ont fourni des prévisions relativement bien corrélées aux observations. Toutefois, le faible nombre d'épisodes de pollution dans les données d'apprentissage rend difficile la prédiction des valeurs élevées.

AIRAQ et AIRLOR qui a travaillé en collaboration avec le CRAN, ont suivi une démarche analogue dans l'élaboration d'un modèle linéaire :

1. Construction d'un modèle de persistance ;
2. Insuffisance constatée de ce premier modèle, et nécessité d'introduire des variables exogènes.

Les caractéristiques des modèles élaborés par ces deux associations sont synthétisées dans le tableau 4-1 ci-après :

Tableau 4-1 Modèles de prévision additifs linéaires

	AIRAQ	AIRLOR
Polluant	O ₃ (prévu : NO ₂ , PM ₁₀)	O ₃ (prévu : NO ₂)
Type de prévision	Concentration maximale	Concentration maximale
Horizon de prévision	J→J	J→J+1
Moment de la prévision	-	16h30 / 17 h (jours ouvrés)
Variables explicatives retenues	<ul style="list-style-type: none"> • Concentration maximale d'O₃ de la veille, et concentration minimale d'O₃ avant 5 heures • Concentration maximale de NO₂ avant 5 heures • Paramètres météorologiques du jour : température minimale et maximale, vitesse du vent 	<ul style="list-style-type: none"> • Concentration maximale d'ozone de la veille et du jour • Paramètres météorologiques prévus pour le lendemain : température maximale, gradient de température, humidité relative moyenne, vitesse moyenne du vent
Variables explicatives non retenues	nébulosité (corrélée à la température), pluie (non déterminante), direction du vent (non testée).	rayonnement
Critère de sélection des variables	Calcul du coefficient de corrélation [O ₃]/variable	
Historique utilisé pour l'identification	2*6 mois : printemps et été 1998 et 1999	2 *6 mois : printemps et été 1995 et 1996 Mise à jour annuelle envisagée
Historique utilisé pour la validation	Validation prévue sur les données de l'été 2000	2 * 6 mois : printemps et été 1997 et 1998 <i>Pas d'appréciation sur l'historique nécessaire</i>

	AIRAQ	AIRLOR
Lieu de la prévision, stations utilisées	4 stations de l'agglomération bordelaise	
Contrôle qualité	$\varepsilon = g(\text{obs})$ $f(\varepsilon)$	corr (obs/prévi) $f(\varepsilon)$ EMQ
Résultats	Erreur relativement faible au vu des graphiques comparatifs prévisions/observations, mais certains événements non expliqués.	$\varepsilon \in [-20, + 20] \mu\text{g}/\text{m}^3$ Valeurs du coefficients de corrélation obs/prévi: 1995 : 0,86 1997 : 0,82 1996 : 0,86 1998 : 0,88 Sous-estimation des pointes
Durée et coût de développement	2 mois 1/2 d'étude	800 kF / 3 ans
Coût annuel du modèle	1000 (?) F : données météo	10 kF/an : données météo 10 jours ingé/an (ajustement) 0,5 h/jour technicien

Malgré des résultats globalement satisfaisants: erreurs de prévision faibles, coefficients de corrélation (*prévisions/observations*) élevés, ces deux modèles ne constituent qu'une première étape. La prévision des pointes de pollution notamment reste peu satisfaisante. Aussi bien AIRAQ qu'AIRLOR envisagent d'améliorer les modèles, et d'accroître leur capacité à prédire les fortes valeurs. Parmi les travaux à venir, figurent une meilleure caractérisation des journées à forts niveaux d'ozone, une étude sur l'incertitude des données et la sensibilité du modèle aux paramètres météorologiques, la production d'un indice de confiance.

4.2.3 Modèles non linéaires

Ils portent essentiellement sur l'ozone et ont été retenus pour leur facilité de compréhension et de mise en œuvre et leurs bonnes performances (AIRPARIF, AIR PAYS DE LA LOIRE).

Tableau 4-2 Modèles de prévision non linéaires

	AIR BREIZH	AIR PARIF	AIR Pays de la Loire
Type de modèle	Modèle non linéaire additif (GAM) Modèle conditionnel estimé (MCE) (en cours de développement)	Modèle non linéaire additif	Régression non linéaire
Polluant	O ₃ (prévu : NO ₂ , PS)	O ₃ , NO ₂ (prévu : PM ₁₀)	O ₃
Type de prévision	O ₃ max	O ₃ max (fourchette)	Classes de valeurs

	AIR BREIZH	AIR PARIF	AIR Pays de la Loire
Horizon de prévision	J→J+1	J→J J→J+1	J→J+1 (tous les jours)
Moment de la prévision		9h pour le jour-même, 12h et 19h pour le lendemain (tous les jours)	16h (tous les jours)
Variables explicatives retenues	<ul style="list-style-type: none"> • Concentration maximale d'ozone du jour • Paramètres météo prévus pour le lendemain 12 h : température, nébulosité, vent 	<ul style="list-style-type: none"> • Concentration du jour, données horaires de concentration • Paramètres météo prévus: température, gradient de température, hygrométrie, nébulosité, vitesse du vent au sol et en altitude 	<ul style="list-style-type: none"> • Concentration maximale d'ozone du jour • Paramètres météo prévus pour le lendemain : température maximale vitesse et direction du vent
Critère de sélection des variables	Corrélation entre concentration maximale d'ozone et les variables	Critères statistiques et méthode CART	Analyse statistique des variables et réduction par recours à l'expertise des ingénieurs Air Pays de la Loire
Variables explicatives non retenues	Humidité (difficilement prévisible), pression atmosphérique (non déterminante)	Une centaine !	Rayonnement (données non disponibles), pression atmosphérique, concentration de NO ₂
Historique utilisé pour l'identification	5 ans (de 1994 à 1998) <i>pas d'opinion sur la durée nécessaire d'historique</i>	Données depuis 1992 <i>Meilleure performance avec un long historique</i>	1 à 4 ans selon les villes <i>Meilleure performance avec de longs historiques</i>
Historique utilisé pour la validation	Année 1999	Non précisé modèle opérationnel depuis 1998	Non précisé modèle opérationnel depuis 1998
Lieu de la prévision, stations utilisées	Bretagne	Agglomération parisienne Zones rurales	Agglomérations de Nantes, Angers, Le Mans
Contrôle qualité	erreur absolue moyenne relative	Biais EMQ f(ε) ε=g(obs) Analyse clinique	(ε) ε=g(obs)
Résultats	Pourcentages d'erreur (année 99): GAM : 12,9 % MCE : 15,3 %	Répartition des résultats selon des classes d'erreur : Pour la période du 1/07/99 au 23/03/00, tous polluants confondus, le pourcentage de prévisions qui présentent une erreur nulle ou faible(classe 0 ou 1) est supérieur à 87 % pour l'échance J et supérieur à 70 % pour l'échance J+1.	Pas de résultats statistiques sur les bonnes performances et les erreurs

	AIR BREIZH	AIR PARIF	AIR Pays de la Loire
Durée et coût de développement	2 à 3 ans investissement total estimé à 300 kF	6 ans 3 MF en fonctionnement (3 personnes à temps plein), 500 kF en investissement	Modèle régression + CART: 8 mois sur 2 ans 250 kF en fonctionnement, 40 kF en investissement
Coût annuel du modèle	Non encore estimé	Achat de données météo quotidiennes 1 pers à plein temps (pour la prévision statistique et déterministe)	1 mois ingénieur/an

L'application des modèles GAM et MCE par AIR BREIZH aux données de 1999 conduit à un pourcentage d'erreurs limité (<20%), comparable à celui qu'obtient AIR PARIF.

Le bilan trimestriel (du 01/07/1999 au 30/09/1999) et semestriel (du 01/10/1999 au 23/03/2000) des prévisions diffusées par AIRPARIF a permis d'analyser plus en détail la qualité des résultats. D'après ce bilan, le modèle additif non linéaire est nettement supérieur au modèle de persistance. Son efficacité diminuerait cependant sensiblement:

- dans le cas du NO₂, en particulier à l'horizon J+1 (le pourcentage d'erreurs supérieures à 10 µg/m³ est d'environ 29%, contre 10 à 18 % pour l'ozone) ;
- en période estivale (erreur maximale et pourcentage d'erreurs plus élevés, 10 à 15 sous-estimations en trois mois contre aucune en automne et hiver).

4.2.4 Méthode CART

La méthode CART (Classification and Regression Tree) est utilisée aussi bien comme moyen de sélection des variables (AIRPARIF) que comme technique de prévision (AIRMARAIX et AIR PAYS DE LA LOIRE). Sa mise en place dans les associations s'est faite en partenariat avec des laboratoires universitaires (Laboratoire de stochastique et de statistique d'Orsay -Pr Oppenheim- pour Airparif et Air Pays-de-la-Loire ; GREQAM et université de Luminy pour Airmaraix). Cette méthode, facile à appréhender, donne à ce jour des résultats satisfaisants et présente en outre plusieurs caractéristiques intéressantes : possibilité d'introduire des variables qualitatives et quantitatives non limitées en nombre, prise en compte de l'interaction entre variables explicatives, aspect à la fois descriptif et décisionnel.

Tableau 4-3 Prévision par la méthode de classification CART

	AIRMARAIX	AIR PAYS DE LA LOIRE
Polluant	O ₃ (prévu: SO ₂ , NO _x et PM ₁₀)	O ₃ (prévu:NO ₂)
Type de prévision	Concentration maximale	Concentration maximale
Horizon de prévision	J→J J→J+1	J→J+1
Moment de la prévision	9h30 pour la journée 17h pour le lendemain (tous les jours)	16 h (tous les jours)

	AIRMARAIX	AIR PAYS DE LA LOIRE
Variables explicatives retenues	<p><u>Prévision pour le jour:</u></p> <ul style="list-style-type: none"> Concentration maximale d'ozone de la veille et de la nuit; Concentration maximale de NO₂ de la veille et de la nuit; Concentration maximale de SO₂ du matin Paramètres météorologiques du jour: <ul style="list-style-type: none"> Gradient maximal de température du matin, direction, vitesse de vent, température et nébulosité prévues à plusieurs moments de la journée, humidité relative <p><u>Prévision pour le lendemain :</u> même variables, avec combinaison de certaines d'entre elles</p>	<ul style="list-style-type: none"> Concentration maximale d'ozone du jour Paramètres météorologiques prévus pour le lendemain : <ul style="list-style-type: none"> température maximale, humidité relative, nébulosité, vitesse et direction de vent
Critère de sélection des variables	Prise en compte des variables dans l'arbre	Etude des critères de déviance pour chaque prédicteur
Variables explicatives non retenues	Insolation, radiation, concentration d'ozone à plusieurs heures de la nuit (redundantes)	Rayonnement (données non disponibles), pression atmosphérique, concentration de NO ₂
Historique utilisé pour l'identification	2 à 8 ans <i>Meilleure performance si l'historique est supérieur à 5 ans. Au-delà de 5 ans, pas d'amélioration significative.</i>	1 à 4 ans selon les villes <i>Meilleure performance avec de longs historiques</i>
Historique utilisé pour la validation	-	-
Contrôle qualité	EMQ $\epsilon = g(\text{obs})$	f(e) $\epsilon = g(\text{obs})$
Résultats	Résultats relatifs à des classes de valeur (prévisions pour le jour-même, mois d'été 1999) : pourcentages de bonnes prévisions: - classe 0-130 µg/m ³ : 65 à 90 % selon les mois - classe 130-180 µg/m ³ : 50 à 75 % - classe >180 µg/m ³ : 15 à 40 %	Pas de résultats fournis à cause de l'incertitude sur les concentrations mesurées
Durée et coût de développement	6 à 8 mois (travail préliminaire non comptabilisé) 400 kF en fonctionnement 50 kF en investissement	Modèle régression + CART: 8 mois sur 2 ans 250 kF en fonctionnement, 40 kF en investissement
Coût annuel du modèle	25 kF : achat de données 40 à 50 kF : matériel informatique, logiciels, maintenance	1 mois ingénieur/an

Le modèle mis en œuvre par AIRMARAIX s'avère relativement fiable dans le domaine des faibles ou moyennes concentrations. Au-delà de 130 µg/m³, la qualité des résultats se détériore.

4.2.5 Réseaux de neurones

Pour prédire les concentrations d’ozone, l'association LIG’AIR s'est orientée vers une modélisation statistique, fondée sur les réseaux de neurones (tableau 4-4). Plusieurs raisons expliquent ce choix : collaboration possible avec des universitaires, facilité d’utilisation, coût minimal de mise en œuvre. La première phase de test du modèle (été 2000) s'est révélée très concluante, y compris dans la prévision des fortes valeurs. Celles-ci cependant ont été rares, et la bonne performance du modèle demande maintenant à être confirmée.

Tableau 4-4Prévision par la méthode des réseaux neuronaux

	LIG’AIR
Polluant	O ₃ (prévu: PS)
Type de prévision	Concentration maximale
Horizon de prévision	J→J+1
Moment de la prévision	Utilisation prévue en période estivale 14h (tous les jours)
Variables explicatives retenues	<ul style="list-style-type: none"> • Concentration d'ozone du jour (à 14 h) • Paramètres météorologiques du jour: Température maximale et inversion de température, direction et vitesse de vent, couverture nuageuse, temps sensible • Caractérisation du jour de la prévision : jour ouvré ou WE/jour férié Autres variables envisagées : NO _x , traceur de la circulation automobile (CO)
Critère de sélection des variables	Connaissances physico-chimiques, traitement statistique, Adaptation du modèle à l'atmosphère fourni par Météo-France
Variables explicatives non retenues	-
Historique utilisé pour l'identification	1 an, alimentation du modèle d’année en année
Historique utilisé pour la validation	-

	LIG’AIR
Lieu de la prévision, stations utilisées	3 stations dans l'agglomération d'Orléans (généralisation prévue aux autres agglomérations)
Contrôle qualité	$\varepsilon=g(\text{obs})$
Résultats	Erreur relative sur les prévisions de +/- 19 %
Durée et coût de développement	6 mois 50 kF en investissement
Coût annuel du modèle	36 kF : achat de données 1 h ingénieur/jour

4.3 MODELES DETERMINISTES

Seules deux associations (AIRPARIF et ASPA) utilisent à ce jour la modélisation déterministe à des fins prévisionnelles (tableau 4-5). Les modèles déterministes, en effet, sont d'une utilisation routinière moins aisée, et plus coûteuse en données d'entrée et en temps de calcul que les modèles statistiques; or les AASQA doivent fournir des prévisions dans de brefs délais.

En parallèle avec un modèle statistique, l'association AIRPARIF fait appel au système de prévision physico-chimique Pollux (prévision d'O₃ et NO₂). Ce système, développé entre 1996 et 1999 à l'Institut Pierre-Simon Laplace, est fondé sur la version régionale du modèle de chimie-transport, Chimère (Vautard., 1999), volontairement simplifié pour permettre une souplesse d'utilisation et faciliter la prévision quotidienne. Durant l'année 2001, le système de prévision CHIMERE sera également installé à l'ORAMIP à Toulouse, et son intégration est envisagée sur la région Languedoc-Roussillon par AIR Languedoc-Roussillon. L'ASPA s'est équipée de ce même modèle il y a un peu plus d'un an. Depuis l'automne 1998, un modèle déterministe relatif aux polluants primaires (et à terme à l'ozone) est en cours de développement à ATMO Auvergne. Si la prévision n'en constitue pas l'objectif actuel, elle est cependant envisagée.

Tableau 4-5 Prévision par modélisation déterministe

	AIRPARIF	ASPA
Polluant	O ₃ , NO ₂	O ₃ , NO ₂
Type de prévision	Pic de la moyenne journalière calculée sur 8 stations	
Horizon de prévision	J→J-1 J→J+0 J→J+1 J→J+2 J→J+3	J→J+2
Moment de la prévision	Avant 10 h, 1fois/jour (tous les jours)	2 fois/jour

	AIRPARIF	ASPA
Variables explicatives retenues	Emissions, données météorologiques, données sur les rétrotrajectoires...	idem Airparif
Période de validation	4 mois	"
Contrôle qualité	Biais EMQ f(ε) ε=g(obs) Analyse clinique	"
Résultats	cf ci-après	
Durée et coût de développement	1996-1999 2 MF en fonctionnement 500 kF en investissement	
Coût annuel du modèle	Achat de données météo	

Le modèle régional Chimère a été testé pour la prévision des pics d'ozone en zone urbaine (Ile-de-France) entre le 1^{er} mai 1999 et le 28 août 1999. Les statistiques d'erreur portent sur la comparaison entre le pic de la moyenne observée sur 8 stations de fond avec le pic de la moyenne prévue à J-1, J, J+1, J+2 et J+3.

La qualité des prévisions est définie selon la classe de valeurs à laquelle appartient l'erreur moyenne quadratique (EMQ) :

- EMQ ∈ [0-20 µg/m³] : bonne prévision
- EMQ ∈ [20-40 µg/m³] : prévision médiocre
- EMQ > 40 µg/m³ : mauvaise prévision

Le modèle se caractérise par une bonne performance aux échéances courtes, avec un taux de bonnes prévisions compris entre 70 et 80 %. Ce taux diminue logiquement pour les plus longues échéances (J+2 et J+3), passant à 60-70 % (cf tableau 4-6)

Tableau 4-6 Validation du modèle Chimère régional pour la prévision des pics d'ozone en Île-de-France

Echéance	Corrélation observation/prévision	Taux de bonnes prévisions	Taux de mauvaises prévisions
J-1	0,8	70-80 %	très faible
J		"	"
J+1	0,75	"	"
J+2		60-70 %	< 8%
J+3	0,62	"	"

Un étude plus poussée a montré que le modèle comptait pour une faible part de l'erreur; 75% de celle-ci en revanche est due à la mauvaise estimation/prévision des conditions aux limites. Si l'on s'affranchit de cette erreur, la performance du modèle s'améliore nettement : quelle que soit l'échéance, le taux de bonnes prévisions est supérieur à 80 %, et le taux de mauvaises prévisions inférieur à 3 %.

L'estimation de bonnes conditions aux limites constitue donc la principale difficulté du modèle.

4.4 LOGIQUE FLOUE

Cette approche vise à modéliser la réalité de manière plus fine, en tenant compte de l'imprécision et de l'approximation des connaissances. Un modèle fondé sur la logique floue, encore non opérationnel, a été développé au sein de l'association AIR Languedoc-Roussillon (tableau 4-7). Malgré des débuts prometteurs, la phase de test menée en juin 2000 n'a pas donné les résultats escomptés. Aucune amélioration notable n'a été apportée par rapport au modèle de persistance.

Tableau 4-7 Prévission par logique floue

	AIR LANGUEDOC-ROUSSILLON
Polluant	O ₃
Type de prévision	Concentration maximale
Horizon de prévision	J→J+1
Moment de la prévision	16 h (jours ouvrés)
Variables explicatives retenues	<ul style="list-style-type: none"> • Concentration maximale d'ozone jusqu'à 16 h • Paramètres météorologiques prévus pour le lendemain: Température et vitesse du vent maximales
Critère de sélection des variables	-
Variables explicatives non retenues	Rayonnement, direction du vent, humidité
Historique utilisé pour l'identification	Entre 1 et 5 ans selon l'historique de chaque station <i>Aucune amélioration constatée du modèle avec un long historique</i>
Historique utilisé pour la validation	-
Contrôle qualité	Biais $f(\epsilon)$ $\epsilon = g(\text{obs})$ Définition de 3 classes : - Prévission acceptable : $\text{prévi} \in [\text{obs} \pm 5\%]$ - Prévission non acceptable : $\text{prévi} \notin [\text{obs} \pm 5\%]$ - Valeur faible : $[\text{O}_3]_{\text{J}+1} < 100 \mu\text{g}/\text{m}^3$ (non représentatif pour l'efficacité du modèle)
Indice de fiabilité	-

	AIR LANGUEDOC- ROUSSILLON
Résultats	Test de juin 2000 sur 4 stations : Entre 0 et 14 % de prévisions acceptables (entre 4 et 7 % pour le modèle de persistance)
Durée et coût de développement	22 mois 340 kF + 16,5 kF (poste informatique) en investissement 40 kF en suivi ingénieur
Coût annuel du modèle	achat de données météo 0,5 h ingénieur/jour ouvrable

5. PREVISION DU DEPASSEMENT DES SEUILS

La prévision des concentrations a essentiellement pour fin d'anticiper les pointes de pollution. Cependant, prévision des concentrations et prévision du dépassement des seuils ne sont pas nécessairement indissociables. Des associations engagées depuis peu dans une démarche de prévision numérique ont ainsi privilégié celle des concentrations, mais n'ont pas encore entrepris celle du dépassement des seuils (ATMO Auvergne, AIRLOR, AIR Languedoc-Roussillon). D'autres, inversement, ne se sont attachées qu'à cette dernière problématique (ATMO Poitou-Charentes, ASCOPARG, ASPA).

5.1 DEPASSEMENT DES SEUILS : LES METHODES DE PREVISION

Dans les démarches étudiées, on ne constate pas de stratégie commune des AASQA pour prévoir le dépassement des seuils, qu'il s'agisse :

- du choix des seuils (valeur recommandée , seuil d'information ou seuil d'alerte) ;
- de l'échelle du domaine de prévision : cette dernière peut avoir un caractère local, et porter sur des stations particulières, ou un caractère global, et concerner un ensemble de stations voire le réseau entier.
- du type de prévision, qui se réfère à l'une ou plusieurs de ces approches :
 - (1) prévision directe du dépassement des seuils ;
 - (2) prévision des concentrations puis du dépassement des seuils;
 - (3) prévision de la probabilité de dépasser les seuils.

La deuxième situation est la plus fréquente ; les techniques employées dans ce cas sont les méthodes de prévision des concentrations décrites au chapitre précédent.

Le tableau 5-1 suivant recense les méthodes employées par les AASQA pour la prévision du dépassement des seuils.

Tableau 5-1 Méthodes de prévision du dépassement des seuils

Association	Type de prévision des seuils	Technique employée	Domaine de prévision	Polluant	Seuils retenus	Horizon de la prévision
AIR BREIZH	C puis C>seuil	idem C (non linéaire additif et conditionnel estimé)	1 station	O ₃	130 µg/m ³	J pour J+1
AIR Pays de la Loire	C puis C>seuil	idem C (uniquement méthode CART)	- station/station - sur 9 stations	O ₃	appartenance aux classes [130-180 µg/m ³] [180-250 µg/m ³] [250-360 µg/m ³]	H pour H+12 J pour J+1
AIRAQ	C puis C>seuil	idem C (modèle stat additif linéaire)	sur 4 stations en agglomération	O ₃	4 niveaux (O, 1, 2 et 3)	J pour J
AIRFOBEP	C>seuil	Semi-empirique (tests logiques)	sur plusieurs stations de la région	O ₃	information	J pour J J pour J+1
AIRMARAIX	C puis C>seuil	idem C (CART+expertise humaine)	- station/station - sur ensemble de 23 stations	O ₃	recommandation, information, alerte	J pour J J pour J+1
AIRPARIF	C puis C>seuil	idem C (déterministe et statistique non linéaire)	- station/station - sur un ensemble de stations (11 en agglomération, 6 en zone rurale)	O ₃ , NO ₂	information et alerte	J pour J et J+1 (stat) J pour J, J+1, J+2, J+3 (dét.)
ASCOPARG	proba (C>seuil)	régression logistique (SO ₂) modèle multivarié en développement (CART) (O ₃)	- prévision du site le plus pollué (SO ₂) - sur l'ensemble des stations (O ₃)	SO ₂ O ₃	150 µg/m ³ (SO ₂) 180 µg/m ³ (O ₃)	J pour J (SO ₂) J pour J+1 (O ₃)

Association	Type de prévision des seuils	Technique employée	Domaine de prévision	Polluant	Seuils retenus	Horizon de la prévision
ASPA	C>seuil	modèle linéaire, analyse discriminante	- sur plusieurs stations	O ₃	160 µg/m ³ 180 µg/m ³	J pour J+2
ATMO Poitou-Charentes	C puis C>seuil	modèle neuro-flou	moyenne sur 2 stations (périurbaines)	O ₃	140 µg/m ³ 180 µg/m ³ 360 µg/m ³ non observé	H pour H+12 J pour J+1 (en période estivale)
COPARLY	C>seuil proba (C>seuil)	Expertise humaine, logique floue, réseaux neuronaux	- sur 4 stations (O ₃) - sur l'ensemble des stations (SO ₂)	SO ₂ O ₃	recommandation information	J pour J+1
LIG'AIR	C puis C>seuil	idem C (expertise humaine, réseaux neuronaux)	sur un ensemble de 3 stations (en agglomération)	O ₃	information	J pour J+1

C>seuil : prévision directe du dépassement de seuil

C puis C>seuil : prévision des concentrations puis du dépassement des seuils

proba (C>seuil) : probabilité de dépassement de seuil

idem C : même méthode que pour la prévision des concentrations

seuil de recommandation (niveau 1): 130 µg/m³

seuil d'information (niveau 2): 180 µg/m³

seuil d'alerte (niveau 3): 360 µg/m³

Cinq méthodes spécifiques à la prévision du dépassement des seuils méritent d'être détaillées:

1) Le modèle de prévision de SO₂, établi par ASCOPARG en 1989, est fondé sur la **régression logistique**. Cette technique utilise des variables explicatives catégorielles ou continues, pour prévoir les probabilités associées aux valeurs d'une variable de réponse. Le modèle fournit ici la probabilité de dépassement du seuil 150 µg/m³ sur 24 heures. Les variables pertinentes (sélectionnées par analyse en composantes principales et analyse factorielle) sont la concentration maximale horaire sur les stations, et comme paramètres météorologiques, la température au sol et deux gradients de température.

2) Le système **neuroflou**, mis récemment en place par ATMO POITOU-CHARENTES pour la prévision du dépassement des seuils, se compose de deux modèles pour l'horizon J et deux modèles pour l'horizon J+1. Cette approche permet de combiner un modèle statistique, construit selon le principe des réseaux de neurones à partir de données mesurées, et l'expertise humaine. La base d'apprentissage couvre une période de quatre années et contient environ 8 événements par an. Pour chaque horizon, les prédictors sont la concentration maximale d'ozone observée, ainsi que la température maximale, la force et la direction de vent prévues pour l'après-midi ou lendemain, (1^{er} modèle), ou uniquement la température maximale prévue (2^e modèle).

3) Depuis 1997, COPARLY a développé un ensemble de modèles, qui seuls ou en combinaison, visent à prévoir le dépassement des seuils. Différentes techniques ont été employées : statistique, réseaux de neurone, logique floue, l'idée étant de valider une approche par une autre. Les données d'apprentissage s'étendent de 1994 à 1998, avec environ 10 dépassements du seuil d'information (ozone) par an. Les modèles mis en œuvre ont été:

- en 1999 : le modèle flou pour la prévision à 10h, le modèle statistique et les réseaux de neurones pour la prévision à 22h ;
- en 2000 : le **modèle flou** pour la prévision à 8h, le **modèle statistique et flou** pour la prévision à 14h.

Les variables prises en compte sont:

- pour la prévision à 8 heures, la température maximale prévue et le couple de géopotentiels prévus pour le jour et le lendemain (10 classes de géopotentiels fondées sur l'observation des champs de pression ont été définies) ;
- pour la prévision à 14h, des variables météorologiques, et les concentrations d'O₃, NO et NO₂ mesurées à 12 et 14h. La prévision s'accompagne d'un indice de confiance.

Cela constitue un système informatique de prévision de la qualité de l'AIR appelé PICO3.

4) Entre 1996 et 1999, un programme de recherche coordonné par l'ASPA a permis le développement d'un système de prévision statistique des pointes de pollution par l'ozone sur la zone de Strasbourg/Kehl (Engel & al, 1998). Le modèle élaboré pour prévoir à 24 heures un dépassement du seuil d'information repose sur une technique d'**analyse discriminante**. Celle-ci consiste à déterminer les paramètres météorologiques qui séparent au mieux la classe des jours pollués ([O₃] > seuil) de celle des jours non pollués ([O₃] < seuil). La construction du modèle s'est appuyée sur une analyse rétrospective d'épisodes de pollution, affinée par des études à partir d'un modèle déterministe. Les prédictors sélectionnés dépendent du seuil fixé (160, 170 et 180 µg/m³). La concentration maximale d'ozone de la veille et la température maximale quotidienne sont complétées par deux de ces trois variables : température minimale quotidienne, vitesse du vent à 12h et hauteur de la couche de mélange à 1500 m.

5) Les performances limitées du modèle prévisionniste développé par la société SAI (Systems Applications International) -méthode CART-, ont conduit AIRFOBEP à privilégier l'expertise et le savoir-faire de l'association (AIRFOBEP, 1999, Etude interne). Un modèle semi-

empirique a été ainsi élaboré pour prévoir à J et J+1 le dépassement du seuil d'information pour l'ozone. Il s'agit d'une modélisation implicite de la pollution photochimique, fondée sur un ensemble de tests logiques binaires couplés. Ces tests sont réalisés sur des paramètres qui discriminent au mieux les journées polluées ($[O_3] > \text{seuil}$) des journées non polluées ($[O_3] < \text{seuil}$), et qui sont sélectionnés par expertise et analyse des données (ex: persistance, température, vitesse du vent et indicateurs de la stabilité: gradient de température, $[SO_2]$).

5.2 LA PERFORMANCE DES MODELES

L'aptitude des modèles à prévoir le dépassement des seuils s'évalue couramment à l'aide de tables de contingences, de la forme:

	Pas de dépassement prévu	Dépassement prévu
Pas de dépassement observé	t_{00}	t_{01}
Dépassement observé	t_{10}	t_{11}

t_{00} , t_{01} , t_{10} , t_{11} désignent le nombre de jours correspondant à la situation : dépassement (non) prévu/dépassement (non) observé.

Sont alors calculés

- le taux de non détection : $T_{nd} = t_{10} / (t_{10} + t_{11})$
- le taux de fausse alerte : $T_{fa} = t_{01} / (t_{01} + t_{11})$
- le taux de bonnes détections par rapport aux situations à risque potentiel :
 $T_{bd} = t_{11} / (t_{01} + t_{10} + t_{11})$

Remarque :

La définition des scores peut varier d'une association à l'autre.

Ainsi le nombre de dépassements correctement prédits est parfois rapporté au nombre de dépassements réels, sans que soient prises en compte les fausses alertes. Le taux de bonnes détections devenant $T_{bd} = t_{11} / (t_{10} + t_{11})$

Ou bien le nombres de bonnes, de mauvaises prévisions et de fausses alertes est rapportés au nombre total de dépassements prévus et observés. Les différents scores deviennent alors:

- $T_{bd} = t_{11} / (t_{01} + t_{10} + t_{11})$: taux de bonnes détections (*threat score*)
- $T_{md} = t_{10} / (t_{01} + t_{10} + t_{11})$: taux de mauvaises détections
- $T_{fa} = t_{01} / (t_{01} + t_{10} + t_{11})$: taux de fausses alertes

Certaines associations enfin rapportent le nombre de bonnes, de mauvaises prévisions et de fausses alertes au nombre total de situations. Les différents scores s'écrivent donc :

- $T_{bp} = (t_{00} + t_{11}) / (t_{00} + t_{01} + t_{10} + t_{11})$: taux de bonnes prévisions
- $T_{mp} = t_{10} / (t_{00} + t_{01} + t_{10} + t_{11})$: taux de mauvaises prévisions (sous-estimations)
- $T_{fa} = t_{01} / (t_{00} + t_{01} + t_{10} + t_{11})$: taux de fausses alerts (surestimations)

C'est dans ce cas la performance globale du modèle qui est évaluée, quel que soit le niveau de pollution. Le comportement du modèle dans le domaine des fortes concentrations n'est en revanche pas caractérisé.

Il faut donc se garder d'une comparaison trop hâtive entre les résultats des différents systèmes prévisionnistes, et vérifier que les scores donnés par les associations ont la même signification. Le tableau V.2 rassemble les résultats obtenus par les associations.

Tableau 5-2 Performance des modèles de prévision du dépassement des seuils

Association	Méthode	Seuil ($\mu\text{g}/\text{m}^3$) Polluant Horizon	% de bonnes détections ou de bonnes prévisions	% Mauvaises détections	% Fausses alertes	Nombre réels de dépassements/nb total de jours	Période
AIRPARIF	Stat additif non linéaire	180 O ₃ J+1	D : 33 (100) T : 98,5	0 0	67 1,5	2/267 zone urbaine	9 mois : du 01/07/1999 au 23/03/2000
	Déterministe	200 NO ₂ J+1	D: 41 (78) T: 96,3	22 0,7	53 3	9/267 zone urbaine	
		130 O ₃ J+1	D : 45 (63) T : 85	37 7,5	38 7,5	24/120 zone urbaine	
		180 O ₃ J+1	D : 25 (67) T : 95	33 0,8	71 4,2	3/120 zone urbaine	
AIR BREIZH	Stat non linéaire GAM	130 O ₃ J+1	db : 54	33	13	15/an	Eté 2000
	Stat MCE		db : 47	40	13		
AIR Pays de la Loire	Stat CART	180 O ₃ J et J+1	Pas de statistiques , trop de données <180 $\mu\text{g}/\text{m}^3$				
AIRAQ	Stat additif linéaire	4 niveaux de seuil (0,1,2,3) O ₃ J	T : 85	10	5	74/353 : niveau 1 12/353 : niveau 2	Etés 98 et 99

Association	Méthode	Seuil ($\mu\text{g}/\text{m}^3$) Polluant Horizon	% de bonnes détections ou de bonnes prévisions	% Mauvaises détections	% Fausses alertes	Nombre réels de dépassements/nb total de jours	Période
AIRFOBEP	Semi-empirique (tests logiques)	180 O ₃ J	D : 77 (modèle 1) D : 66 (modèle 2) D : 74 (modèle 3)	23 34 26	27 28 16	27 région Etang de Berre	Mai à août 1998
		180 O ₃ J+1	D : 86	14	37	14	
AIRMARAIX	Stat CART	180 O ₃ J (J+1 réactualisé à J)	Db : 69,2 De : 71,4	30,7 28,6	7,5 6,3	32 (région de Marseille)	Eté 1999
ASPA	Stat: analyse discriminante	160 O ₃ J+1	D : 62 (72) T : 82	28 12	18 7	25/60	Eté 1997 (saison de test)
		180 O ₃ J+1	D : 56 (67) T : 87	33 8	23 5	15/60	
ATMO Poitou- Charentes	Modèle neuroflou	140 O ₃ J+1	Db : 30 (33)	67	25	9	Eté 1998
			Db : 29 (33)	67	33	6	Eté 1999
COPARLY	Flou	180 O ₃ J+1	De : 53 (80) Te : 96	20 1	38 3	10/171	Période estivale 2000
	Flou + Stat		De : 61 (80) Te : 97	20 1	27 2	10/175	

D: scores définis classiquement à partir des tables de contingence (T_{bd} , T_{md} , T_{fa})

d : scores définis par rapport au nombre total de dépassements prévus et observés

T : scores définis par rapport au nombre total de prévisions

Les valeurs en italique désignent le taux de bonnes détection indépendamment des fausses alertes.

b : résultats bruts

e : résultats suivis d'une expertise

C'est l'utilisation conjointe d'un modèle statistique et d'un modèle flou (COPARLY) qui donne la meilleure prévision à J+1 du dépassement du seuil d'information d'ozone, avec en outre un pourcentage relativement limité de mauvaises détections (20%) et de fausses alertes (27%). L'expérience d'AIRPARIF montre qu'une parfaite détection des pics entraîne en contrepartie un pourcentage élevé de fausses alertes (67%). Inversement, si le modèle neuro-flou d'ATMO Poitou-Charentes limite les fausses alertes, il se montre le moins apte à anticiper les dépassements de seuils.

Les résultats encourageants obtenus par l'ASPA en 1997 ont conduit l'association à pousser plus loin la modélisation, en combinant notamment le modèle avec une classification des situations par type de temps, et en intégrant des données d'émission.

Les difficultés liées à la prévisions des pointes d'ozone et le besoin de mettre en commun les expériences acquises sont à l'origine du projet *Prévision des Pics d'Ozone*, mené dans le cadre du groupe de travail Modélisation pour l'Environnement du club CRIN Ingénierie du Traitement de l'Information. Sur la base d'un même jeu de données fourni par COPARLY, plusieurs techniques ont été mises en œuvre, et différents modèles de prévision des pics d'ozone (dépassement du seuil d'information) ont été élaborés. Toutes les méthodes font apparaître des non détections et des fausses alertes. (*La Lettre des Clubs CRIN*, 2001). Les résultats obtenus soulignent le problème des données manquantes et imprécises, et la difficulté de choisir des variables pertinentes.

6. PREVISION DE L'INDICE ATMO

6.1 CALCUL ET PREVISION DE L'INDICE ATMO

Jusqu'à présent, les techniques numériques de prévision concernent presque exclusivement les pointes d'ozone et les dépassements de seuils de pollution. L'indice ATMO n'en constitue pas moins pour les AASQA l'un des principaux outils d'information du public, puisqu'il renseigne ce dernier au jour le jour sur la qualité de l'air. D'où l'intérêt d'étendre la prévision à cet indice.

Dans la plupart des associations, la prévision de l'indice ATMO se fait par expertise humaine, en fonction des conditions météorologiques prévues par Météo-France. L'indice ATMO intègre en effet des données non seulement d'ozone mais aussi de NO_x, de SO₂ et de PM₁₀, polluants pour lesquels les modèles prévisionnistes sont peu répandus.

Des méthodes numériques de prévision sont cependant opérationnelles dans quelques AASQA (AIRPARIF, AIRMARAIX, AIR Pays de la Loire), en cours d'élaboration (ASCOPARG, COPARLY), ou envisagées à terme (AIR BREIZH, LIG'AIR).

Les méthodes de calcul et de prévision de l'indice ATMO sont synthétisées dans le tableau VI-1 ci-après. Les associations AIRPARIF et AIR PAYS DE LA LOIRE ont recours aux techniques décrites dans le cadre la prévision des concentrations ou des dépassements de seuils. AIRMARAIX en revanche a construit un modèle statistique linéaire propre à l'indice ATMO. De même, COPARLY prévoit pour 2000/2001 le développement d'un modèle statistique spécifique à l'indice ATMO.

Tableau 6-1 Les méthodes de prévision de l'indice ATMO

Association	Polluants	Horizon de la prévision	Nature de la prévision : Tendance = T Chiffrée = C	Méthodologie	Technique de prévision	Contrôle qualité
AIR Languedoc-Roussillon	NO2 SO2 O3 PM10 (4+3+3 st.)	J → J+1	T C en interne (prévision d'une fourchette)		Expertise humaine	Comparaison classe prévue/indice réalisé
AIR Pays-de-la-Loire	NO2 SO2 O3 PM10 (6+3+2+2 st.)	J → J+1	C	ss-i → ATMO (CART) C → ATMO (régression non linéaire)	CART Régression non linéaire	Table de contingences
AIRAQ	NO2 SO2 O3 PM10 (4+2 st.)	J _(17h) → J+1	T (quelquefois C)	directe	Expertise humaine	Comparaison indice prévu/indice réalisé
AIRLOR	NO2 SO2 O3 PM10 (5 st.)	J → J+1	T+C	directe	Expertise humaine	Comparaison indice prévu/indice réalisé
AIRMARAIX	NO2 SO2 O3 PM10 (5 aggl.)	J _(17h) → J+1	C	ss-i → ATMO	Aix et Marseille : modélisation stat. (linéaire) + expertise humaine Avignon, Aubagne, Toulon: expertise humaine	Comparaison indice prévu/indice réalisé Calcul du pourcentage de bonnes et mauvaises prévisions, et du pourcentage de bonnes prévisions à un pas près

Association	Polluants	Horizon de la prévision	Nature de la prévision : Tendance = T Chiffrée = C	Méthodologie	Technique de prévision	Contrôle qualité
AIRPARIF	NO2 SO2 O3 PM10 (11 st.)	J → J et J+1 (modèle stat.) J → J, J+1, J+2 et J+3 (modèle dét.)	C	C → ATMO	Modélisation statistique (CART+régression non linéaire) Modélisation déterministe (système Pollux)	Comparaison indice prévu/indice réalisé Classes d'erreur
ARPAM	NO2 SO2 O3 PM10 (7 st.)	J _(16h) → J+1	T		Expertise humaine	Un point oral est fait si mauvaise prévision
ASCOPARG	NO2 SO2 O3 PM10	J _(10h) → J J _(16h) → J+1			Expertise humaine	
ASPA	NO2 SO2 O3 PM10				Expertise humaine	
ATMO Auvergne	NO2 SO2 O3 PM10 (5+3+3 st.)	J → J+1	T+C	ss-i → ATMO	Expertise humaine	Comparaison indice prévu/indice réalisé
COPARLY	NO2 (3 st.) SO2 (5 st.) O3 (3 st.) PM10 (2 st.)	J → J+1	T+C	C → ATMO	Expertise humaine Modélisation statistique prévue	E=g(obs)

Association	Polluants	Horizon de la prévision	Nature de la prévision : Tendance = T Chiffrée = C	Méthodologie	Technique de prévision	Contrôle qualité
LIG'AIR	NO2 SO2 O3 PM10 (sur 4 agglo.)	J → J+1	T	C → ATMO	Expertise humaine	Comparaison indice prévu/indice réalisé

directe : Prévision directe de l'indice ATMO directe

ss-i → ATMO : prévision des sous-indices ATMO puis calcul de l'indice ATMO

C → ATMO : prévision des concentrations puis calcul de l'indice ATMO

$\epsilon = g(\text{obs})$: erreur de prévision en fonction de l'observation

2 st. : 2 stations utilisées pour le calcul de l'indice ATMO

agglo. : agglomération

6.2 QUALITE DES PREVISIONS

Les prévisions de l'indice ATMO, effectuées à AIRPARIF par modélisation statistique, se révèlent tout à fait satisfaisantes. La tendance de l'indice est correctement évaluée, et la qualité des résultats supérieure en toutes circonstances à celle du modèle de persistance.

Du 1^{er} juillet 1999 au 30 septembre 1999, le pourcentage de prévisions assorties d'un erreur faible (en classe 0 ou 1) est de 97 % pour l'échéance J (persistance: 81%) et de 81% pour l'échéance J+1 (persistance:73%).

Du 1^{er} octobre 1999 au 23 mars 2000, ce pourcentage est de 99% pour l'échéance J (persistance: 87%) et de 94 % pour l'échéance J+1 (persistance: 80%).

Le modèle se montre le plus performant aux échéances courtes (prévisions pour le jour), et hors période estivale.

7. BILAN DES EXPERIENCES, DIFFICULTES DE LA PREVISION

7.1 BILAN DES EXPERIENCES DANS LES AASQA

Les expériences en prévision des AASQA se révèlent satisfaisantes, même si toutes ne sont pas encore abouties. La plupart des modèles portent sur les pics d'ozone mais tendent à s'élargir aux polluants de l'indice ATMO.

En ce qui concerne l'approche statistique, les méthodes employées se montrent plus fiables que le simple modèle de persistance et justifient les investissements réalisés. Le montant et la répartition des dépenses consacrées à la mise en place de modèles prévisionnistes sont variables. Le coût global de développement se situe généralement entre 250 et 450 kF pour une durée comprise entre quelques mois et 2-3 ans. Un développement plus long et plus poussé entraîne en revanche des coûts élevés (AIRPARIF 3,5 MF au total). L'utilisation quotidienne des modèles semble peu exigeante en temps de travail : environ 0,5 à 1 heure (ingénieur ou technicien) par jour, à quoi viennent s'ajouter chaque année quelques journées d'ingénieur destinées à la réactualisation des modèles.

Aucune technique statistique (régression linéaire, non linéaire, logistique, CART, réseaux de neurones) ne se détache réellement du point de vue de la performance. La principale faiblesse des modèles statistiques est la sensibilité aux paramètres d'entrée, et la sous-estimation des pics de concentration du fait du petit nombre d'épisodes de pollution dans l'historique d'apprentissage. Or plus un événement est rare, moins il est facile à prédire. Par ailleurs, le fonctionnement des modèles est encore trop récent pour qu'une évolution de leur fiabilité au cours du temps puisse être constatée.

Par rapport aux modèles statistiques, le système de prévision Chimère-Pollux (approche déterministe) permet une meilleure compréhension des phénomènes de formation et de transport d'ozone, et fournit une information cartographique à l'échelle régionale. La qualité des prévisions est bonne aux courtes échéances (J, J+1). Les erreurs s'expliquent essentiellement par une mauvaise définition des conditions aux limites. Le développement d'un tel modèle requiert d'importants moyens financiers (AIRPARIF : 2,5 MF)

Une méthode de prévision par logique floue a été élaborée au sein d'AIR Languedoc-Roussillon, mais n'est pas encore opérationnelle. Deux AASQA recourent également à la logique floue pour la prévision du dépassement des seuils : en combinaison avec les réseaux de neurones (modèle neuro-flou) pour ATMO Poitou-Charentes, seule ou associée à un

modèle statistique pour COPARLY. Les résultats obtenus sur deux saisons par cette dernière association s'avèrent concluants.

7.2 QUELQUES DIFFICULTES DE LA PREVISION

7.2.1 Les données d'entrée

Les incertitudes sur les données d'entrée des modèles expliquent une part importante des erreurs de prévision. Une aide à la validation de ces données est d'ailleurs un besoin exprimé par plusieurs associations (AIRLOR, AIR PAYS DE LA LOIRE).

Une étude comparative de modèles de prévision d'ozone fondés l'un sur la régression non linéaire, l'autre sur les réseaux de neurones, a montré la grande sensibilité de ces modèles aux erreurs commises sur les prévisions météorologiques (Cobourn & al., 2000). Face à ce problème, les auteurs suggèrent deux voies de développement possibles: une réduction de la sensibilité des modèles, ou une précision accrue des prévisions météorologiques¹ par temps chaud et ensoleillé. L'élaboration d'un modèle statistique additif de prévision d'ozone (modèle GAM) sur la ville de Houston a soulevé la même question (Davis & al., 1999). Le modèle prédit avec succès les pointes d'ozone du lendemain lorsqu'il introduit les conditions météorologiques qui auront été non pas anticipées mais observées le jour-même. L'utilisation comme prédicteurs des paramètres météorologiques prévus pour le lendemain constitue une source d'erreur supplémentaire. La performance du modèle peut donc être garantie par la persistance des conditions météorologiques. Les situations les plus problématiques seraient en conséquence les périodes de transition météorologique, au cours desquelles les concentrations d'ozone peuvent brutalement varier.

Pour ce qui est des données manquantes, aucune méthode particulière de traitement n'a été mise en évidence : elles sont généralement ignorées (seule l'ASCOPARG mentionne un traitement par interpolation). Notons que les données manquantes n'empêchent pas la méthode CART (AIRMARAIX) d'effectuer une prévision, mais celle-ci s'en trouve faussée. L'analyse experte des résultats doit alors en tenir compte.

7.2.2 Echelle de la prévision

Le nombre de stations qui alimentent en données les modèles statistiques reste limité (de 2 à une douzaine) et l'échelle du domaine de prévision dépasse rarement celle de l'agglomération. Le modèle peut être mis en œuvre station par station (ex : AIRPARIF, AIRMARAIX, AIR Pays de la Loire), les résultats ont alors un caractère ponctuel, avec le risque que les prédicteurs météorologiques ne reflètent pas les phénomènes à petite échelle ; et/ou il intègre les données moyennées de plusieurs stations et fournit une information plus globale sur la ville (ex: AIRPARIF, ATMO Poitou-Charentes). Cette seconde méthode permet de s'affranchir de variabilités locales, mais peut s'avérer minorante en cas de pointes de pollution localisées.

¹ Cette seconde voie de recherche a déjà été explorée dans la région de Strasbourg (Fischer et al., 1998). Un dispositif de mesures micro-climatiques urbaines a été mis en place en 1997 pour affiner les prévisions météorologiques.

Ce principe a été appliqué en Autriche à l'échelle régionale (développement d'un modèle de régression linéaire multiple, Scheifinger & al., 1996). La combinaison des données issues de plusieurs stations du réseau national non seulement améliore la corrélation entre valeurs prédites et observées, mais permet d'obtenir une prévision régionale.

L'approche déterministe adoptée par AIRPARIF et par l'ASPA -système Chimère-Pollux (Vautard, 1999)- a l'avantage, quant à elle, de ne pas se limiter à une seule information quantitative, et de fournir une image régionale de la pollution. Le modèle, validé en 1999 sur la région Ile-de-France, a permis de couvrir un domaine de 150 km*150 km, avec une résolution spatiale de 6 km.

A l'échelle nationale, l'obtention d'une carte de prévisions semble se faire selon deux approches (*TWG-DFO, European Environment Agency, 1997*, cf chap. VIII):

- Un modèle prévisionniste est développé pour l'ensemble du pays et mis en œuvre sur un réseau national de surveillance (resp. 100, 50 et 22 stations en Allemagne, Autriche, Belgique en 1997). Dans les petits pays (Autriche, Belgique), les concentrations prédites ponctuellement aux différentes stations donnent lieu à une interpolation spatiale ;
- Ou alors des modèles déterministes lagrangiens ou eulériens, relativement lourds et complexes, sont développés pour effectuer des prévisions à grande échelle.

8. COMPARAISON AVEC LES EXPERIENCES EUROPEENNES

L'expérience française est ici placée dans son contexte européen. La comparaison avec les pratiques prévisionnistes étrangères peut aider à définir des axes de développement pertinents.

Plusieurs pays européens ont développé et rendu opérationnels des systèmes de prévision d'ozone, principalement destinés à l'information du public (*TWG-DFO, European Environment Agency, 1997*). Si les objectifs sont similaires, aucune tendance générale dans le choix des techniques prévisionnelles ne ressort vraiment. La variété des méthodes rencontrées en France se retrouve à l'échelle de l'Europe.

- Les systèmes de prévision relèvent ainsi de modèles empiriques (modèles de persistance), statistiques (classification, régression, réseaux de neurones), déterministes, ou s'appuient sur l'expertise humaine.
- Il n'existe pas de méthode unique et bien définie pour évaluer leur performance.
- Les estimations portent sur des domaines d'échelle très variable (prévision ponctuelle -station-, régionale, nationale).

En outre, rares sont les modèles qui associent aux résultats une indication sur l'incertitude des prévisions.

8.1 CHOIX DES MODELES DE PREVISION

Il s'agit d'opter pour des modèles d'utilisation facile (essentiellement modèles statistiques) mais parfois peu fiables et peu précis, notamment en cas de conditions météorologiques inhabituelles et de fortes concentrations d'ozone ; ou pour des modèles beaucoup plus complexes (modèles déterministes), coûteux en données d'entrée, souvent lourds à mettre en œuvre, mais plus aptes à traiter des situations anormales (cf. tableau 8-1).

Les difficultés inhérentes à la prévision ont conduit certains pays à intégrer l'expertise humaine dans leur système de prévision (analyse experte des données d'entrée, évaluation des résultats, ex: Royaume Uni) ou à utiliser conjointement plusieurs modèles. Les concentrations d'ozone sont alors prédites en parallèle (ex: Autriche, Pays-Bas) selon les approches statistique et déterministe. Ou bien, comme c'est le cas en Belgique (système *SMOGSTOP*), le système de prévision regroupe plusieurs modèles statistiques qui diffèrent par leurs domaines de performance : les modèles classiques de régression fournissent les meilleurs résultats en période de faible pollution, les modèles fondés sur les réseaux de neurones sont les plus performants pour la prédiction des valeurs extrêmes. Des modèles dits "des plus proches voisins" viennent compléter le système *SMOGSTOP*; ils reposent sur une classification des données et ont pour principe la recherche de cas passés similaires et la comparaison avec ces derniers.

Tableau 8-1 Quelques modèles numériques européens de prévision

Pays	Modèle	Date de mise en œuvre	Avantages	Inconvénients
Autriche	Statistique +interpolation (à partir de 50 stations sur l'ensemble du pays) En développement : Réseaux de neurones Déterministe : lagrangien	01/04/1996	Presque pas de maintenance, simplicité d'utilisation Nombreux paramètres inclus simultanément dans un système relativement simple Capacité à prédire les concentrations dans des conditions météorologiques inhabituelles	Mauvaise prédiction des valeurs élevées
Belgique	Ensemble de modèles statistiques (système <i>SMOGSTOP</i>) : plus proches voisins, régression, réseaux de neurones + interpolation (à partir de 22 stations sur le pays)	01/05/1995	Bonne performance des réseaux de neurones pour la prévision des fortes concentrations Complémentarité des modèles	
Pays	Modèle	Date de mise en œuvre	Avantages	Inconvénients
Allemagne	A l'échelle nationale : modèle statistique (<i>UBA</i>) par régression linéaire multiple sur 100 stations A l'échelle des Länder: différents modèles	Entre 1989 et 1995		Biais significatif pour le modèle national Problème de la prévision des

	statistiques (régression, réseaux de neurones) Projet : combinaison de différentes approches : statistiques (classification, régression), déterministes, neuro-floues			fortes valeurs
Luxembourg	Empirique	1989	Peu de paramètres d'entrée, facilité d'utilisation	Pas de prévision exacte de la concentration maximale (prévision d'une plage de valeurs)
Suède	Déterministe :eulérien (<i>MATCH</i>) (à l'échelle européenne)	1998	Premiers résultats satisfaisants (bonne corrélation prévisions/observations)	
Royaume-Uni	Déterministe+expertise humaine (<i>UK APFS</i>)	1992	Bonne performance, facilité d'interprétation des résultats	
Pays-Bas	Déterministe Statistique	1992	Bonne performance globale	Peu fiable Mauvais résultats en situations anormales

Il est intéressant d'ajouter à ces exemples celui de la Lombardie (Italie). Un système (FOREPOLL) destiné spécifiquement à prévoir à 12, 24 et 36h la probabilité de dépassement des seuils de CO y a été développé à partir de 1994 (Maffei, 1999). Il se compose de trois modules :

- un module *heuristique* qui permet d'éliminer certaines sources de variabilité dans les concentrations mesurées et transforme les données de façon à ce qu'elles dépendent uniquement des conditions de dispersion ;
- un module *stochastique* qui classe les données selon les conditions météorologiques et ajuste une distribution à chaque classe. A une distribution donnée correspond une probabilité *a priori* de dépasser un seuil ;
- un module *bayésien* qui augmente ou diminue cette probabilité à partir de règles bayésiennes fondées sur l'expérience, et fournit une valeur de probabilité *a posteriori*.

Le modèle a été testé pour la prévision à 12 heures du dépassement du seuil 15 mg/m³. Les résultats obtenus sur un an se révèlent satisfaisants, en particulier pour les stations en zone métropolitaine, où la pollution est plus forte et plus diffuse.

8.2 CRITERES DE PERFORMANCE DES MODELES

L'Agence Européenne de l'Environnement insiste sur la nécessité d'harmoniser les critères d'évaluation des modèles et de recourir à des indicateurs de performance.

Les tableaux de contingence conviennent aux prévisions exprimées de façon qualitative. Pour des résultats numériques, le choix des indicateurs est plus vaste. Les paramètres énumérés ci-après caractérisent chacun un ou plusieurs aspects du modèle :

- Erreur quadratique moyenne;
- Coefficient de corrélation entre valeurs calculées par le modèle et observées;
- FB (*fractional bias*) $FB = \frac{\bar{P} - \bar{M}}{\bar{P} + \bar{M}}$

Il sert à détecter une erreur systématique entre valeurs observées et prédites.
 $-2 < FB < +2$ (le meilleur score correspond à $FB=0$).

- S (*skill score*) $S = 100 \cdot \left[1 - \frac{\sum (P_{i+1} - M_{i+1})^2}{\sum (M_i + M_{i+1})^2} \right]$

(où M_i et P_i sont les concentrations observées et prédites le jour i).

Il permet d'établir une comparaison avec le modèle de persistance.

$S < 0$ (> 0) indique une performance inférieure (resp. supérieure) à celle du modèle de persistance.

Le modèle parfait correspond à $S=100$.

- H (*hit score*) $H = 100 \cdot \frac{1}{N} \sum \frac{2r - \Delta}{2r}$

(où r est une plage d'incertitude autour des valeurs observées (M_i) et prédites (P_i), et $\Delta = \min(|P_i - M_i|, 2r)$).

Il vise à estimer l'impact des incertitudes liées aux données d'entrée et au modèle lui-même sur la qualité des prévisions.

$0 < H < 100$ (le meilleur score correspond à $H=100$).

Ces indicateurs sont complémentaires. Fonder son appréciation sur un seul d'entre eux peut conduire à des conclusions erronées ou incomplètes (Comrie, 1997, Gardner, 1999).

Pour apprécier l'aptitude du modèle à anticiper les pointes d'ozone, l'EEA recommande de mener une évaluation dans le domaine des fortes concentrations (en se limitant aux journées où la concentration maximale observée excède une valeur seuil), et de prendre en compte les données de plusieurs saisons estivales.

9. ETUDES STATISTIQUES SUR LES PARTICULES

La plupart des AASQA souhaitent étendre la modélisation à la prévision des concentrations de PM_{10} , ce qui exige une bonne compréhension de l'origine de cette pollution. Ce chapitre constitue une brève synthèse des études statistiques françaises et étrangères sur ce sujet.

Celles-ci n'abordent pas directement la question de la prévision quotidienne des concentrations de particules, mais traitent plutôt de la relation sources/concentrations. La plupart visent à identifier les sources émettrices d'aérosols, et à déterminer l'importance de leur contribution à la pollution particulaire mesurée dans l'air ambiant. Ces sources incluent

entre autres le trafic routier, les industries, le sol. Les modèles employés sont les modèles récepteurs, qui reposent sur différentes techniques statistiques : régression linéaire, analyse factorielle, méthode de classification.

9.1 MODELES RECEPTEURS

Ils sont fondés sur le principe de conservation de la masse :

Soit p le nombre de sources. S'il n'existe aucune interaction entre les aérosols émis par les sources, la concentration massique du composant i dans l'aérosol prélevé s'écrit :

$$C_i = \sum_{j=1}^p a_{ij} S_j \quad (1)$$

où S_j est la contribution de la source j , et a_{ij} la fraction massique de cette contribution, relative au composé i .

Henry et al (1984) ont passé en revue des modèles récepteurs et les ont classés en deux catégories :

- Chemical mass balance models (équilibre de la masse chimique)
- Modèles multivariés

9.1.1 Chemical mass balance model

Ces modèles se réfèrent à l'une de ces approches:

a) La méthode des éléments traceurs

Elle suppose que chaque aérosol contient un traceur t , propre à la seule source j , et qui est considéré par conséquent comme la signature de cette dernière. La contribution de la source j s'obtient de façon immédiate, pourvu que les fractions massiques a_{ij} soient connues :

$$S_j = \frac{C_t}{a_{ij}}$$

b) La méthode des moindres carrés ordinaire (MCO) ou la *méthode des moindres carrés généralisée*, plus appropriée lorsqu'il s'agit d'introduire les erreurs de mesure dans les concentrations C_i et les paramètres a_{ij} .

Si les sources émettent des aérosols de même composition chimique, ou que la composition chimique de l'un soit une combinaison linéaire de celles des autres, la modélisation se heurte au problème de la colinéarité. Celui-ci peut être résolu par la mise en œuvre d'une régression linéaire *de Ridge* ou d'une régression linéaire sur les composantes principales.

Exemple : Au lieu de traiter directement les données de PM_{10} , certains auteurs mènent une régression linéaire sur les concentrations de polluants choisis comme traceurs du trafic routier: CO, NOx, (Deacon et al., 1997).

9.1.2 Modèles multivariés

Ils s'emploient pour analyser un ensemble de m échantillons, issus de m sites ou prélevés au cours de m périodes. L'équation (1) devient alors :

$$C_{ik} = \sum_{j=1}^p a_{ij} S_{jk} \quad k=1..m$$

L'objectif de ces modèles est de prédire le nombre p de sources, les S_{jk} ou d'estimer simultanément les a_{ij} et S_{jk} . Ils se divisent en deux groupes : les analyses factorielles et les régressions linéaires multiples.

a) Méthodes d'analyse factorielle (AF)

Elles consistent à mener une analyse en composantes principales sur la matrice des corrélations relative aux observations C_{ik} . L'analyse factorielle a donné lieu à différents développements, telle la méthode d'Alpert et al. (Target transformation factor analysis (TTFA)-, 1980)².

Quelques exemples d'AF :

1. Etude japonaise (Okamoto et al., 2000) : détermination des sources de PS au moyen d'une analyse factorielle

Les données se composent de prélèvements de PS effectués en hiver et printemps sur huit sites, à raison de deux échantillonneurs par site. Au cours de chaque campagne, les PS ont été échantillonnées en continu pendant deux semaines. Les sites se trouvent le long d'une rue de Tokyo qui coupe une grande artère (100000 véhicules/jour). 25 composés ont été mesurés (Al, Br...) ainsi que l'état du trafic et différents paramètres météorologiques (vitesse du vent, humidité, température).

2. Etude suisse (Staehelin et al., 2000): détermination de la contribution du trafic aux concentrations de particules observées, au moyen d'une analyse factorielle

Les données se composent de prélèvements de composés organiques volatiles (COV) et inorganiques effectués en deux sites, le premier au centre de Zurich, le second à sa périphérie. L'échantillonnage a été mené de façon continue durant une année.

3. Alpert et al. (1980): application de la méthode TTFA pour déterminer le nombre et la contribution des sources émettrices des aérosols observés

90 échantillons d'aérosols ont été collectés pendant 5 mois et répartis en deux catégories selon leur origine: urbaine ou périurbaine. 16 composés ont été mesurés.

9.1.3 Méthode de régression multiple

Un élément traceur (une signature) est déterminé au préalable pour chaque source de pollution. Une régression linéaire multiple permet ensuite d'expliquer par ces traceurs les concentrations des éléments qui composent l'aérosol. La contribution de chaque source est

² La matrice est calculée autour de l'origine et non comme d'ordinaire, autour de la moyenne. La projection des variables C_i sur les axes factoriels mis en évidence est menée selon un vecteur test b . Ce vecteur résulte de recherches en chimie et correspond au profil réel des émissions par les différentes sources. La projection fournit directement la décomposition des C_i selon l'équation (1).

représentée par l'estimation du paramètre associé à son traceur. Le modèle de régression s'écrit :

$$M_k = b_0 + \sum_{i=1}^n b_i T_{ik} + \varepsilon_k$$

où M_k est la masse observée le jour k , T_{ik} la quantité observée du traceur i le jour k , b_i le coefficient de régression du traceur i , b_0 la pollution de fond, et ε_k l'erreur aléatoire.

Le choix des éléments traceurs se fait grâce à la connaissance des sources d'émission et de leur composition. Pour prévenir le problème de colinéarité, il importe que les traceurs soient indépendants les uns des autres.

Exemple :

Dans le cas de traceurs communs à plusieurs sources, Morandi et al. (1987) ont fait appel à l'analyse factorielle et à la régression linéaire multiple. Les données proviennent d'échantillons d'aérosol, collectés sur des périodes de 24 heures, pendant les saisons estivales et hivernales de 3 années. Les concentrations moyennes journalières de SO_2 , CO et O_3 ont été mesurées en parallèle.

9.2 METHODE DE CLASSIFICATION AUTOMATIQUE

Elle sert à répartir les échantillons en différents groupes, selon les variables observées. L'application de cette méthode précède souvent la mise en œuvre d'un modèle récepteur.

Exemples :

- 1- Dans une étude sur l'origine de la pollution particulaire à Boston (Alpert et al., 1980), la classification automatique a permis de répartir les 90 échantillons prélevés en deux groupes: les échantillons d'origine urbaine, et ceux d'origine périurbaine.
- 2- De la même manière, une analyse de l'influence des paramètres météorologiques sur les concentrations des aérosols acides en Pennsylvanie (Zelenka, 1997) a été précédée d'une classification automatique. Chaque classe réunit les jours de la base de données qui présentent des conditions météorologiques similaires.

10. CONCLUSION

Ce retour d'expérience montre un réel engagement des AASQA dans la prévision des pointes de pollution. En plus de l'expertise humaine, qui intervient aussi bien en amont (choix des prédicteurs) qu'en aval (analyse des résultats) de la prévision, trois approches se distinguent : l'approche statistique, l'approche déterministe et la logique floue. Le recensement des démarches menées par les AASQA met en évidence une orientation générale vers les modèles statistiques, relativement faciles d'approche et d'utilisation. Il apparaît cependant une grande diversité dans le choix même des techniques, qui s'observe également à l'échelle européenne.

Les résultats peuvent être dans l'ensemble jugés satisfaisants. Le test et l'utilisation routinière des modèles font toutefois ressortir quelques faiblesses qui suggèrent des axes de développement : meilleure prise en compte des dépassements de seuils dans la phase d'apprentissage, évaluation des incertitudes liées aux données et de la sensibilité des modèles, définition d'un indice de confiance... Quelques expériences réussies montrent par ailleurs la pertinence de combiner différentes approches.

La prévision aujourd'hui se limite surtout à l'ozone et concerne dans une moindre mesure le SO₂ et les NO_x. La prévision de l'indice ATMO, outil indispensable d'information sur la qualité de l'air, suggère de diriger aussi les efforts vers la prévision des particules. Les études statistiques dans ce domaine traitent essentiellement des relations sources/concentrations. Mais par l'analyse qui est faite sur l'origine des particules, elles peuvent constituer un point de départ intéressant pour la sélection de prédicteurs.

Sont joints en annexe les tableaux récapitulatifs des démarches adoptées par les AASQA ainsi que le questionnaire qui leur a été soumis.

11. REFERENCES

- AIRFOBEP, 1999. *Prévision des pics de pollution d'ozone dans la région de l'Etang de Berre*, Etude interne.
- CHANG M.E., CARDELINO C., 2000. *Application of the Urban Airshed Model to Forecasting Next-Day Peak Ozone Concentrations in Atlanta, Georgia*, Journal of the Air and Waste Management Association, 50, 2010-2024
- COBOURN W.G., DOLCINE L., FRENCH M., HUBBARD M.C., 2000. *A comparison of nonlinear regression and neural network models for ground-level ozone forecasting*, Air & Waste Management Assoc., 50, 1999-2009
- COMRIE A., 1997. *Comparing neural networks and regression models for ozone forecasting*, Air & Waste Management Assoc., 47, 653-663
- DAVIS J.M., SPECKMAN P., 1999. *A model for predicting maximum and 8 h average ozone in Houston*, Atmospheric Environment, 33, 2487-2500
- EUROPEAN ENVIRONMENT AGENCY, 1997. *National Ozone Forecasting Systems and International Data Exchange in Northwest Europe*, Technical Report n°9
- ENGEL F., VIEL C., CHANUT H., 1998. *Développement d'un modèle statistique de prévision à 24 heures d'un dépassement du seuil d'information de la population pour l'ozone*, Pollution Atmosphérique, 59-63, juillet-septembre 1998
- FISCHER L., TARGET A., KLEINPETER J., NAJJAR G., PAUL P., STEIGER D., DELACOURT D., 1998. *Premières investigations concernant l'amélioration des prévisions de dépassement des seuils d'ozone sur la région de Strasbourg par analyse de données fines météorologiques*, Pollution Atmosphérique, 73-81, juillet-septembre 1998
- FROMAGE A., 1996., *Prévision des pointes de pollution atmosphérique : état de l'art dans le monde et perspectives pour la région Ile-de-France*
- FROMAGE A., GILIBERT E., 1997. *Prévision des épisodes d'ozone : état de l'art dans le monde*, Pollution Atmosphérique, avril-juin 1996
- GARDNER M.W., DORLING S.R., 1999. *Neural network modelling and prediction of hourly NOx and NO2 concentrations in urban air in London*, Atmospheric Environment, 33, 709-719
- GUILLAS S., RHOMARI N., ZHANG J., 2000. *Bilan de l'existant en matière de prévision statistique des pics de pollution*, Rapport LCSQA.
- Journées Scientifiques de POLLUTEC, 1997, *Les outils de prévision à court terme de la pollution atmosphérique urbaine*, Pollution Atmosphérique, octobre-décembre 1997
- La Lettre des Clubs CRIN, 2000-2001. *Ingénierie du traitement de l'information*, Groupe de travail Modélisation pour l'Environnement, 42, 6-7.
- MAFFEIS G., 1999. *Prediction of carbon monoxide acute air pollution episodes. Model formulation and first application in Lombardy*, Atmospheric Environment, 33, 3859-3872
- ROUÏL L., WROBLEWSKY A., 1999. *Retour d'expérience en modélisation*, Rapport LCSQA

SCHEIFINGER H., STOHL A., KROMMP-KOLB H., SPANGL W., 1996. *A statistical method for predicting daily maximum ozone concentrations*, Gefahrstoffe-Reinhaltung der Luft, 56, 133-137

VAUTARD R., BEEKMANN M., 1999. Validation du modèle CHIMERE Régional pour la prévision des pics d'ozone en Ile-de-France, Rapport interne

Particules :

APLERT D.J., HOPKE P.K., 1980. *A quantitative study of sources in the Boston urban aerosol*, Atmospheric Environment, 14, 1137-1146

DEACON A. R., DERWENT R. G., HARRISON R. M., MIDDLETON D. R. and MOORCROFT S., 1997. *Analysis and interpretation of measurements of suspended particulate matter at urban background sites in the united Kingdom*. The science of Total Environment 203 , 17-36.

HENRY R.C., LEWIS C.W., HOPKE P. K. and WILLIAMSON H.J. (1984). *Review of receptor model fundamentals*. Atmospheric Environment Vol.18, No 8, 1507-1515.

MORANDI M. T., DAISEY J.M. and LIOY P.J., 1987. *Development of a modified factor analysis/multiple regression model to apportion suspended particulate matter in a complex urban airshed*. Atmospheric Environment Vol.21, No 8, 1821-1831.

OKAMOTO S., TAKAHASHI K. and MINAKAWA N., 2000. *Study on suspended particulate matter in the vicinity of roadway*. 9ème colloque international 'Transport et Pollution de l'Air', Avignon, 5-8 juin 2000. Actes, n°70, Inrets ed. Arceuil France, 2000, 7-14.

STAEHELIN J., LOCHER R. MONKEBERG S. and STAHEL W.A., 2000. *Contribution of road traffic emissions to ambient air concentrations of hydrocarbons : The interpretation of monitoring measurements of Switzerland by principal component analysis and road tunnel measurements*. 9ème colloque international 'Transport et Pollution de l'Air', Avignon, 5-8 juin 2000. Actes, n°70, Inrets ed. Arceuil France, 2000, 7-14.

ZELENKA M.P., 1997. *Analysis of the meteorological parameters affecting ambient concentrations of acid aerosols in Uniontown, Pennsylvania*. Atmospheric Environment Vol.31, No 6, 869-878.

12. LISTE DES ANNEXES

Repère	Désignation précise	Nb/N° pages
1	Tableau récapitulatif des méthodes de prévision utilisées par les AASQA	1
2	Tableau complémentaire sur les partenaires associés aux AAQA dans l'élaboration de modèles prévisionnistes et sur les logiciels utilisés	1
3	Questionnaire sur la prévision diffusé aux AASQA par l'ADEME, le MATE et l'INERIS	6