

**UNIVERSITATEA TEHNICĂ DE CONSTRUCȚII
BUCUREȘTI**

**MODELAREA PRECIPITAȚILOR SPAȚIAL
DISTRIBUITE**

Rezumatul tezei de doctorat

Drd. ALINA BĂRBULESCU

**Conducător științific
Prof. dr. ing. RADU DROBOT**

2014

CUPRINSUL TEZEI

INTRODUCERE	1
Contextul studiului	3
Date analizate	4
Conținutul lucrării	5
CAPITOLUL I. METODELE MATEMATICE APLICATE LA MODELAREA SERIILOR DE PRECIPITAȚII DIN DOBROGEA	7
1. Metode de modelare matematică	7
1.1 Tipuri de modele. Metoda clasică	8
1.2. Modele de tip Box - Jenkins	9
1.3. Algoritmi genetici	11
1.4. Support Vector Regression (SVR)	13
1.5. General Regression Neural Network (GRNN)	14
1.6. Wavelets	15
2. Modele pentru serii de precipitații lunare	16
2.1. Modele de descompunere și wavelets	16
2.1.1. Modele pentru seria Mangalia	21
2.1.2. Modele pentru seria Sulina	22
2.2. Modelare și predicție bazate pe GEP, AdaGEP, SVR și GRNN	24
3. Modele ARMA pentru serii de precipitații anuale și generarea câmpurilor de precipitații pe baza lor	29
3.1. Modele pentru seriile principale	30
3.2. Modele pentru seriile secundare	38
Rezumatul capitolului	38
CAPITOLUL II. MODELAREA PRECIPITAȚIILOR LA SCARĂ REGIONALĂ ÎN DOBROGEA	40
1. Asupra corelației și predictibilității seriilor precipitațiilor lunare la nivel regional	40
2. Modelarea precipitației regionale	47
2.1. Modelarea precipitației totale	48
2.1.1. Modele splines	49
2.1.2. Modele wavelets	51
2.2. Modelarea precipitației lunare maxime anuale	53
Rezumatul capitolului	58
CAPITOLUL III. INTERPOLARE SPAȚIALĂ CU APLICAȚII LA REGIUNEA DOBROGEA	59
1. Considerații teoretice asupra metodelor de interpolare spațială	59
1.1. Metode mecanice	59
1.1.1. Metoda poligoanelor Thiessen	59
1.1.2. Inverse Distance Weighted interpolation (IDW)	60
1.1.3. Nearest neighbour interpolation	60
1.1.4. Natural neighbour interpolation	60
1.1.5. Splines și local trend surface	61
1.2. Metode statistice	62
1.2.1. Variograma	62
1.2.2. Kriging	64
2. Aplicații ale metodelor de interpolare spațială	65
2.1. Metoda precipitației celei mai probabile	65
2.2. Interpolare spațială a precipitației lunare maxime anuale	70
2.2.1. Interpolare utilizând metoda kriging - ului	70
2.2.2. Interpolare utilizând IDW	72
2.3. Interpolare spațială a parametrilor modelelor AR ale seriilor de precipitații anuale utilizând metodele natural neighbour, nearest neighbour și kriging	74
Rezumatul capitolului	70
CAPITOLUL IV. GENERARE DE CÂMPURI DE PRECIPITAȚII CU APLICAȚII LA REGIUNEA DOBROGEA	81
1. Generarea câmpurilor de precipitații anuale la mai multe locații simultan	81

1.1. Considerații teoretice	81
1.2. Studiu de caz	83
2. Generarea câmpurilor de precipitații lunare	84
2.1. Considerații teoretice	84
2.2. Studiu de caz	87
Rezumatul capitolului	98
CONCLUZII	99
BIBLIOGRAFIE	103

INTRODUCERE

Contextul studiului

Studiul seriilor cronologice reprezintă un domeniu vast de studiu, care implică abordarea din perspectiva domeniului timpului sau a celui al frecvențelor [BoJeRe2008] [Bri2001] [GouMon1990] [JenWat19685] [Vat2003]. Analiza seriilor de timp staționare s-a dezvoltat în mod deosebit după 1970, datorită aplicațiilor sale în diferite domenii. Modelarea seriilor de timp nestaționare, în general, și a celor hidro - meteorologice în particular [ViSmNa2010] implică dificultăți legate de dependența temporală lungă în timp [DmoSal1999] [DoOpTa2003][GrzWac1994] și de dependența spațială [Dor2007] a acestora, corelația cu alte serii [Mietal2009], conceperea de metode de detecție și măsurare a perturbațiilor [OrtRom2004] [KiBaHu2005], propagarea erorilor. În plus, asigurarea acurateții datelor deținute este esențială [Waetal2010].

Modelele hidrologice [Peetal2009] prezintă, în general, cel puțin o componentă deterministă și una stocastică. Utilizarea modelelor pur stocastice este legată de necunoașterea relațiilor de cauzalitate a fenomenului analizat, cele pur deterministe fiind folosite în special în meteorologie, în scopul reproducerii dinamicii câmpurilor de precipitații, pe baza ecuațiilor Navier-Stokes, trunchiate, approximate, apoi integrate numeric (în ipoteza omogenității de scară) [ChaCoq2005]. În ciuda simplificărilor, sistemele de ecuații rezultate sunt complexe, dificil de rezolvat, iar scalele sunt independente între ele.

În vederea simplificării abordărilor, datele sunt supuse unor ipoteze restrictive sau se utilizează diferite transformări pentru a le încadra în tipare standard. Este cunoscut faptul că majoritatea seriilor hidrologice este formată din serii nestaționare în medie [Scetal2002], cu variație diferită pe subperioade, ceea ce necesită procedee diverse pentru modelare pe porțiuni. În plus, distribuțiile lor statistice sunt diferite [BenHub1998], datele nefiind în general independente, prezentând dependență lungă în timp. Existența acestei proprietăți suscită un interes deosebit deoarece estimarea coeficienților Hurst este dificilă în practică [Baetal2003] [Taetal2005], în ciuda clare sale definiri teoretice.

Dacă descrierea evoluției seriilor de date hidro - meteorologice colectate într-un singur punct este dificilă, ea se complică și mai mult atunci când se dorește modelarea la nivel regional, când, pe lângă coordonata timp intervin repartiția spațială a stațiilor hidro-meteorologice, densitatea rețelei, caracteristicile fizico-geografice ale terenului etc. Mai mult, este cunoscut faptul că modelele construite în jurul unei sigure scări sunt inadecvate datorită legăturilor dintre realizarea fenomenului pe diferite scări. Modelele multiscală spațiale și spațio - temporale privilegiază, nejustificat din punct de vedere fizic, una dintre scări, [Hub1999] [LeBris2005] [Tcetal2004]. Pentru conformare la realitate, acestea ar trebui să reprezinte o serie la diferite scări, cu aceleași valori ale parametrilor.

Modelarea structurii precipitațiilor în spațiu și timp este necesară pentru înțelegerea mai bună influenței lor asupra eroziunii solului, producerii inundațiilor, transportului poluanților etc. [BaiRom2007] [ZhaGar2003]. Simularea episoadelor secetoase [Scetal2005] are de asemenea implicații în planificarea distribuției apei între folosințe, terenuri agricole, industrie etc. De asemenea, acesta este necesară pentru elaborarea predicțiilor producerii precipitațiilor utilizând modelele globale sau regionale de circulație [Chetal2004] [HanIne2005]. Modelele spațio-temporale au fost dezvoltate și pentru rezolvarea diferenței dintre scări, privind procesul original și cel agregat [Laetal2008] [WiHaKa2010].

Datele spațiale continue joacă un rol important în planificarea, evaluarea riscurilor și luarea deciziilor în managementul mediului. Practic, eșantioane ale datelor sunt colectate în puncte diferite, deci prezintă discontinuitate spațială. Metodele de interpolare spațială incluzând geostatistică, au fost dezvoltate și aplicate în discipline diverse [HeHeSt2004] [HudWac1994] [MarCue1992] [MeuVan2003] [Wac2003]. Ele sunt specifice datelor sau chiar variabilelor. Mulți factori, inclusiv dimensiunea eșantionului, planul de eșantionare a datelor și proprietățile lor afectează estimațiile făcute prin diferite metode. Nu există rezultate coerente cu privire la modul în care acești factori afectează performanța interpolatorilor spațiali. De aceea, este dificilă selectarea unei metode de interpolare spațială pentru un anumit set de date de intrare. Fiecare metodă are ipotezele și caracteristicile sale specifice, ca global versus local, exact versus inexact, deterministic versus stocastic, gradual versus abrupt [LiHea2008]. Recent, câțiva autori [GotYou2007] [Goo2008]

[Goo2010] [GotYou2002] [GotYou2005] [Kyr2004] au propus folosirea krigingului pentru predicția valorilor punctuale din arealul de date (ATP kriging) [Kyr2004], ceea ce permite cartografierea variabilității în unitățile geografice, asigurând în același timp coerența predicției astfel încât suma sau media estimațiilor dezagregate este egală cu datele originale din areal.

Un criteriu major de evaluare a rezultatelor modelelor este măsura în care valorile simulate reproduc modelul de variabilitate spațială. Ca urmare, au fost elaborate metode de verificare a calității rezultatelor, punându-se totodată problema utilizării valorilor simulate în evaluarea riscurilor [DowPar2002]. În aplicațiile meteorologice, de exemplu, modelele de predicție sunt rafinate prin interpolarea bazată pe erorile determinate la calibrarea locațiilor unde sunt cunoscute atât predicțiile cât și datele observate.

Alte probleme sunt legate de caracterizarea variabilelor agregate. Inferența în astfel de cazuri ar trebui să țină cont de continuitatea spațială și temporală crescută [BacKot1995]. Datele hidrologice conțin informații importante cu privire la evoluția vremii și condițiilor de mediu. Generatorii de vreme cunoscuți până în prezent (WGEN, CLIGEN, LARS - WG) [BaiJon2010] [RaSzSe1991] [RicWri1984] sunt bazați pe generarea unui număr aleator dintr-o distribuție uniformă care este apoi folosit cu un lanț Markov de ordin unu sau doi, cu două stări, pentru a crea starea evenimentului de precipitație la nivelul fiecărei stații.

Pentru producerea cantităților de precipitații, generatorii de vreme selectează o valoare aleatoare a funcției de distribuție corespunzătoare, care este apoi rescalată conform parametrilor statistici ai fiecărei stații meteorologice. Au fost dezvoltate diferiți generatori ai stării vremii: parametrici [BrKhLe2007] [KhLeBr2007], neparametrici [Buetal2008] și hibridi [Foetal2005]. Cei mai mulți generatori parametrici sunt bazați pe primul model al lui Wilks [Wil1998], iar cei neparametrici pe KNN (k-nearest neighbor) [DuHaSt2000].

Datele anuale generate au importanță directă mai redusă, dar sunt utilizate indirect în schemele de dezagregare pentru a obține date lunare. Estimarea cerinței de apă și simularea alocării apei, în general, necesită date lunare. Pentru modelele precipitații - scurgere și cele ale creșterii culturilor sunt necesare date zilnice [SriMcM2001].

Generarea de precipitații și a altor date climatice necesită o gamă de modele depinzând de timpul și scalele spațiale implicate, modele încadrate în trei mari tipologii: statistice empirice, ale dinamicii meteorologice și intermediare stocastice. Modelele de generare a precipitațiilor anuale, lunare și zilnice se încadrează în clasa modelelor statistice empirice [SriMcM2000].

Generarea stocastică de precipitații și predicția evoluției celor din urmă prezintă un interes considerabil pentru evaluarea probabilistică a riscurilor ce ar putea apărea în cadrul sistemelor naturale sau antropice, în care precipitațiile au o contribuție importantă. Astfel de sisteme cuprind infrastructuri de inginerie civilă - cum ar fi clădiri sau poduri (care trebuie să satisfacă cerințele de siguranță pentru a rezista la diferite niveluri de inundații), depozite de apă (rezervoare, bazine de retenție sau rezervoare de apă de ploaie, care trebuie să funcționeze în condiții specifice de fiabilitate) sau sisteme agricole și ecologice, unde amploarea incidenței precipitațiilor asupra sistemului prezintă interes [ShaMeh2010].

Datele analizate

În contextul problematicei prezentate anterior, lucrarea de față își propune aprofundarea modelării evoluției regionale a precipitațiilor în Dobrogea, ca o continuare firească a studiilor noastre asupra evoluției climatice în zonă.

Dobrogea este situată în sud-estul României între 27°15'05" - 29°30'10" longitudine estică și 43°40'04" - 45°25'03" latitudine nordică, având o suprafață de 11145 km² (fără a lua în calcul Complexul Razim - Sinoe și Delta Dunării), cu un relief predominant de podiș, cu altitudine medie între 100 și 300 metri și o înălțime maximă de 467m (în partea de nord a regiunii). Din punct de vedere hidrologic, Dobrogea este caracterizată de fenomene de scurtă durată, cu valori ale precipitațiilor minime la scară națională [PoBoZa2005].

Climatul este continental - temperat, cu temperaturi medii anuale în jurul valorii de 11°C, care scad cu creșterea altitudinii, până în jurul a 9,9°C (la Corugea).

Analiza izohietelor arată că izohieta de 400 mm delimitează teritoriul în două regiuni - zona litorală și cea continentală, pe cea litorală înregistrându-se cele mai mici precipitații. Se remarcă o

descreștere a cantităților de precipitații de la Dudaș la Marea Neagră, în platoul Dobrogei și o creștere a lor în partea sudică a regiunii, pe direcția NE – SV.

Pentru detalii asupra climei în Dobrogea a se vedea [BaTeDe2011][MafBar2008].

Seriile de date analizate în actuala lucrare au fost colectate în Dobrogea, în perioada 1965-2005, la 10 stații meteorologice principale și 41 puncte hidrometrice.

Mulțumiri

Îmi exprim deosebita grațitudine conducătorului științific dl. prof. dr. ing. Radu Drobot, care a avut încredere în mine, a fost un adevărat mentor, m-a susținut pe parcursul elaborării tezei și mi-a împărtășit din valoroasele idei ale domniei sale. Mulțumesc d-lui prof. dr. Romică Trandafir, care m-a ajutat în clarificarea direcției de cercetare și în documentarea pentru elaborarea tezei, ca și domnilor prof. dr. ing. Radu Popa și cc. st. I. dr. Gheorghe Stăncălie pentru efortul depus în analizarea rezultatelor expuse în teză

Mulțumesc colegilor și prietenilor mei dr. Dana Simian și dr. Nicolae Popescu - Bodorin pentru colaborarea fructuoasă care a dus la obținerea unor rezultate importante prezentate în această teză, ca și tuturor celorlalți prieteni și familiei, care m-au susținut necondiționat și au fost în permanență lângă mine, chiar și în momentele în care eu am fost “absentă” față de ei.

CAPITOLUL I

METODE MATEMATICE APLICATE LA MODELAREA SERIILOR LOCALE DE PRECIPITAȚII DIN DOBROGEA

Acest capitol este dedicat prezentării unor modele ale evoluției precipitațiilor înregistrate la stațiile meteorologice din Dobrogea.

În Capitolul I.1. sunt trecute în revistă câteva metode de modelare matematică ce vor fi utilizate în continuare pentru construirea de modele pentru seriile de precipitații, și anume metoda clasică de descompunere, metode de tip Box – Jenkins, algoritmi genetici, SVR, GRNN, wavelets, splines.

În Capitolul I.2. sunt construite mai multe tipuri de modele, astfel:

- Modele de descompunere și wavelets pentru seriile lunare Sulina și Mangalia.
- Modele GEP, AdaGEP, SVR și GRNN pentru seriile lunare Constanța, Sulina și Adamclisi.

Este discutată, de asemenea, influența existenței valorilor excepționale asupra determinării prin diverse metode a punctelor de ruptură și sunt făcute analize comparative ale performanțelor diferiților algoritmi pentru modelarea și predicția seriilor de precipitații. Calitatea modelelor este analizată folosind MSE, MAPE și coeficientul de corelație dintre valorile actuale și cele estimate prin modele. S-a concluzionat că singurul algoritm care învață foarte bine datele de intrare este GRNN, dar nu poate prezice, pe baza acestora, datele de validare.

În continuare a fost propusă o nouă metodă [BarSim2013] pentru obținerea unor nuclee SVR optime multiple pentru predicția unei serii de timp, folosind nuclee standard - polinomial, RBF, sigmoidal - și un set de operații $\{+, *, exp\}$ care păstrează condițiile Mercer [MiNiYa]. Urmând [SimSto2012] s-a propus un nucleu multiplu, format din 4 nuclee simple (însă este posibilă utilizarea unui număr variabil de nuclee simple). Pentru construcția nucleelor multiple se folosește o metodă bazată pe două niveluri. La nivel macro se construiește nucleul multiplu, folosind un algoritm genetic. Nucleele multiple sunt codate în cromozomi a căror calitate este evaluată la nivel micro folosind un algoritm SVR. Principala diferență față de cazul clasificării este existența a două constante adiționale care trebuie alese. Performanța modelului predictiv bazat pe nucleul multiplu dat de algoritmul genetic este evaluat prin validare încrucișată.

În Capitolul I.3 este tratată problema generării de câmpuri de precipitații anuale pornind de la modele de tip ARMA, construite pentru seriile de precipitații anuale. Deși testele statistice au dus la acceptarea ipotezei normalității, la nivelul de semnificație de 5%, pentru 8 dintre seriile de precipitații anuale, calculul coeficienților de asimetrie a relevat existența unei asimetrii care nu a putut fi neglijată.




Fig.3.2 Datele înregistrate și simulările lor (folosind SCL [SCL])

Ca urmare, seriile au fost normalizate prin utilizarea de transformări Box-Cox iar apoi, utilizând software - ul SCL [SCL] au fost generate câmpuri de precipitații pe baza modelelor AR(1), (Tabelul 3.4) cu incertitudinea parametrilor:

$$z_t = \mu + \phi_1(z_{t-1} - \mu) + \varepsilon_t, \quad (3.4)$$

unde (z_t) este o serie de timp normal distribuită, μ este media, iar ε_t este o variabilă aleatoare gaussiană, cu medie zero și dispersie 1.

Exemplificăm pentru seria Adamclisi (Tabelul 3.6, Fig. 3.2)

Tabel 3.4 Modelele seriilor transformate

Seria	Model	Varianta reziduală
Adamclisi	$X_t = 0,142 X_{t-1} + Z_t$	0,5067
Cernavodă	$X_t = 0,169 X_{t-1} + Z_t$	0,3189
Constanța	$X_t = 0,146 X_{t-1} + Z_t$	1,3515
Corugea	$X_t = 0,115 X_{t-1} + Z_t$	0,00001
Hârșova	$X_t = 0,127 X_{t-1} + Z_t$	0,0002
Jurilovca	$X_t = 0,307 X_{t-1} + Z_t$	1,4915
Mangalia	$X_t = -0,141 X_{t-1} + Z_t$	0,012
Medgidia	$X_t = 0,187 X_{t-1} + Z_t$	12,879
Sulina	$X_t = 0,388 X_{t-1} + Z_t$	22,627
Tulcea	$X_t = 0,1637 X_{t-1} + Z_t$	0,0248

Tabel 3.6 Rezultatele simulărilor pentru seria anuală Adamclisi

	Date istorice	Medie	2.50%	50%	97.50%	Da/Nu
Medie	484,54	491,92	418,37	491,645	573,51	Da
Abatere standard	118,31	132,58	83,76	124,165	201,42	Nu
Coeficient asimetric	0,297	0,511	-0,824	0,406	2,407	Da
Coef. autocorel ordin 1	0,136	0,122	-0,344	0,123	0,577	Da
Max	1,511	1,721	1,357	1,617	2,611	Nu
Min	0,612	0,506	0,142	0,535	0,687	Nu
Suma prec min 2 ani	1,353	1,25	0,723	1,27	1,541	Da
Suma prec min 3 ani	2,169	2,08	1,431	2,131	2,459	Da

Abaterea standard nu este estimată cu toleranța stabilită, datorită estimațiilor cuantilelor la peste 90%.

O abordare alternativă este determinarea distribuțiilor care generează seriile de date, aplicarea testelor de conformitate, generarea a 100 de serii de valori din distribuțiile corespunzătoare, estimarea statisticilor de bază și compararea cu cele ale seriilor de date inițiale. Procedul nu introduce erori suplimentare deoarece ceea ce interesează este valoarea medie a statisticilor de bază ale celor 100 de serii generate.

Pentru rațiuni legate de interpolarea spațială, care vor fi tratate în capitolul următor, au fost alese distribuții comune tuturor seriilor principale. Testele de conformitate pe baza cărora s-a făcut selecția au fost Kolmogorov- Smirnov, Anderson - Darling și Shapiro – Wilk. Rezultatele obținute sunt diferite:

- Modelele GEV și Pearson 5 păstrează în limite de toleranță media, abaterea standard, valorile maxime și minime, suma precipitațiilor minime pe 2,3,5,7,10 ani, însă coeficientul de corelație de ordinul 1 este subestimat, iar coeficientul de asimetrie, supraestimat.
- Modelul logistic păstrează numai medie și minimum, supraestimând coeficientul de asimetrie. Exemplificăm rezultatele obținute pentru seria Adamclisi (Tabel 3.17).

Tabel 3.17 Rezultatele simulării pentru seria anuală Adamclisi

	Date istorice	GEV		Pearson 5		Log-logistic	
		Medie	Da/Nu	Medie	Da/Nu	Medie	Da/Nu
Medie	484,54	485,76	Da	484,74	Da	489,233	Da
Abatere standard	118,31	120,70	Da	118,81	Da	130,616	Da
Coeficient asimetric	0,297	0,341	Nu	0,648	Nu	1,278	Nu
Coef. autocorel ordin 1	0,136	0,018	Nu	0,014	Nu	- 0,023	Nu
Min	296,7	259,69	Da	272,92	Da	267,179	Da
Max	731,9	771,33	Da	805,89	Da	966,562	Nu

CAPITOLUL II

MODELAREA PRECIPITAȚILOR LA SCARĂ REGIONALĂ ÎN DOBROGEA

În acest capitol se trece de la modelarea seriilor de precipitații locale (înregistrate la fiecare stație meteorologică) la modelarea evoluției precipitației la nivel regional, pe baza datelor istorice înregistrate la stațiile meteorologice din Dobrogea.

În primul subcapitol propunem o nouă abordare a analizei corelației datelor regionale și a posibilității predicției precipitației la scară regională numai pe baza datelor istorice. În continuare, pe baza acestor rezultate teoretice obținute, sunt propuse două noi metode, utilizate la modelarea datelor anuale [BarDeg2014] și a extremelor lunare [BarPet2013].

În Capitolul II.1 - *Asupra corelației și predictibilității seriilor precipitațiilor lunare la nivel regional* - se evidențiază o procedură de verificare a independenței statistice a datelor istorice și a datelor curente din seriilor lunare de precipitații, bazată pe calculul unui coeficient empiric de corelație - *distanța de corelație empirică* (EDCor) – testul SBR [SRB2013]. Procedura este aplicată pe seriile lunare de precipitații înregistrate la 49 stații hidro-meteorologice din Dobrogea în decursul a 480 luni succesive (începând din ianuarie 1965), și pe versiunile fuzzificate ale datelor, reprezentate folosind 4 sau 5 etichete lingvistice (*uscat, normal, umed* și *ud*, respectiv *uscat, normal, umed, ud* și *foarte ud*).

Sunt concepute mai multe teste pentru a studia independența statistică dintre datele istorice și cele viitoare. De exemplu:

T.1.1: Pentru fiecare stație meteorologică, seriile precipitațiilor locale lungi se împart în date istorice (H_i – primele 240 de luni) și de test (T_i – următoarele 240 de luni) și se calculează distanțele de corelație empirică $R_i(H_i, T_i)$ dintre H_i, T_i . Testul este repetat pentru datele actuale (**T.1.1.a**), trunchiate în domeniul $8/4$ (**T.1.1.b**) și fuzzificate $5/4$ (**T.1.1.c, d** respectiv).

T.1.2 și **T.1.3** ilustrează convergența la valorile EDCor obținute în **T.1.1.d**.

T.1.2 testează convergența EDCor prin calculul coeficienților EDCor pentru serii multi-semestriale de lungimi crescătoare, cu originea respectiv în prima și a 241- a lună (ianuarie 1965, respectiv ianuarie 1985). În **T.1.3** seriile multi-aniuale de lungimi crescătoare sunt consecutive una celeilalte, prima având originea în luna ianuarie 1965.

T.1.4 exemplifică evoluția EDCor calculați pentru cele mai dependente șiruri din datele existente.

T.1.6 are ca scop ilustrarea convergenței coeficienților EDCor calculați pentru cele mai slab dependente șiruri de lungime crescătoare existente în datele înregistrate simultan la diferite stații meteorologice, începând cu luna 1.

Rezultatele testelor conduc la respingerea ipotezei că seriile lungi ale precipitațiilor trecute și cele ale precipitațiilor viitoare sunt statistic dependente. Mai mult, șansele de predicție a seriilor din datele istorice (un gen interpolare temporală) sunt cu mult mai reduse decât cele de determinare a valorilor pe baza valorilor la stațiile învecinate (interpolare spațială).

În Capitolul II.2 propunem două metode de grupare a datelor în vederea determinării trendului precipitației anuale, folosind datele de la cele 10 stații meteorologice principale [BarDeg2014b]. Modele de același tip sunt construite pentru precipitația lunară maximă anuală. Cele două metode sunt aplicate împreună cu tehnicile wavelets și splines pentru determinarea unui model regional al evoluției precipitației anuale și lunare în Dobrogea, folosind serii de date omogene (determinate anterior prin ANOVA). Concluzionând,

- Metoda B furnizează curbe mai netede și dă posibilitate de a avea o imagine de ansamblu asupra trendului global și a punctelor de extrem. Aplicată cu netezirea splines, este mai rigidă decât Metoda A, în contrast cu aplicarea sa împreună cu tehnica wavelets.
- În termeni de eroare standard, tehnicile prezentate aici conduc la modele mai bune în comparație cu cele determinate prin alte metode pentru modelarea precipitației anuale în regiunea Dobrogea [BarDeg2012].
- Chiar dacă modelele splines au fost mai bune în situația de față, remarcăm că modelele wavelets captează mai bine valorile extreme, având capacitatea de a localiza salturile, punând un wavelets mic și extrem de oscilant în jurul său. În plus, modelarea wavelets a seriei de timp furnizează o interpretare a structurii seriei și extrage informații semnificative despre comportamentul său, folosind un număr mic de coeficienți.

- Studiul prezentat are implicații practice. Dacă, de exemplu, o serie de date aparține mai multor grupuri omogene (Gr.1 și Gr.2, în cazul de față), și se dorește determinarea valorilor precipitației în această locație, pentru perioade de timp pentru care datele nu sunt disponibile, datele lipsă pot fi înlocuite cu cele furnizate de modelul cel mai bun. Așadar, este vorba de un gen de proces de interpolare.

CAPITOLUL III

INTERPOLARE SPAȚIALĂ CU APLICAȚII LA REGIUNEA DOBROGEA

Partea întâi conține o serie de considerații teoretice asupra metodelor de interpolare spațială (metoda poligoanelor Thiessen, IDW, nearest neighbour, natural neighbour, splines și local trend surface, kriging). În partea a doua este introdusă *Metoda precipitației celei mai probabile* (MPCMP), ca alternativă a metodei poligoanelor Thiessen și se analizează comparativ cele două metode, pe baza valorilor erorii standard și erorii medii absolute.

Etapele MPCMP sunt:

- Se presupune că sunt date seriile de precipitații înregistrate în n perioade succesive în k locații și se notează prin $\{y_{it}\}_{t=1, \overline{n}}$ seria de precipitații înregistrată la stația i .
- Se construiește matricea precipitației regionale, \mathbf{Y} , care conține pe coloana i precipitația de la stația i .
- Se calculează minimele și maximele valorilor de pe fiecare linie a matricii \mathbf{Y} , adică: $y_{j \min} = \min_{i=1, k} y_{ij}$ și $y_{j \max} = \max_{i=1, k} y_{ij}$, $(\forall) j = \overline{1, n}$ și amplitudinile: $A_j = y_{j \max} - y_{j \min}$, $(\forall) j = \overline{1, n}$.
- În funcție de numărul de serii disponibile se împart intervalele $[y_{j \min}, y_{j \max}]$ într-un număr m_j de subintervale, de lungime $L_j = A_j / m_j$, $(\forall) j = \overline{1, n}$. Numărul natural m_j este ales astfel încât fiecare interval rezultat să conțină un număr suficient de valori, iar lungimea intervalelor să nu fie prea mică.
- Pentru fiecare $j = \overline{1, n}$, se formează cupluri (I_{lj}, f_{lj}) , unde I_{lj} este subintervalul l din perioada j , iar f_{lj} este numărul de valori ale precipitației cuprinse în I_{lj} , numită frecvența absolută a lui I_{lj} .
- Pentru fiecare $j = \overline{1, n}$ se alege acel interval I_{lj} pentru care f_{lj} este maxim. Fie $\overline{I_j}$ acest interval și $\overline{f_j}$ frecvența corespunzătoare. Dacă există mai multe sub - intervale cu aceeași frecvență maximă, se alege ca $\overline{I_j}$ acel interval pentru care media valorilor precipitației este mai apropiată de media aritmetică a valorilor precipitațiilor înregistrate în perioada j .
- Pentru fiecare $j = \overline{1, n}$, se alege ca valoare reprezentativă media valorilor precipitațiilor din $\overline{I_j}$.

Din analiza datelor rezultă că cele metodele sunt comparabile, în cel puțin 30% dintre cazuri estimarea prin MPCMP fiind chiar mai bună. În plus, metoda nu este sensibilă la neomogenitatea datelor, apărând astfel ca o alternativă a metodei poligoanelor Thiessen.




Fig. 2.1 Modele rezultate prin utilizarea MPCMP și metoda poligoanelor Thiessen cu utilizarea a 10, respectiv 9 serii de precipitații anuale

Partea a treia este dedicată interpolării spațiale a precipitației lunare maxime anuale utilizând metodele kriging și IDW și se determină parametrul care minimizează erorile de estimare în metoda IDW.

În Fig.2.4 sunt prezentate rezultatele interpolării seriilor de precipitații Corugea și Adamclisi prin metoda kriging-ului ordinar. Seriile estimate prin utilizarea celorlalte 9 serii principale au fost notate prin *estimat* (9), iar cele estimate prin utilizarea celorlalte 9 serii principale, fără Sulina, au fost notate prin *estimat* (8). Rezultatele au fost comparate utilizând erorile standard și erorile medii absolute și sunt prezentate în Tabelul 2.5. ES sunt comparabile în general, fiind mai mici în 6 cazuri pentru *estimat* (8), în schimb EMA este mai mică numai în 3 cazuri pentru *estimat* (8). S-a observat ca stațiile care au poziții extreme (Mangalia, Sulina) față de grupul celorlalte au șanse mai mari ca erorile de estimare să fie ridicate.




Fig. 2.4 Rezultatele estimării valorilor seriilor Corugea și Adamclisi (1965 - 2005)

Tabel 2.5 ES și EMA în estimările valorilor seriilor prin kriging ordinar

Seria	ES		EMA	
	estimat (9)	estimat (8)	estimat (9)	estimat (8)
Adamclisi	32,73	32,60	25,09	24,88
Cernavodă	22,11	23,32	16,08	17,43
Constanța	30,25	30,03	18,63	19,39
Corugea	22,51	22,04	16,20	16,67
Mangalia	41,97	41,63	26,48	27,15
Medgidia	23,86	22,86	20,11	19,33
Harșova	35,91	36,82	26,13	27,45
Jurilovca	22,67	26,73	18,63	21,56
Tulcea	33,85	32,65	26,56	25,36

În Tabelul 2.6. prezentăm ES și EMA din modelul wavelets construit pentru evoluția regională a precipitației maxime (aceeași abordare din Capitolul II, Secțiunea 2.2), în vederea comparației cu performanțele kriging-ului. Se observă că valorile sunt apropiate, deci rezultatele sunt comparabile.

Tabel 2.6 Eroare medie, ES și EMA în modelul wavelets pentru maxime anuale

	Adamclisi	Cernavodă	Constanța	Corugea	Harșova	Jurilovca	Mangalia	Medgidia	Sulina	Tulcea
Eroare medie	6,71	1,15	-5,50	-2,38	-7,71	-9,23	-2,97	2,54	-28,10	5,45
ES	32,76	31,43	34,71	38,46	35,40	35,97	43,82	26,98	36,10	25,10
EMA	24,63	21,76	22,63	19,50	26,34	19,83	22,46	21,57	30,59	19,15

Ultima parte este dedicată discutării rezultatele interpolării spațiale a parametrilor modelelor AR pentru seriile anuale de precipitații prezentate în Capitolul I.3 și studierii calității interpolării obținute prin diferite metode, pe seriile colectate la stațiile meteorologice principale, apoi pe întregul ansamblu de serii, în scopul estimării influenței aportului de informație suplimentară. A rezultat că metoda nearest neighbour nu dă rezultate satisfăcătoare. În ciuda faptului că metoda natural neighbour

nu furnizează valori ale parametrilor pentru toate locațiile de coordonate introduse pe grid și există o anumită omogenitate spațială a repartizării valorilor parametrilor estimați, valorile furnizate de aceasta sunt mult mai apropiate de cele reale.

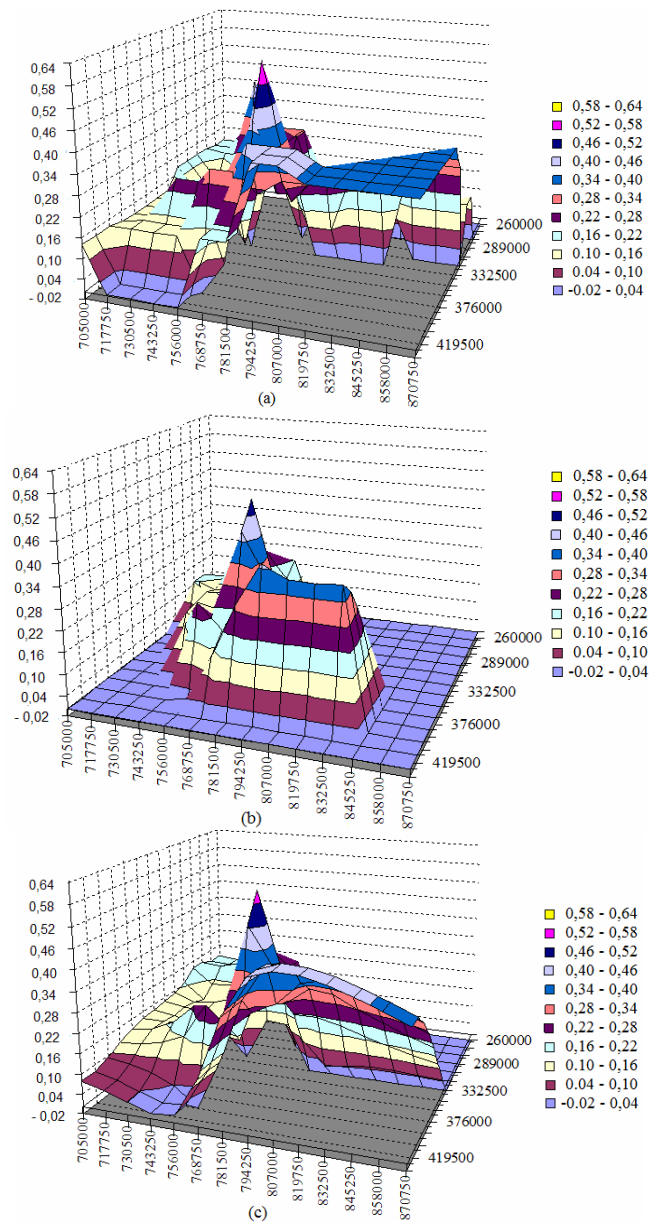


Fig.2.8 Interpolare spațială a coeficienților modelelor AR prin:
 (a) nearest neighbour, (b) natural neighbour, (c) kriging

Tabel 2.13 Interpolarea parametrilor modelelor AR (pentru 51 serii) prin metoda natural neighbour

	709000	260000	273100	286200	299300	312400	325500	338600	351700	364800	377900	391000	404100	417200
721150	-	-	-	-	-	-	-	-	-	-	-	-	-	-
733300	-	-	-	0,17	0,14	0,10	-	-	-	-	-	-	-	-
745450	-	-	-	0,20	0,13	0,13	0,08	-0,01	-0,10	-	-	-	-	-
757600	-	0,19	0,32	0,21	0,16	0,11	0,04	0,01	0,09	0,15	-	-	-	-
769750	-	0,21	0,25	0,24	0,23	0,02	0,10	0,21	0,13	0,18	0,27	0,00	-	-
781900	-	0,20	0,20	0,16	0,17	0,14	0,22	0,46	0,38	0,16	0,19	0,16	-	-
794050	-	0,02	0,08	0,03	0,07	0,04	0,21	0,28	0,31	0,28	0,24	0,30	-	-
806200	-	-	-	0,12	0,10	0,09	0,06	0,01	0,16	0,23	0,26	0,30	0,33	-
818350	-	-	-	-	0,19	0,16	0,15	0,15	0,15	0,17	0,23	0,25	0,24	-
830500	-	-	-	-	-	-	0,23	0,21	0,21	0,21	0,23	0,25	0,25	-
842650	-	-	-	-	-	-	-	-	0,27	0,26	0,26	0,27	0,28	-
854800	-	-	-	-	-	-	-	-	-	-	0,31	0,31	0,31	-
866950	-	-	-	-	-	-	-	-	-	-	-	-	0,35	-

Notă: “-” semnifică faptul că interpolarea nu s-a făcut în punctul de coordonate corespunzătoare

Interpolarea prin kriging furnizează valori între - 0,142 și 0,346, cu o distribuție spațială neuniformă, ceea ce este mai aproape de realitate. Densitatea spațială a seriilor de date fiind foarte mică, rezultatele interpolării nu pot fi foarte bune.

Rezultatele interpolării spațiale a parametrilor autoregresivi de ordin 1 în modelele construite pentru cele 51 de serii de precipitații anuale sunt reprezentate în Fig.2.8 și Tabelele 2.13 - 2.15.

Rezultatele estimărilor au înregistrat o îmbunătățire, în sensul că valorile coeficienților medii au fost captate mai bine de către toate modelele, deși există încă supraestimări ale coeficienților corespunzători modelelor AR pentru locații învecinate stațiilor ai căror coeficienți AR au valorile cele mai ridicate.

CAPITOLUL IV

GENERARE DE CÂMPURI DE PRECIPITAȚII

În acest capitol discutăm problematica generării câmpurilor de precipitații din două perspective.

În prima parte este propusă modelarea simultană a parametrilor modelelor AR construite în Capitolul I.3 pentru seriile anuale prin metoda lowess, folosind 50% dintre vecini, respectiv restul seriilor. Această abordare nu a mai fost întâlnită, după cunoștința noastră, pentru tratarea unor astfel de probleme.

Tabel 1.1 Erori în modelul lowess

Serie	Cu utilizare a 50% dintre vecini				Cu utilizarea tuturor vecinilor			
	Grad polinom local				Grad polinom local			
	0	1	2	3	0	1	2	3
Adamclisi	-0,078	-0,154	-0,154	-0,154	0,016	-0,023	-0,112	-0,112
Cernavodă	0,031	0,109	0,109	0,109	0,072	0,143	0,047	0,048
Constanța	-0,044	-0,031	-0,031	-0,031	-0,005	0,000	0,018	0,038
Corugea	-0,106	-0,329	-0,329	-0,329	-0,094	-0,111	0,248	0,248
Harșova	-0,074	-1,107	-1,107	-1,107	-0,042	-0,134	-0,081	-0,081
Jurilovca	0,129	0,075	0,075	0,075	0,203	0,204	0,117	0,120
Mangalia	-0,395	0,459	0,459	0,459	-0,348	-0,448	-0,334	-0,380
Medgidia	0,035	0,101	0,101	0,101	0,031	-0,094	-0,030	0,032
Sulina	0,130	-0,076	-0,076	-0,076	0,146	-0,039	-0,031	-0,172
Tulcea	-0,051	-0,144	-0,144	-0,144	-0,001	0,220	0,256	0,213
EMA	0,107	0,259	0,259	0,259	0,0957	0,1417	0,1275	0,1445
SE	0,147	0,402	0,402	0,402	0,141	0,187	0,167	0,179

În metoda *lowess* variabilele explicative au fost coordonatele (latitudinea, longitudinea, altitudine) stațiilor meteorologice iar variabila explicată a fost coeficientul autoregresiv de ordinul 1, ϕ_1 , din modelele AR(1) obținute în Capitolul I.3. Setările utilizate în metoda lowess au fost:

- Numărul de serii învecinate utilizate pentru estimare: 50% sau 100% (toate celelalte serii);
- Nucleul utilizat: tricubic,
- Metoda de determinare a parametrului de netezire (bandwidth): minimizarea abaterii standard.

Rezultatele, prezentate comparativ în Tabelul 1.1, arată că cel mai bun model a fost obținut prin utilizarea unui polinom de grad zero (adică netezire local constantă) și a tuturor datelor disponibile.

În Fig.1.1 sunt prezentate valorile înregistrate față de cele estimate, în cele mai bune modele. Dreapta punctată reprezintă prima bisectoare a axelor de coordonate. Cu cât estimațiile sunt mai bune, cu atât punctele care reprezintă datele sunt mai apropiate de prima bisectoare. Se observă gruparea bună, mai ales în cazul (b). Ca urmare, valorile estimate ale coeficienților AR pot fi utilizate cu succes pentru generarea câmpurilor de precipitații. Nu s-a înregistrat o îmbunătățire a modelului prin utilizarea metodei lowess robustificat. Din experimentele preliminare rezultă că metoda neparametrică de netezire local constantă, cu nucleu Gaussian ar duce la obținerea de performanțe superioare, dar nu ne vom referi la aceasta în prezenta lucrare.




Fig.1.1 Dependența parametrilor înregistrați și estimați prin lowess cu: 50% vecini; (b) 100% vecini

Având în vedere că rezultatele sunt bune, se concluzionează că generarea simultană (la toate stațiile) de câmpuri de precipitații poate fi făcută cu succes pe baza acestor modele.

În partea a doua a capitoului sunt generate câmpuri locale de precipitații lunare, utilizând două abordări, despre care se afirmă în literatură că dau rezultate bune. Simulările pe datele din Dobrogea au arătat că abaterile standard ale seriilor de date nu sunt păstrate în mare parte dintre serii, atunci când se utilizează metoda modificată a fragmentelor. Utilizarea metodei AAS, despre care autorii [KouMan1996] afirmă că furnizează predicții foarte bune pe termen lung, a dat rezultate foarte slabe chiar și pentru prognoza pe anul imediat următor datelor de test. Din nou, rezultatul este concordant cu demonstrația din Capitolul II.1 a lipsei de predictabilitate numai pe baza datelor istorice.

CONCLUZII

În acest capitol sunt trecute în revistă contribuțiile personale din cele mai semnificative la modelarea precipitațiilor distribuite spațial în Dobrogea, prezentate în lucrarea de față. Dintre acestea menționăm:

- Construirea de modele de descompunere și wavelets pentru seriile locale de precipitații.
- Construirea de modele alternative pentru evoluția seriilor de precipitații și analiza calității predicției realizate pe baza acestor modele obținute prin aplicarea unor tehnici moderne.
- Construirea de modele AR(1) pentru seriile de precipitații anuale, după normalizare și de modele ARMA pentru seriile secundare.
- Studiul existenței corelației seriilor de precipitații lunare, înregistrate în locații diferite și a legăturii dintre aceasta și posibilitatea elaborării unei prognozei bune a evoluției precipitației la scară regională bazată numai pe datele istorice.
- Propunerea a două metode de grupare și modelare a datelor, care au fost utilizate în continuare împreună cu tehnicile splines și wavelets pentru descrierea evoluției precipitației regionale (totale și maxime) pe date anuale și lunare.
- Introducerea metodei precipitației celei mai probabile.
- Detectarea parametrului optim pentru interpolarea IDW.
- Generarea simultană de câmpuri de precipitații anuale utilizând lowess pentru interpolarea parametrilor.
- Generarea de câmpuri de precipitații lunare și analiza critică a metodei AAS.

Rezultatele originale din teză au fost publicate parțial în articolele:

Bărbulescu A., Deguenon J., 2014, Models for trend of precipitation in Dobrudja, *Environmental Engineering and Management Journal*, **13**(4), pp. 873 – 880 (ISI, FI: 1,258)

Bărbulescu A., Deguenon J., 2014, Change points detection and models for precipitation evolution. Case study, *Romanian Journal of Physics*, **59**(5-6), pp. 590 – 600 (ISI, FI: 0,745)

Băutu E., Bărbulescu A., 2013, Forecasting meteorological time series using soft computing methods: an empirical study, *Applied Mathematics and Information Science*, **7**(4), pp. 1297 - 1306. (ISI, FI: 1,232)

Bărbulescu A., Petac A.-O., 2013, Statistical assessment of precipitation evolution. Case Study, *Automation, Computers, Applied Mathematics*, **22**(1), pp. 23 - 32. (Mathematical Reviews)

Bărbulescu A., Simian D., 2013, Theoretical and practical approaches for time series prediction, *Proceedings of the Third International Conference on Modelling and Development of*

Intelligent Systems, October 10 – 12, 2013, Sibiu, Romania, pp. 40 – 48. (submis pentru indexare ZentralBlatt)

O altă parte din rezultate este prezentată în articolul:

Popescu-Bodorin N., Bărbulescu A., History-based long-term predictability of regional monthly rainfall fuzzy data, *submis la IEEE Tansaction on Fuzzy Systems* (ISI, FI 6,306)

BIBLIOGRAFIE SELECTIVĂ

[BaiPer2003] Bai J., Perron P., 2003, Computation and Analysis of Multiple Structural Change Models, *Journal of Applied Econometrics* **18**, pp. 1 - 22.

[BarLew1994] Barnett V., Lewis T., 1994, *Outliers in Statistical Data*, 3rd ed., John Wiley & Sons.

[BarHar1993] Barry D., Hartigan J.A., 1993, A Bayesian Analysis for Change Point Problems, *Journal of the American Statistical Association*, **35**(3), pp. 309 - 319.

[BasNik1993] Basseville M., Nikiforov I., 1993, *Detection of abrupt changes: theory and application*, Prentice Hall.

[BarBau2009a] Bărbulescu A., Băutu E., 2009, Alternative models in Precipitation Analysis, *Analele Științifice ale Universității Ovidius, Matematică*, **17**(3), pp. 45 - 68.

[BarBau2009b] Bărbulescu A., Băutu E., 2009, Time Series Modeling Using an Adaptive Gene Expression Programming, *International Journal of Mathematical Models and Methods in Applied Sciences*, Issue 2, vol. 3, pp. 85 - 93.

[BarBau2010] Bărbulescu A., Băutu E., 2010, Mathematical models of climate evolution in Dobrudja, *Theoretical and Applied Climatology*, **100**(1-2), pp. 29 - 44.

[BarDeg2011] Bărbulescu A., Deguenon J., 2011, Mathematical models for extreme monthly precipitation, *Ovidius University Annals, Series: Civil Engineering*, vol. **1**, no. 7, pp. 93 - 104.

[BarDeg2012] Bărbulescu A., Deguenon J., 2012, Modeling the annual precipitation evolution in the region of Dobrudja, *International Journal of Mathematical Models and Methods in Applied Sciences*, Issue 5, vol. **6**, pp. 617 - 624.

[BarDeg2014a] Bărbulescu A., Deguenon J., 2014, Change points detection and models for precipitation evolution. Case study, *Romanian Journal of Physics*, **59**(5-6), în curs de apariție.

[BarDeg2014b] Bărbulescu A., Deguenon J., 2014, Models for trend of precipitation in Dobrudja, *Environmental Engineering and Management Journal*, **13**(4), 2014, pp. 873-880.

[BaMaBa2010] Bărbulescu A., Maftai C., Băutu E., 2010, *Modeling the hydro-meteorological time series. Applications to Dobrudja region*, Lambert Academic Publishing, Germany.

[BarPet2013] Bărbulescu A., Petac A.- O., 2013, Statistical assesment of precipitation evolution. Case Study, *Automation, Computers, Applied Mathematics*, **22**(1), pp. 23 - 32.

[BaTeDe2011] A. Bărbulescu, D. Teodorescu, J. Deguenon, Study on Water Resources in the Romanian Black Sea Region. In Ryann A.M., Perkins N.J. (eds.), *The Black Sea: Dynamics, Ecology and Conservation*, Nova Publishers, USA, 2011, pp 175 -205.

[BarSim2013] Bărbulescu A., Simian D., 2013, Theoretical and practical approaches for time series prediction, Proceedings of the Third International Conference on Modelling and Development of Intelligent Systems, October 10 - 12, 2013, Sibiu, Romania, pp. 40 - 48.

[BauBar2013] Băutu E., Bărbulescu A., 2013, Forecasting meteorological time series using soft computing methods: an empirical study, *Applied Mathematics and Information Science*, **7**(4), pp. 1297 - 1306.

[BoJeRE2008] Box G.P.E., Jenkins G.M., Reinsel G.C., 2008, *Time series analysis: Forecasting and control*, 4th ed., Wiley.

[BrKhLe2007] Brissette F.P., Khalili M., Leconte R., 2007, Efficient stochastic generation of multi-site synthetic precipitation data, *Journal of Hydrology*, **345**, pp. 121 - 133.

[ChiDel1999] Chiles J.P., Delfiner P., 1999, *Geostatistics, modeling spatial uncertainty*, Wiley, New York.

[Chu1992] Chui C.K., 1992, *An Introduction to Wavelets*, Academic Press, Inc., San Diego.

[Cle1979] Cleveland W. S., 1979, Robust Locally Weighted Regression and Smoothing Scatterplots, *Journal of the American Statistical Association*, **74**, pp. 829 - 836.

- [CleDev1988] Cleveland W.S., Devlin S.J., 1988, Locally weighted regression: an approach to regression analysis by local fitting, *Journal of the American Statistical Association*, **83**(403), pp. 596 - 610.
- [Fer2006] Ferreira C., 2006, *Gene Expression Programming: Mathematical Modeling by an Artificial Intelligence*, Springer - Verlag.
- [Foetal2005] Fowler H.J., Kilsby C.G., O'Connell P.E., Burton A., 2005, A weather-type conditioned multi-site stochastic rainfall model for the generation of scenarios of climatic variability and change, *Journal of Hydrology*, **308**, pp. 50 - 66.
- [FrThSK2007] Frost A. J., Thyer M. A., Srikanthan R., Kuczera G., 2007, A general Bayesian framework for calibrating and evaluating stochastic models of annual multi-site hydrological data, *Journal of Hydrology*, **340**, pp. 129 - 148.
- [Haw1980] Hawkins D., 1980, *Identification of Outliers*, Chapman and Hall.
- [IsaSri2007] Isaaks E.H., Srivastava R.M., 2007, *Applied geostatistics*, Oxford University Press.
- [Kou2000] Koutsoyiannis D. , 2000, A generalized mathematical framework for stochastic simulation and forecast of hydrologic time series, *Water Resources Research*, **36**(6), pp. 1519 - 1533.
- [KouMan1996] Koutsoyiannis D., Manetas A., 1996, Simple disaggregation by accurate adjusting procedures, *Water Resources Research*, **32**, 2105 - 2117.
- [KouOno2001] Koutsoyiannis D., Onof C., 2001, Rainfall disaggregation using adjusting procedures on a Poisson cluster model, *Journal of Hydrology*, **246**, pp. 109 - 122.
- [Laf1972] Lafitte P., 1972, *Traité d'informatique géologique*, Masson & Cie.
- [LuoWoo2006] Luo L., Wood E.F. , 2006, Assessing the idealized predictability of precipitation and temperature in the NCEP Climate Forecast System, *Geophysical Research Letters*, **33**, L04708, doi:10.1029/2005GL025292
- [MahPer1996] Maheepala S., Perera C.J.C., 1996, Monthly hydrologic data generation by disaggregation, *Journal of Hydrology*, **178**, pp. 277 - 291.
- [Mat1967] Matalas N. C., 1967, Mathematical assessment of synthetic hydrology, *Water Resources Research*, **4**(3), pp. 937 - 945.
- [PorPin1991] Porter J.W., Pink B.J., 1991, A method of synthetic fragments for disaggregation in stochastic data generation, Hydrology and Water Resources Symposium, Institution of Engineers, Australia, pp. 187 - 191.
- [ShaMeh2010] Sharma A., Mehrotra R., 2010, Rainfall generation, A review. In Testik F.Y., Gebremichael M. (eds.), *Rainfall: State of the Science*, AGU, pp. 215 - 246.
- [SimSto2012] Simian D., Stoica F., A general frame for building optimal multiple SVM kernels, *Large Scale Scientific Computer, Lecture Notes in Computer Science*, **7116**, pp. 256 - 263.
- [SriChi2003] Srikanthan R., Chiew F., 2003, *Stochastic models for generating annual, monthly and daily rainfall and climate data, at a site*, Technical Report **03/16**, Cooperative Research Centre for Catchment Hydrology.
- [SriMcM1985] Srikanthan R., McMahon T., 1985, *Stochastic generation of rainfall and evaporation data*, AWRC Technical Paper No. 84, 301pp.
- [SriMcM2000] Srikanthan R., McMahon T., 2000, *Stochastic generation of climate data: A review*, Technical Report **00/16**, Cooperative Research Centre for Catchment Hydrology.
- [SriMcM2001] Srikanthan R., McMahon T., 2001, Stochastic generation of annual, monthly and daily climate data: A review, *Hydrology and Earth System Sciences*, **5**(4), pp. 653 - 670.
- [SrKuTM2002] Srikanthan R., Kuczera G., Thyer M., McMahon T., 2002, *Stochastic generation of annual rainfall data*, Technical Report **02/6**, Cooperative Research Centre for Catchment Hydrology.
- [Sretal2002] Srikanthan R., McMahon T.A., Pegram G.G.S., Kuczera G.A., Thyer M.A., 2002, *Generation of Annual Rainfall Data for Australian Stations*, Working Document **02/3**, Cooperative Research Centre for Catchment Hydrology.
- [SrMcSh2002] Srikanthan R., McMahon T. A., Sharma A., 2002, *Stochastic generation of monthly rainfall data*, Technical Report **02/8**, Cooperative Research Centre for Catchment Hydrology.
- [SriSri2005] Srinivas V.V., Srinivasan K., 2005, Hybrid moving block bootstrap for stochastic simulation of multi-site multi-season streamflows, *Journal of Hydrology*, **302**, pp. 307 - 330.
- [Srisri2006] Srinivas V.V., Srinivasan K., 2006, Hybrid matched-block bootstrap for stochastic simulation of multiseason streamflows, *Journal of Hydrology*, **329**, pp. 1 - 15.

[SzeRiz2013] Szekely G.J. , Rizzo M.L., 2013, The distance correlation t-test of independence in high dimension, *Journal of Multivariate Analysis*, **117**, pp. 193 - 213.

[SzRiBa2007] Szekely G.J. , Rizzo M.L., Bakirov N.K. , 2007, Measuring and testing dependence by correlation of distances, *The Annals of Statistics*, **35**(6), pp. 2769 - 2794.

[ThoFie1962] Thomas H.A., Fiering M.B., 1962, Mathematical synthesis of streamflow sequences for the analysis of river basins by simulation. In: Maass A. et al. (ed), *Design of water resource systems*, McMillan, London, pp. 459 - 493.

[ThyKuc2000] Thyer M., Kuczera G., 2000, Modeling long-term persistence in hydroclimatic time series using a hidden state Markov Model, *Water Resources Research*, **36**(11), pp. 3301 - 3311.