



HAL
open science

Adapter localement les prévisions climatiques saisonnères : désagrégation stochastique et interpolation spatiale

Pierre Camberlin, Christian Baron, Benjamin Bois, Joseph Boyard-Micheau,
Wilson Gitau, Vincent Moron, Pascal Oettli, Laban Ogallo, Nathalie
Philippon

► To cite this version:

Pierre Camberlin, Christian Baron, Benjamin Bois, Joseph Boyard-Micheau, Wilson Gitau, et al.. Adapter localement les prévisions climatiques saisonnières : désagrégation stochastique et interpolation spatiale. 26e colloque de l'Association Internationale de Climatologie, Sep 2013, Cotonou, Bénin. pp.141-146. hal-01116969

HAL Id: hal-01116969

<https://hal.science/hal-01116969v1>

Submitted on 24 Feb 2023

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.



Distributed under a Creative Commons Attribution 4.0 International License

ADAPTER LOCALEMENT LES PREVISIONS CLIMATIQUES SAISONNIERES : DESAGREGATION STOCHASTIQUE ET INTERPOLATION SPATIALE

CAMBERLIN P. ⁽¹⁾, BARON C. ⁽²⁾, BOIS B. ⁽¹⁾, BOYARD-MICHEAU J. ⁽¹⁾, GITAU W. ⁽³⁾, MORON V. ⁽⁴⁾, OETTLI P. ⁽⁵⁾, OGALLO L. ⁽⁶⁾, PHILIPPON N. ⁽¹⁾.

(1) Centre de Recherches de Climatologie, Biogéosciences, UMR 6282 CNRS, Université de Bourgogne, 6 Bd Gabriel, 21000 Dijon, France. [camber@u-bourgogne.fr, benjamin.bois@u-bourgogne.fr, joseph.boyard-micheau@u-bourgogne.fr, nathalie.philippon@u-bourgogne.fr]

(2) CIRAD, UMR TETIS, Maison de la Télédétection, 500 rue J.F. Breton, Montpellier, F-34093, France [christian.baron@cirad.fr]

(3) Department of Meteorology, University of Nairobi, P.O.Box 30197, Nairobi, Kenya [wilsonnie@gmail.com]

(4) Aix-Marseille Université ; CEREGE, UMR 7330 CNRS, Aix en Provence, France, et IRI, Columbia University, New York, Etats-Unis [moron@cerege.fr]

(5) Department of Earth and Planetary Science, The University of Tokyo, Science Building #1, Room 810, 7-3-1 Hongo, Bunkyo-ku, Tokyo 113-0033 Japon, et JAMSTEC, Yokohama, Japon [oettli@eps.s.u-tokyo.ac.jp]

(6) IGAD Climate Prediction and Applications Centre, P.O.Box 30259, Nairobi, Kenya [logallo@icpac.net]

Résumé - Un panorama est fait des méthodes de descente d'échelles permettant de passer de prévisions climatiques saisonnières de large-échelle à des séries locales journalières. L'exemple des générateurs stochastiques de temps est appliqué à la prévision des récoltes de sorgho au Kenya, dans le cadre du programme ANR PICREVAT. Une méthode d'interpolation spatiale des paramètres des générateurs est testée, pour obtenir des séries journalières de précipitations en tout point du territoire. Les séries générées sont utilisées en entrée du modèle agronomique SARRA-H.

Mots-clés : précipitations, désagrégation, prévision saisonnière, générateur stochastique, rendements.

Abstract : *Local-scale adaptation of seasonal climate forecasts : stochastic disaggregation and spatial interpolation.* A presentation is made of downscaling methods enabling to obtain local daily climate time-series from large-scale seasonal forecasts. A stochastic weather generator is then applied to sorghum crop yield prediction in Kenya, in the framework of the ANR-PICREVAT project. A spatial interpolation method of the generator's parameters is tested, to get daily precipitation time-series at any location. The series generated are then used as input to the agronomic model SARRA-H.

Keywords : rainfall, downscaling, seasonal prediction, stochastic generator, crop yields.

Introduction

Les prévisions climatiques saisonnières sont délivrées principalement à l'échelle subcontinentale. Elles occultent également la distribution des événements à l'intérieur des saisons. Or évaluer certains impacts (agricoles, etc) nécessite des données à haute résolution spatio-temporelle. Par exemple, l'intensité des pluies, leur interruption par des séquences sèches, à cumul saisonnier égal, modulent le bilan hydrique des cultures. Si la prévisibilité de ces éléments est mal connue, il faut au moins en tenir en compte de façon probabiliste dans la prévision des récoltes. Adapter localement et à résolution journalière les prévisions saisonnières repose sur des méthodes de descente d'échelle (« downscaling »). Le but ici est (1) d'en faire un tour d'horizon, et (2) de mettre en œuvre l'une d'entre elles, un générateur stochastique, couplée à une procédure d'interpolation afin d'obtenir des séries journalières spatialisées utilisées ensuite dans un modèle agroclimatique de prévision des récoltes.

1. De l'échelle large à l'échelle fine : la désagrégation statistique des données climatiques

La prévision saisonnière s'appuie fortement sur les modèles globaux de climat (MCG : modèles atmosphériques forcés par les températures marines prévues, ou modèles couplés). Leurs mailles sont de l'ordre de 200 km. Si ces modèles permettent en théorie d'accéder à des échelles temporelles fines (notamment journalière), des biais existent dans les nombres de jours de pluie et l'intensité des pluies simulés. L'accès à des échelles spatiales fines et la réduction de ces biais peuvent se faire (1) via un modèle numérique de climat à aire limitée,

apte à décrire des échelles de l'ordre de 5 à 50 km, ou (2) via des méthodes statistiques de descente d'échelle, seules considérées ici. Ces méthodes complémentaires ont jusqu'ici plus été appliquées au climat futur qu'aux prévisions saisonnières.

La descente d'échelle spatiale englobe deux approches (Maraun et al, 2010). Le « Perfect prognosis » établit une relation entre les valeurs observées d'un prédicteur et la variable à prévoir (prédicteur). On substitue alors aux valeurs observées celles prévues par un modèle numérique, s'il n'a pas de biais. Le MOS (« model output statistics ») considère directement la relation (décrite par régression linéaire ou analyse de corrélations canoniques [CCA]) entre sorties d'un MCG et prédicteur. L'avantage est que les biais du MCG sont alors corrigés. Ces techniques sont applicables aux séries journalières générées par les MCG. Elles peuvent être aussi appliquées aux séries saisonnières, qui constituent la partie prévisible du signal, mais si on a besoin de séries journalières, il faut les assortir d'une désagrégation temporelle.

La descente d'échelle temporelle repose surtout sur des Générateurs Stochastiques de Temps (GS) (Srikanthan & McMahon, 2001). Ils produisent des séries journalières stationnelles réalistes, respectant la distribution statistique de la variable climatique. L'intérêt est qu'une infinité de séries peut être générée, ce qui permet de tester la robustesse des prévisions. Pour les précipitations, les GS courants ont deux composantes. La première simule l'occurrence des jours pluvieux, à l'aide de chaînes de Markov. Les chaînes d'ordre 1 considèrent la probabilité qu'un jour pluvieux suive un jour sec (p_{01}) et que deux jours pluvieux se suivent (p_{11}). La seconde composante des GS décrit la quantité de pluie par jour pluvieux (ex : loi exponentielle mixte, loi Gamma). En prévision saisonnière, les GS peuvent être conditionnés en amont (paramètres calculés pour différents régimes de circulation, phases El-Niño... ; Grondona et al., 2000) ou en aval (les séries sont générées stochastiquement, et on ne retient que celles conformes à la valeur saisonnière prévue ; Hansen et Ines, 2005).

Deux types de méthodes permettent une désagrégation à la fois spatiale et temporelle :

- (a) Les analogues. On calcule la distance entre un champ prévu (ex : températures marines) et l'ensemble des réalisations antérieures. Les réalisations les plus proches sont identifiées. On retient les valeurs locales journalières observées aux stations ces années-là.
- (b) Les chaînes de Markov non-homogènes cachées, appliquées aux pluies journalières (Robertson et al., 2007). L'occurrence de pluie est décrite par quelques configurations spatiales journalières. La transition de l'une à l'autre est conditionnée par une chaîne de Markov, et les probabilités de transitions varient selon des prédicteurs atmosphériques.

Nous retiendrons ici les GS, car ils permettent une prévision en des sites non instrumentés, en recourant à une interpolation spatiale des paramètres de ces générateurs (Wilks, 2008).

2. Application à la prévision des précipitations en Afrique de l'est.

2.1. Objectifs

L'utilisation d'un générateur stochastique (GS) pour assurer une désagrégation temporelle des précipitations saisonnières est illustrée pour l'Afrique de l'Est (Kenya et nord tanzanien). Les objectifs sont : (1) évaluer la capacité d'un GS à reproduire la répartition journalière des pluies ; (2) établir la possibilité, par des méthodes d'interpolation spatiale prenant en compte la topographie, d'utiliser le GS dans des sites non instrumentés ; (3) utiliser les séries journalières produites pour des prévisions probabilistes de rendements agricoles. Le terrain est-africain, exigeant car très accidenté, offre un bon test pour l'interpolation spatiale. Parallèlement, les prévisions saisonnières des pluies régionales, bien liées aux températures marines, y sont assez performantes (Philippon et al., 2002). L'objectif est ici d'en dériver des scénarios locaux de répartition des pluies journalières, pour estimation des récoltes à venir.

2.2. Données et méthodes

Les précipitations journalières couvrent un réseau de 121 stations (fig.1). Un contrôle de qualité est effectué et les pluies <1 mm/jour (parfois mal enregistrées) sont considérées comme nulles. Comme il faut privilégier un bon échantillonnage spatial, aux fins d'interpolation spatiale, on retient les séries d'au moins 15 ans sur la période de 1961 à 2001. Le Modèle Numérique de Terrain (MNT) STRM30 (*Shuttle Radar Topography Mission*), à résolution kilométrique, est utilisé pour décrire la topographie.

Le GS retenu a deux composantes. L'occurrence de pluie est décrite par des chaînes de Markov d'ordre 1.

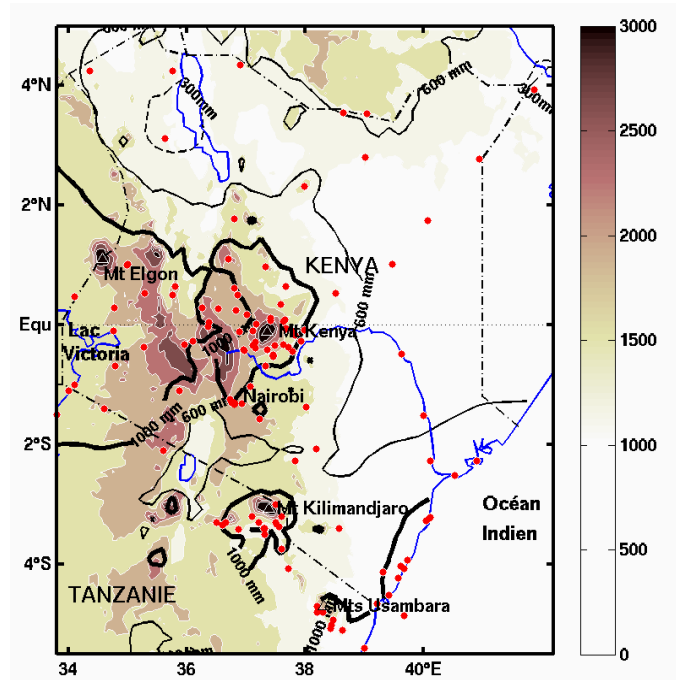
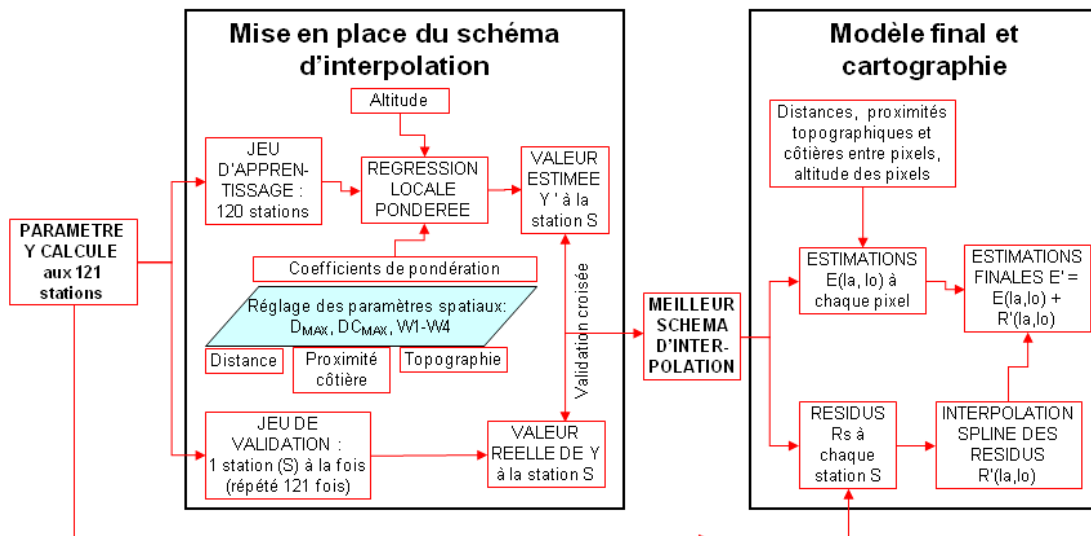


Figure 1. Carte de localisation et réseau de stations. A-plats : altitudes (m). Isolignes : précipitations moyennes annuelles

Quoique pas toujours optimales, elles sont les plus couramment utilisées, avec des résultats satisfaisants dans beaucoup de régions (Srikanthan et McMahon, 2001), y compris en Afrique de l'Est (Gitau et al., 2008). Les quantités précipitées sont décrites par une distribution gamma à 2 paramètres : α , le paramètre de forme, et β , le paramètre d'échelle.

L'analyse comprend quatre étapes, dont les trois premières sont illustrées en fig.2 :

(a) Le calcul des paramètres du GS (p_{01} , p_{11} , α et β) à chaque station et pour chaque mois. La qualité de l'ajustement est évaluée par un test de Kolmogorov-Smirnov (KS).



(b) L'interpolation spatiale des paramètres du GS. Elle s'inspire des méthodes proposées par Wilks (2008) et se base sur des régressions locales pondérées (Joly et al. 2011). Le prédicteur est l'altitude, avec pondération des stations entrant dans les équations de régression en fonction de leur proximité (distance euclidienne [DIST] et/ou ressemblance de

l'environnement topographique) vis-à-vis du pixel cible (fig.2). Les variables représentant l'environnement (TOPO : pentes, orientation et géométrie des reliefs) sont construites selon la méthode d'Oettli et Camberlin (2005), à partir de 4 fenêtres spatiales emboîtées. Une pondération décrivant la proximité côtière est aussi introduite. Un rayon maximal (D_{MAX}) est défini autour de chaque pixel pour intégrer les stations dans le modèle de régression.

(c) *La validation et la cartographie.* Les performances de différents modèles d'interpolation, intégrant un nombre plus ou moins grand d'éléments de pondération, sont comparées par validation croisée. Les critères de validation sont l'erreur quadratique moyenne (RMSE) et le coefficient de corrélation spatial entre les valeurs ponctuelles observées et estimées. La cartographie est ensuite réalisée à la résolution du MNT. Les champs interpolés sont corrigés en réalisant un lissage des résidus par une fonction spline (fig.2).

(d) *La prévision des récoltes.* L'exemple traité porte sur les rendements de sorgho de la saison d'octobre-décembre à l'est du Mt Kenya (Embu). Pour estimer les récoltes, on utilise le modèle de culture SARRA-H. C'est un modèle déterministe de croissance des cultures à l'échelle de la parcelle, validé en milieu tropical (Traoré et al. 2011). Dans le cadre du projet Picrevat, il a été calibré sur les variétés locales adoptées par les agriculteurs sur le Mt Kenya. Les pluies saisonnières (1973-2001) sont prévues par régression à partir du contenu de chaleur de l'est de l'océan Indien [98-101°E, 0-4°S] en juillet-septembre. Pour chaque année, SARRA-H est alimenté par 20 séries de pluie générées stochastiquement en fonction du cumul saisonnier prévu. Ces séries constituent 20 réalisations possibles de distributions intra-saisonnières des pluies. Les rendements potentiels prévus sont comparés avec ceux obtenus dans SARRA-H à partir des précipitations réelles. On se limite ici à une station effective, mais la démarche peut être appliquée en tout point du territoire en utilisant les paramètres interpolés du GS. Les autres données climatiques qui alimentent SARRA-H sont des valeurs climatologiques moyennes, car elles ont une moindre incidence sur les résultats.

2.3 Interpolation spatiale des paramètres des générateurs stochastiques

Le test de KS appliqué à la distribution des épisodes secs montre que 84% des mois et stations (89% pour les épisodes pluvieux) ne présentent aucune différence significative ($P=0,01$) entre l'observation et la simulation à partir de chaînes de Markov d'ordre 1. Ce modèle reproduit donc bien l'occurrence des pluies. Pour reproduire les quantités précipitées, la distribution Gamma est satisfaisante dans 67 à 75% des cas ($P=0,01$) en saison pluvieuse.

La répartition spatiale des paramètres du GS montre une excellente relation avec l'altitude pour p01 et p11 (chaînes de Markov), ce qui est moins net pour les paramètres Gamma malgré une structuration régionale affirmée. Elle se matérialise par des effets d'exposition et littoraux, qui justifient l'utilisation de co-variables environnementales pour l'interpolation. Différents schémas d'interpolation sont testés, avec un nombre plus ou moins grand de variables environnementales, et sont comparés à un schéma de base (« REF ») où toutes les stations sont affectées d'un poids identique égal à 1 (modèle de régression unique pour toute la région). Pour p01 (fig.3) et p11, l'utilisation de régressions locales avec pondération des stations selon la distance (schéma DIST) abaisse fortement les erreurs d'interpolation par rapport au schéma REF. La corrélation spatiale (fig.3b), très basse pour REF, devient en tous mois hautement significative (0,69 à 0,86) avec DIST. La prise en compte de la topographie et de la proximité côtière (« DIST +TOPO ») améliore encore les estimations. Pour les paramètres Gamma, la diminution de l'erreur avec DIST+TOPO est moins spectaculaire, mais les corrélations spatiales sont nettement augmentées (fig.3d). Au cœur des saisons des pluies (avril, octobre-novembre), les configurations spatiales sont très bien reproduites ($r>0,75$).

La fig.4 illustre pour avril l'application du schéma d'interpolation DIST+TOPO au paramètre d'échelle, qui décrit l'intensité des pluies. Les plus fortes intensités sur les versants au vent (expositions est ou sud) et secondairement sur la côte tranchent avec les valeurs très faibles des hautes-terres de l'ouest. L'opposition de versants est particulièrement nette sur le Mt Kenya.

2.4 Prédiction probabiliste des rendements agricoles : exemple d'Embu

La station d'Embu (centre du Kenya) pendant les pluies d'automne boréal est retenue pour illustration.

Un excellent accord ($r=0,89$) apparaît entre les rendements obtenus avec les pluies journalières observées et ceux obtenus avec les pluies saisonnières désagrégées par le GS (fig.5, haut). On conclut au réalisme des pluies journalières générées. Les boîtes-à-moustaches compactes indiquent pour cette station une faible sensibilité des rendements à la distribution intra-saisonnière des pluies. La figure du bas montre les rendements simulés à partir des pluies saisonnières prévues (à partir du contenu de chaleur de l'est de l'océan Indien) puis désagrégées. Les rendements sont souvent bien prévus, mais la performance reste modeste ($r=0,33$), du fait de pluies saisonnières très mal prévues entre 1989 et 1992, ce qui impacte les rendements.




Figure 3. Scores de performance de différents modèles d'interpolation des paramètres p_{01} et β , en validation croisée : à gauche, erreur quadratique moyenne (RMSE) ; à droite, corrélation spatiale entre valeurs observées et estimées ($n=121$; trait horizontal : seuil de signification à 99%).


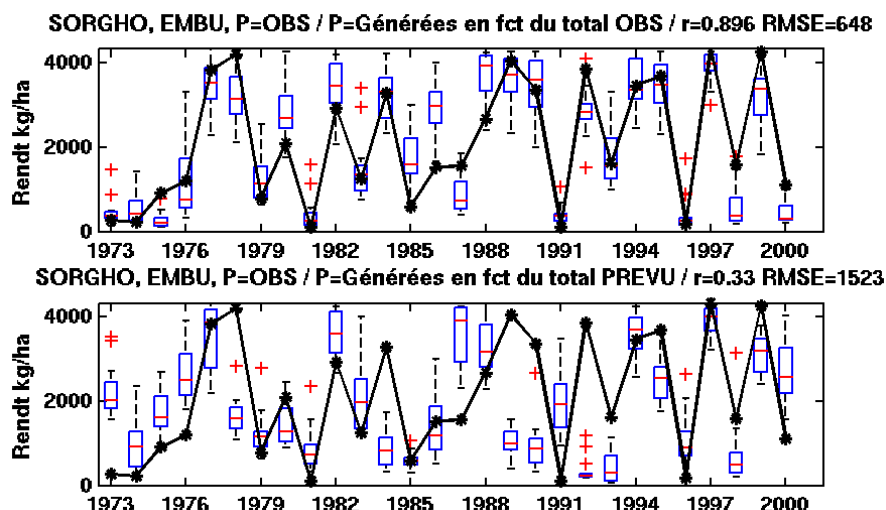


Figure 4. Valeurs interpolées du paramètre d'échelle de la distribution Gamma, pour avril (en dixièmes de mm).

Figure 5. Rendements de sorgho simulés par le modèle SARRA-H pour la station d'Embu à partir des précipitations journalières observées (ligne noire épaisse), et générées stochastiquement (boîtes-à-moustaches) à partir du total saisonnier observé (« prévision parfaite » en haut) et prévu (« prévision opérationnelle » en bas).



Conclusion

La chaîne méthodologique présentée permet de désagréger dans le temps, et à l'échelle locale, des prévisions saisonnières de précipitations, pour estimer les récoltes de la saison à venir à partir d'un modèle agronomique. Les limites de cette simulation des rendements résident dans le fait que, faute de statistiques agricoles, on ne raisonne que sur les rendements potentiels. Les résultats soulignent que l'élément clé d'une prévision correcte des rendements, au-delà de la descente d'échelle, reste la qualité de la prévision des pluies à large échelle.

Bibliographie

- Gitau W., Ogallo L., Mutemi J.N., 2008 : Intraseasonal characteristics of wet and dry spells over Kenya. *J Kenya Meteorol Soc* **2**, 1: 18–28.
- Grondona M.O., Guillermo P.P., Mario B., Monica M., Hugo H., 2000: A Stochastic Precipitation Generator Conditioned on ENSO Phase. A Case Study in Southeastern South America. *J Climate* **13**: 2973–2986.
- Hansen J.W., Ines A.V.M., 2005: Stochastic disaggregation of monthly rainfall data for crop simulation studies. *Agric Forest Meteo* **131**: 233-246.
- Joly D., Brossard T., Cardot H., Cavailhes J., Hilal M., Wavresky J., 2011: Temperature interpolation based on local information. The example of France. *Int J Climatol* **31**: 2141–2153.
- Maraun D., Wetterhall F., Ireson A.M., Chandler R.E., Kendon E.J., Widmann M., Brienen S., Rust H.W., Sauter T., Themeßl M., Venema V.K.C., Chun K.P., Goodess C.M., Jones R.G., Onof C., Vrac M., Thiele-Eich I., 2010 : Precipitation Downscaling under climate change. Recent developments to bridge the gap between dynamical models and the end user, *Rev. Geophys.*, **48**, RG3003, doi:10.1029/2009.
- Oettli P., Camberlin P., 2005: Influence of topography on monthly rainfall distribution over East Africa. *Clim Res* **28**, 3: 199-212.
- Philippon N., Camberlin P., Fauchereau N., 2002: Empirical predictability study of October-December East African rainfall. *Quarterly Journal Royal Meteorological Society*, **128**, 2239-2256.
- Robertson A.W., Ines A., Hansen J.W., 2007: Downscaling of Seasonal Precipitation for Crop Simulation. *J Appl Meteor Climatol* **46**: 677–693.
- Srikanthan R., McMahon T.A., 2001: Stochastic generation of annual, monthly and daily climate data, a review. *Hydrol Earth Syst Sci* **5**, 4: 653-670.
- Traoré S.B., Alhassane A., Muller B., Kouressy M., Somé L., Sultan B., Oettli P., Siéné L., Ambroise C., Sangaré S., Vaksmann M., Diop M., Dingkuhn M., Baron C., 2011: Characterizing and modelling the diversity of cropping situations under climatic constraints in W.Africa. *Atmos. Sci. Let.* DOI:10.1002/asl.332
- Wilks D.S., 2008: High-resolution spatial interpolation of weather generator parameters using local weighted regressions. *Agric Forest Meteo* **148**: 111-120.