

Contract CEEEX-ET nr. 5877 / 18.09.2006, cod 196

**PREDICTIBILITATE ȘI INCERTITUDINE ÎN SISTEMUL CLIMATIC ÎN
CONTEXTUL MODIFICĂRILOR CLIMATICE GLOBALE.
O ABORDARE GEOMATICĂ**

Director proiect: CS III dr. Patriche Cristian-Valeriu

- raport final -

CUPRINS

1. Introducere	2
2. Contextul internațional și național al cercetărilor. Justificarea temei propuse.....	2
3. Analiza programelor SIG și statistice utilizabile în scopul modelării spatio-temporale a variabilelor meteo-climatice	4
3.1. Analiza comparativă a posibilităților de modelare spațială a diferitelor programe SIG și de utilizare a programelor statistice	4
3.2. Interoperabilitatea diferitelor softuri SIG	5
4. Derivarea predictorilor potențiali și analiza reprezentativității spațiale a rețelei meteorologice	6
4.1. Derivarea predictorilor potențiali	6
4.2. Analiza reprezentativității spațiale a stațiilor meteorologice / posturilor pluviometrice în raport cu predictorii potențiali	9
5. Derivarea metodelor optime de spațializare în funcție de natura elementului meteo-climatic, scara de spațiu și timp	11
5.1 Testarea comparativă a mai multor metode de spațializare (statistice, conceptuale, matematice) cu alegerea metodei optime în raport cu natura elementului meteo-climatic	11
5.2 Analiza influenței scării de spațiu și timp în alegerea metodei optime de spațializare	16
6. Incertitudine în modelarea spațială a variabilelor meteo-climatice	25
7. Modelarea evoluției temporale a parametrilor meteo-climatici	29
7.1. Apecte metodologice	29
7.2. Medii, abateri și tendințe liniare	32
7.3. Analiza cauzalității în evoluția parametrilor meteo-climatici	36
7.4. Evoluția probabilă a climei în contextul modificărilor climatice globale ...	43
Bibliografie	46

1. Introducere

Proiectul propune o analiză multidimensională complexă a sistemului climatic în scopul cuantificării predictibilității spațio-temporale a parametrilor meteo-climatici și a incertitudinii introduse de modelele utilizate. Aplicatiile vizează estul României, suprapunându-se în cea mai mare parte pe zona Podișului Moldovei și a Subcarpaților Moldovei. Analiza spațială a urmărit relevarea și cuantificarea rolului factorilor climatogenetici regionali și locali în explicarea distribuției spațiale a parametrilor climatici, la diferite scări de spațiu și timp, prin aplicarea comparativă a unei game variate de metode statistice, matematice, conceptuale. O atenție specială s-a acordat etapei de validare a modelelor, în scopul stabilirii metodelor optime de spațializare, precum și etapei de evaluare a incertitudinii derivate din presupunerile specifice metodelor utilizate și din erorile rezultate. Analiza temporală a urmărit identificarea tendințelor de evoluție ale parametrilor climatici, prezența componentelor cvasi-ciclice și legarea cauzală a acestora de factorii potențial explicativi (efectul de seră, erupții vulcanice, ciclicitatea activității solare etc.), precum și cuantificarea incertitudinii modelelor prin analiza reziduurilor. Seriile cronologice ajustate au fost extrapolate în scopul efectuării de progoze privind evoluția probabilă a parametrilor meteo-climatici în contextul modificărilor climatice globale.

2. Contextul internațional și național al cercetărilor. Justificarea temei propuse

În condițiile reducerii, din motive practice, a numărului de stații meteorologice și posturi pluviometrice din România, punerea la punct a unor metodologii de estimare a valorilor parametrilor meteo-climatici în zone lipsite de măsurători devine tot mai importantă.

Metodele de spațializare citate mai frecvent în literatura de specialitate, de tipul IDW, kriging ordinar, chiar cokriging, sunt adesea prea simpliste și generale. Acestea pot fi suficiente pentru analize climatice și agroclimatice la scară mică, dar sunt inutilizabile în studii de detaliu, cu caracter topoclimatic. Un exemplu elocvent în acest sens îl constituie compararea unei distribuții spațiale a temperaturii radiative obținute pe baza imaginilor satelitare în infraroșu termic, cu o spațializare simplă a temperaturii, obținută prin aplicarea gradientului termic vertical, cokriging sau chiar printr-o metodă mai complexă de tipul krigingului rezidual cu model de regresie funcție de altitudine. Diferențele dintre cele acestea sunt foarte importante, datorită faptului că, la nivel local, distribuția spațială a parametrilor meteo-climatici este mult mai complicată ca urmare a interferenței unor factori locali (panta și expoziția versanților, albedoul suprafeței active, energia reliefului etc.).

Proiectul de cercetare abordează aceasta problemă prin testarea performanțelor mai multor metode de spațializare, statistice, matematice și conceptuale, aplicate în cadrul SIG. O atenție specială se acordă validării modelelor spațiale obținute, cuantificării erorilor și analizei propagării acestora în cazul derivării unor variabile meteo-climatice complexe. În paralel, se analizează și aplicabilitatea diferitelor pachete soft de SIG și statistică, relevându-se avantajele și dezavantajele utilizării acestora.

Modelarea spațială a parametrilor meteo-climatici constituie încă o problemă delicată în climatologia contemporană, fiind obiectul de studiu a numeroase proiecte de cercetare pe plan internațional, finalizate sau în derulare (COST719, COST718, Voltaire, MAP, NORDKLIM, NORDGRID, ENSEMBLES, Alpine Tmap etc.). Progrese deosebite s-au

realizat odată cu dezvoltarea (dar și ieftinirea) tehnicii de calcul, prin integrarea modulelor de statistică în pachete de SIG. Implementarea SIG și a metodelor cantitative de modelare spațială în cadrul serviciilor naționale de meteorologie, care sunt primele interesate de aplicarea acestora, s-a realizat diferit pe plan european. State precum Norvegia, Finlanda, Austria utilizează deja metode complexe de tipul krigingului rezidual, iar în Franța și Ungaria metoda Aurelhy este operațională. Interpolarile deterministe de tipul spline sunt încă folosite în Portugalia, Grecia sau Olanda.

Un aspect deficitar general valabil îl constituie faptul că majoritatea aplicațiilor sunt derulate la rezoluții mici, în general de 1x1 km sau mai grosiere. Acestea pot fi adecvate, spre exemplu, pentru precipitațiile atmosferice, însă sunt insuficiente pentru elemente precum temperatura sau radiația solară, care variază considerabil în funcție de caracteristicile locale ale topografiei.

Analiza critică a stadiului actual al cunoașterii în domeniu, relevă o serie de aspecte care necesită în continuare a fi aprofundate: problema spațializării parametrilor meteo-climatici condiționați în principal de factorul dinamic (ex: precipitațiile); problema scăderii semnificative a gradului de predictibilitate spațială odată cu creșterea complexității terenului (regiuni muntoase, zone restrânse) și cu trecerea de la valori mediate (ex: medii anuale, lunare) la valori cvasi-momentane (ex: diurne); problema integrării situațiilor sinoptice și/sau tipurilor de circulație atmosferică în modelele statistice; problema cuantificării incertitudinilor derivate din presupunerile diferitelor modele de spațializare; problema propagării erorilor în variabilele meteo-climatice derivate (ex: evapotranspirația); problema reprezentativității spațiale a rețelei de stații meteorologice / posturi pluviometrice în raport cu variabilele meteo-climatice și cu factorii potențiali explicativi ai acestora; problema adecvării și interoperabilității programelor actuale de SIG care pot fi utilizate pentru analiza spațială a parametrilor meteo-climatici etc.

Cea de-a doua parte a proiectului este dedicată modelării temporale a parametrilor meteo-climatici. În contextul schimbărilor climatice globale, elaborarea unor scenarii realiste privind evoluția probabilă a parametrilor meteo-climatici și a climei în general constituie o prioritate pe plan mondial.

Cercetările efectuate până în prezent sunt focalizate pe elaborarea și aprofundarea unor modele climatice globale care să cupleze interacțiunile complexe atmosferă-ocean-uscat, aducerea acestora la scară regională și locală, monitorizarea și analiza evoluției seriilor cronologice reprezentând parametri meteo-climatici și factorii de control. Finalitatea acestor studii este aceea de a cuantifica sensibilitatea climatului în raport cu perturbațiile induse de activitățile antropice, pentru a putea astfel acționa eficient în direcția limitării efectelor negative asupra societății umane.

În România, studiile privind evoluția parametrilor meteo-climatici vizează ajustarea unor tendințe liniare de evoluție sau calcularea mediilor mobile pentru minimizarea zgomotului și evidențierea unor eventuale tendințe și ciclicități (*Ciulache S., Cismaru C., 2000, Cismaru C. et al., Dragotă Carmen, 2001, Dragotă Carmen, Măhăra Gh., Drăgănescu Adriana, 2002* etc.). Cercetări mai complexe vizează utilizarea modelelor autoregresive tip ARIMA, identificarea statistică a tranzițiilor climatice în seriile cronologice (*Haidu I., 2004*), analiza simultană a evoluției parametrilor meteo-climatici de la stațiile din România pe baza unor tipuri speciale de reprezentări grafice (*Cheval S., Baciu M., Breza T., 2003*), simularea impactului schimbărilor climatice globale asupra

elementelor bilanțului hidric în sudul României (*Marica Adriana, Busuioc Aristita, 2004, raport în cadrul proiectului COST718*).

În cadrul proiectului nostru, n-am propus identificarea și separarea tendințelor de evoluție, a componentelor cvasi-ciclice și a reziduurilor din seriile cronologice, în vederea relevării și cuantificării modului în care schimbările climatice globale se resimt în teritoriul studiat. Componentele filtrate au fost corelate cu factorii potențiali explicativi (ciclicitatea activității solare, a oscilației El-Niño, evoluția bioxidului de carbon atmosferic, erupții vulcanice etc) pentru a evidenția rolul fiecărui factor în evoluția parametrilor meteo-climatici. Seriile cronologice ajustate au fost extrapolate pe termen mediu în scopul efectuării de prognoze privind evoluția probabila a climei teritoriului studiat în contextul schimbărilor climatice globale.

3. Analiza programelor SIG și statistice utilizabile în scopul modelării spatio-temporale a variabilelor meteo-climatice

Existența unui număr apreciabil de programe SIG și statistice care pot fi utilizate în scopul modelării spatio-temporale a variabilelor meteo-climatice, pe de o parte, precum și constatarea că o modelare spațială complexă nu poate fi realizată cu ajutorul unui singur program, justifică efectuarea unei analize comparative privind caracteristicile modulelor de spațializare specifice fiecărui program și posibilitățile de transfer a informației dintr-un program în altul.

3.1. Analiza comparativă a posibilităților de modelare spațială a diferitelor programe SIG și de utilizare a programelor statistice

Programele de SIG supuse analizei sunt: TNTmips, ArcGIS, IDRISI, Surfer, SAGA-GIS, NewLocClim.

Modulele de regresie prezente în TNTmips, ArcGIS. SAGA-GIS nu sunt adecvate pentru elaborarea modelelor spațiale privind variabilele meteo-climatice deoarece nu permit integrarea progresivă a variabilelor explicative, esențială pentru minimizarea coliniarității predictorilor și nu generează suficienți parametri statistici necesari pentru validarea modelelor elaborate. Prin urmare, *pentru realizarea regresiei se impune utilizarea unui soft statistic specializat.*

Analizând comparativ posibilitățile de regresie oferite de Excel prin modulul XLSTAT și Statistica, constatăm că cel de-al doilea este superior, permițând, spre deosebire de primul, vizualizarea progresivă a fiecărui pas din cadrul regresiei multiple progresive, selectarea indivizilor (ex: stațiilor meteorologice), efectuarea validării încrucișate, identificarea outliers. În privința regresiei neliniare, XLSTAT este superior prin nelimitarea numărului de predictorii, în timp ce programul Statistica permite integrarea doar a maxim 4 predictorii în ecuații neliniare. În plus, modulul de tendință din Excel permite vizualizarea rapidă a relațiilor optime dintre predictor și variabila dependentă. Totuși, XLSTAT nu permite, spre deosebire de Statistica, vizualizarea progresivă a integrării predictorilor în ecuațiile de regresie neliniare. În privința analizei componentelor principali, programul Statistica este de asemenea superior, permițând rotația axelor componentelor și efectuarea analizei factoriale. În privința analizei seriilor de timp, Statistica prezintă un modul de analiză spectrală care permite identificarea ciclicităților în șirurile de date, fără însă a genera șiruri ajustate conform ciclurilor, în timp ce Excel/XLSTAT permite doar ajustarea unor tendințe liniare sau neliniare.

Prin urmare, programul Statistica este net superior pentru analize specializate, de tipul regresiei, însă Excel/XLSTAT este mult mai flexibil la crearea formulelor, având un număr foarte mare de indici statistici predefiniți.

La toate softurile SIG analizate sunt prezente *module de kriging*, mai simple sau mai complexe. Evaluarea comparativă a performanțelor acestora trebuie să țină cont de posibilitatea identificării semivariogramelor teoretice optime, de posibilitatea setării parametrilor kriging, de numărul tipurilor de semivariograme teoretice și de variante de kriging aplicabile, precum și de posibilitatea generării erorilor standard de estimare.

Surfer-ul și IDRISI permit construcția de semivariograme mediate și oferă parametri statistici privind calitatea ajustării acestora cu semivariograme teoretice, fiind, din acest punct de vedere superioare celorlalte programe. Spre deosebire de acestea, SAGA-GIS nu oferă parametri referitori la calitatea ajustării semivariogramelor empirice mediate cu semivariograme teoretice. ArcGIS, TNTmips și NewLocClim nu permit construcția semivariogramelor empirice mediate. ArcGIS are în schimb un modul de validare încrucișată. Acest modul permite selectarea ajustării optime după rularea mai multor operații kriging cu parametri diferiți.

Toate programele SIG analizate se pretează la mai mult de un tip de kriging, cele mai complexe din acest punct de vedere fiind ArcGIS, IDRISI și TNTmips.

Se poate remarca faptul că, pentru construcția semivariogramelor empirice mediate și a ajustarea celor teoretice, este mai indicată folosirea unui soft statistic specializat, de tipul Variowin sau Vesper, în locul unui soft de SIG, cu excepția programelor IDRISI și Surfer, urmând ca parametrii optimi determinați să fie importați în programul SIG pentru realizarea spațializării.

3.2. Interoperabilitatea diferitelor softuri SIG

Interoperabilitatea programelor este deosebit de importantă atunci când o problemă nu poate fi rezolvată cu ajutorul unui singur program, cum este și cazul nostru. Toate programele SIG analizate pot importa fișierele prelucrate cu programe statistice, sub format dbf, csv, text etc. Problemele apar, în general, la transferul informației georeferențiate și în special a celei stocate în format raster. Unele extensii, precum bil, bip, bsq etc. deși prezente în modulele de import-export a mai multor programe, nu sunt utilizabile pentru transferul informației. Chiar și în format ascii, un fișier creat în TNTmips nu poate fi importat, spre exemplu, în SAGA-GIS. În general, pentru fișierele de tip raster, formatul geotiff reușește de cele mai multe ori să transfere informația corect, iar echivalentul pentru straturile de tip vector este formatul shp. Există însă probleme și cu aceste formate. Spre exemplu, prin transferul unui fișier din TNTmips în IDRISI ca geotiff, valorile nule din raster sunt importate ca valori reale, fiind necesară specificarea valorii minime din raster în cadrul IDRISI.

4. Derivarea predictorilor potențiali și analiza reprezentativității spațiale a rețelei meteorologice

4.1. Derivarea predictorilor potențiali

Elaborarea modelelor spațiale strict pe baza informației preluate din rețeaua de stații meteorologice / posturi pluviometrice este insuficientă pentru analize de detaliu, devenind necesară includerea de informație auxiliară pentru rafinarea spațializărilor. Pe

lângă predictorii clasici, de tipul MNT, latitudine, longitudine, au fost derivați o multitudine de alți predictorii, potențial utilizabili în ecuațiile de regresie elaborate cu scopul explicării variabilității spațiale a parametrilor meteo-climatici:

- *Panta terenului.*
- *Iluminarea terenului:* derivată din MNT pentru o anumită înălțime a Soarelui deasupra orizontului. Valorile iluminării terenului sunt proporționale cu componenta directă a radiației globale receptată pe suprafețe cu pante și expoziții diferite, fiind astfel potențial utile în derivarea câmpurilor radiativ-termice.
- *Separarea componentelor Nord-Sud și Vest-Est ale expoziției versanților:*
 - *Componenta Nord-Sud:* cu valori de la 0° (Nord) la 180° (Sud) a fost separată pentru a exprima influența orientărilor N-S asupra variabilelor meteo-climatică, în special asupra celor radiative și termice.
 - *Componenta Vest-Est:* cu valori de la -90° (Vest) la $+90^{\circ}$ (Est) a fost separată pentru a exprima influența orientărilor V-E asupra variabilelor meteo-climatică. Această transformare este utilă în special pentru precipitații, având în vedere dominanța circulației vestice la latitudini temperate, dar poate fi utilă și pentru temperatura aerului care prezintă valori în general mai ridicate pe versanții vestici, comparativ cu cei estici.
- *Integrarea pantei și expoziției versanților la nivelul unui singur predictor este necesară deoarece efectul pantei asupra parametrilor meteo-climatici diferă în funcție de orientarea acesteia. Integrarea s-a realizat în 2 maniere:*
 - *Prin multiplicarea valorilor standardizate ale pantelor (0-100) și componentei de expoziție N-S (0-100) și împărțirea subsecventă la 100, rezultând un factor pantă – orientare N-S cu valori de la 0 la 100. Prin această integrare se acordă o pondere mai mare expozițiilor N-S asociate cu pante mari și mai redusă celor asociate cu pante mici.*
 - *Prin multiplicarea valorilor standardizate ale pantelor (0-100) și componentei de expoziție N-S (V-E) (-50-+50), rezultând un factor pantă-orientare cu valori de la -5000 (N sau V) la +5000 (S sau E). Valorile mari caracterizează expozițiile sudice (sau estice) asociate cu pante mari, iar valorile mici, negative, caracterizează expozițiile nordice (sau vestice) asociate, de asemenea cu pante mari.*
- *Energia locală a reliefului:* a fost calculată ca diferență între altitudinea reliefului (MNT) într-un anumit punct și altitudinea talvegului cel mai apropiat față de punctul respectiv.
- *Ecartul altitudinal în ferestre glisante*

Figura 1. Separarea componentelor de expoziție Nord-Sud și Vest-Est

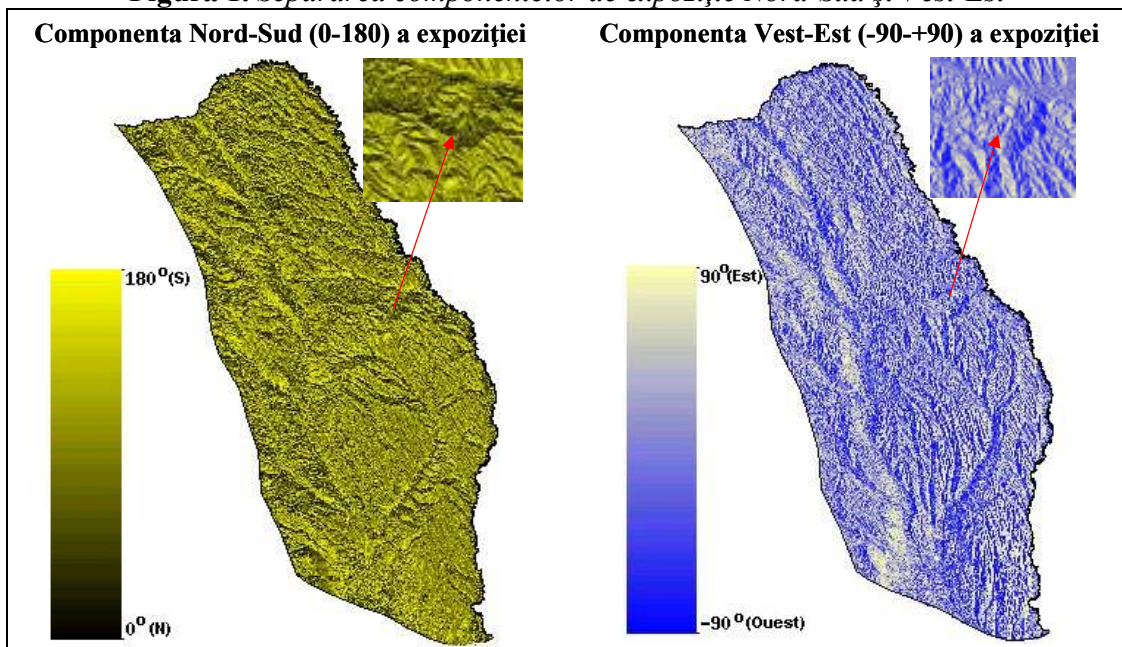


Figura 2. Integrarea pantei și componentei Nord-Sud a expoziției

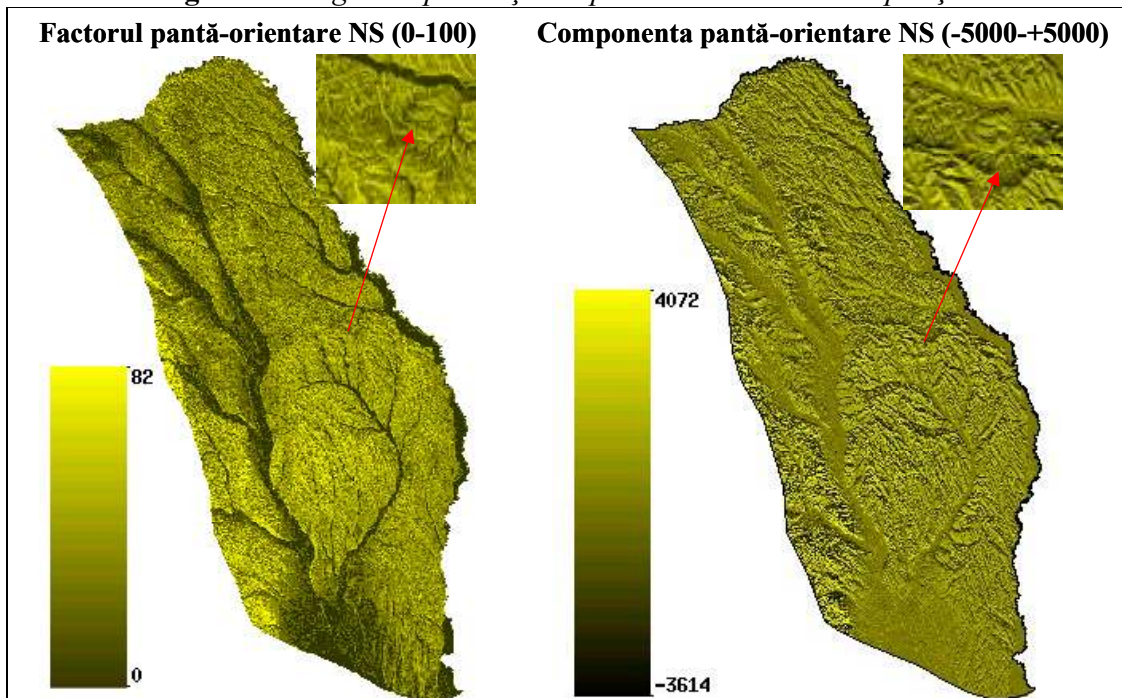


Figura 3. Ecartul altitudinal în ferestre glisante de 9x9 pixeli (810x810m) și energia locală a reliefului

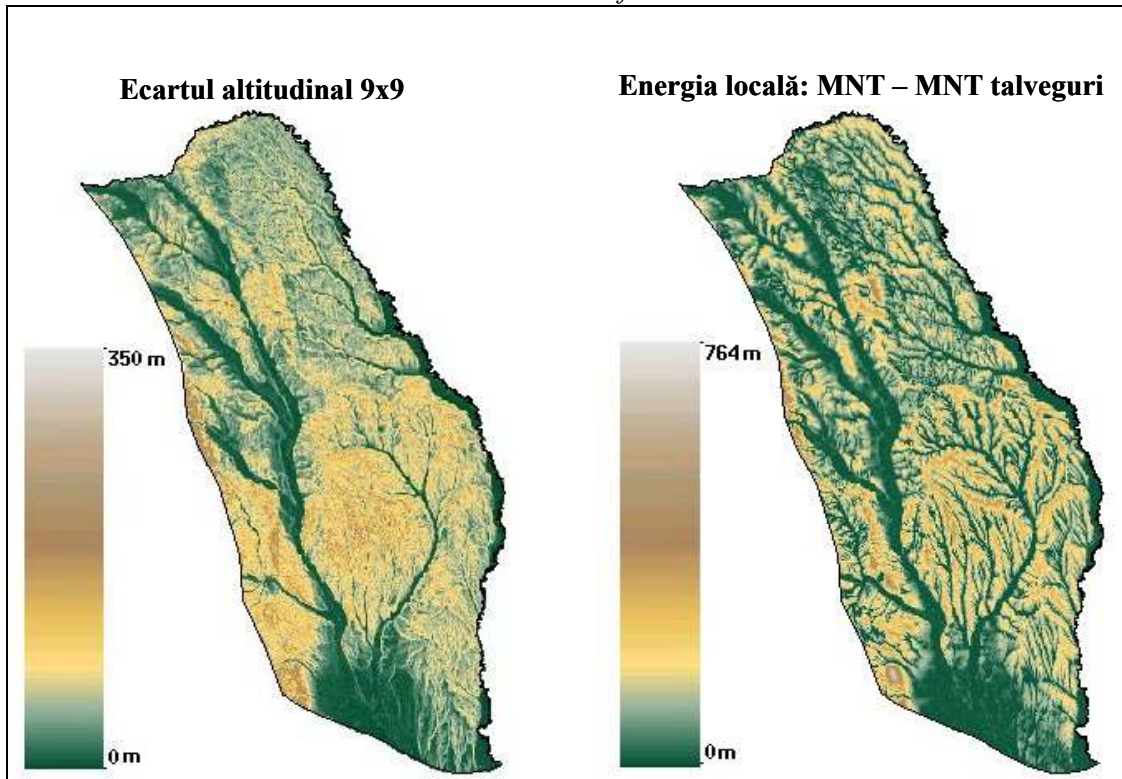
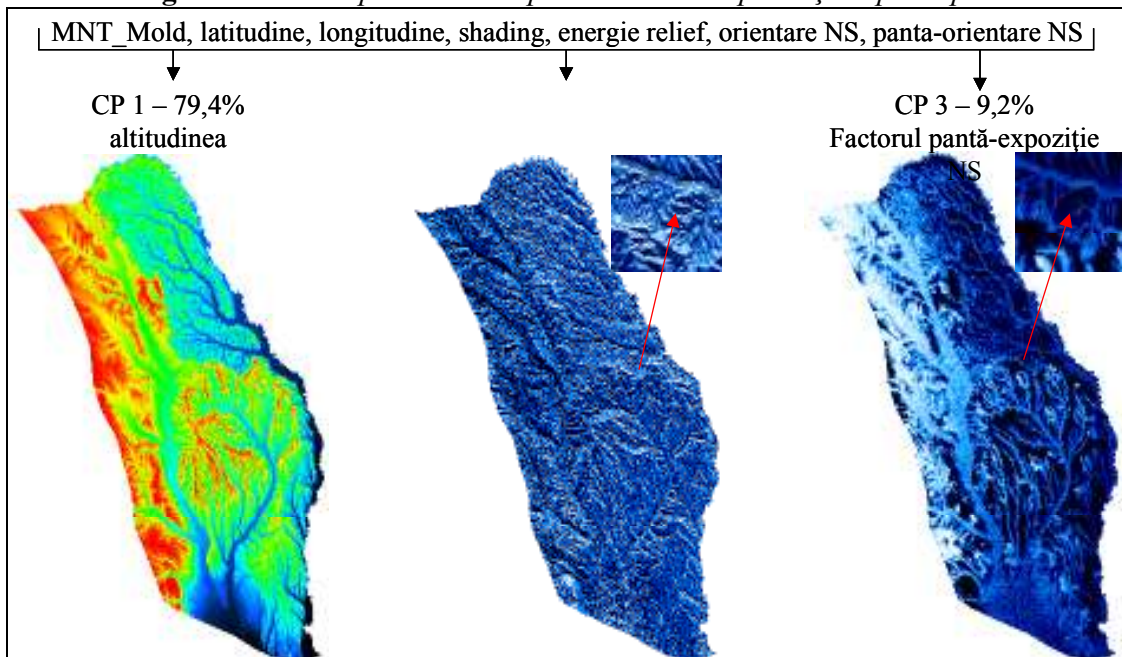


Figura 4. Sinteza predictorilor prin analiza componentelor principale

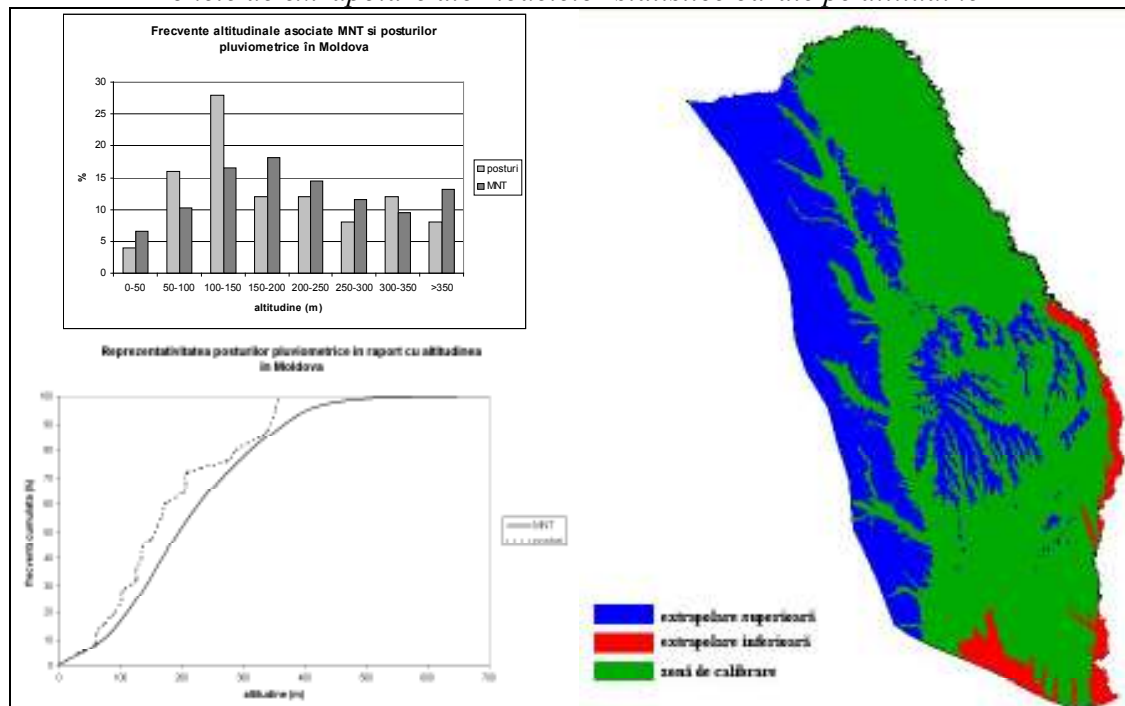


Pe lângă predictorii potențiali menționați, au mai fost derivate altitudinile medii în ferestre glisante de diferite mărimi, curbura suprafeței terenului, utilizarea terenului și albedoul. De asemenea, s-au derivat predictorii sintetici prin condensarea informației privind predictorii bruți la nivelul unor variabile ortogonale, folosind analiza componentelor principali. Această transformare poate fi utilă în analizele de regresie având în vedere reducerea numărului de predictorii și lipsa corelației dintre predictorii sintetici.

4.2. Analiza reprezentativității spațiale a stațiilor meteorologice / posturilor pluviometrice în raport cu predictorii potențiali

Problema reprezentativității spațiale a rețelei de stații meteorologice / posturi pluviometrice este o problemă importantă care necesită a fi analizată într-o etapă preliminară modelării spațiale a variabilelor meteo-climatice, constituind o potențială sursă de erori. Teoretic, rețeaua meteorologică ar trebui să acopere echilibrat un teritoriu, pentru a surprinde toate caracteristicile meteo-climatice ale acestuia.

Figura 5. *Reprezentativitatea altitudinală a posturilor pluviometrice din Moldova și zonele de extrapolare ale modelelor statistice bazate pe altitudine*



Reprezentativitatea rețelei meteorologice în raport cu predictorii potențiali poate fi vizualizată și evaluată prin compararea histogramelor predictorilor cu histogramele aceluiași predictorii obținute însă pe baza valorilor predictorilor asociați stațiilor meteorologice / posturilor pluviometrice. Un exemplu este redat în figura 5 pentru reprezentativitatea altitudinală a rețelei de posturi pluviometrice din Podișul Moldovei. Într-o situație ideală, curbele histogramelor cumulate ale altitudinii derivate de pe MNT și ale altitudinii stațiilor ar trebui să coincidă. Remarcăm însă deficitul de posturi din zona joasă (sub 50m), din intervalul 150-300m și din zona înaltă (peste 350m). Lipsa

posturilor pluviometrice la altitudini joase (sub 50m) și mari (peste 350m) ne forțează să extrapolăm modelele de regresie bazate pe altitudine în aceste regiuni. Extrapolarea poate fi generatoare de erori, fapt ce impune acordarea unei atenții sporite aprecierii verosimilității valorilor estimate din aceste regiuni.

Problema outliers, sau a valorilor ce se abat de la o anumită regula generală, constituie un alt aspect al problemei reprezentativității rețelei meteorologice în raport cu predictorii care trebuie analizată preliminar pentru a minimiza erorile potențiale.

Figura 6 redă variația coeficienților de corelație dintre temperatura medie anuală și altitudine pe măsura includerii progresive de noi stații, includerea pornind de la un fond inițial de 5 stații din Câmpia Moldovei. Se remarcă faptul că includerea stației Cotnari reduce semnificativ corelațiile care, în lipsa acestei stații, s-ar menține la un nivel semnificativ mai ridicat. Această constatare ne poate indica stația Cotnari ca outlier pentru relația temperatură – altitudine, în sensul abaterii acesteia de la regula generală a scăderii temperaturii cu altitudinea. Explicația clasică pentru această situație constă în prezența proceselor de föhnizare pe versanții estici ai Dealului Mare-Hârlău care generează o anomalie termică dar și pluviometrică în această regiune.

O altă modalitate de identificare a outliers constă în compararea reziduurilor regresiei obținute pe baza tuturor stațiilor cu reziduurile recalulate prin eliminarea succesivă a fiecărei stații (*validare încrucișată*). În figura 7 este redat un astfel de exemplu pentru precipitațiile medii din ciclul de vegetație al porumbului în Podișul Moldovei. Dacă modelul de regresie precipitații – altitudine este stabil atunci valorile celor două categorii de reziduuri trebuie să fie asemănătoare. Remarcăm însă o diferență semnificativă în cazul stației Cotnari, precum și situarea valorilor reziduurilor în afara intervalului de $\pm 2,5$ deviații standard, fapt ce justifică statistic constatarea că valorile asociate acestei stații se abat de la regula generală a creșterii precipitațiilor cu altitudinea. În plus, se remarcă faptul că eliminarea stației Cotnari din analiză determină creșterea gradului de explicare a regresiei cu 12% și reducerea erorii medii pătratice (RMSE) de la 27,4mm la 22,2mm.

Figura 6. Variația coeficienților de corelație dintre temperatura medie anuală și altitudine pe măsura includerii progresive de noi stații

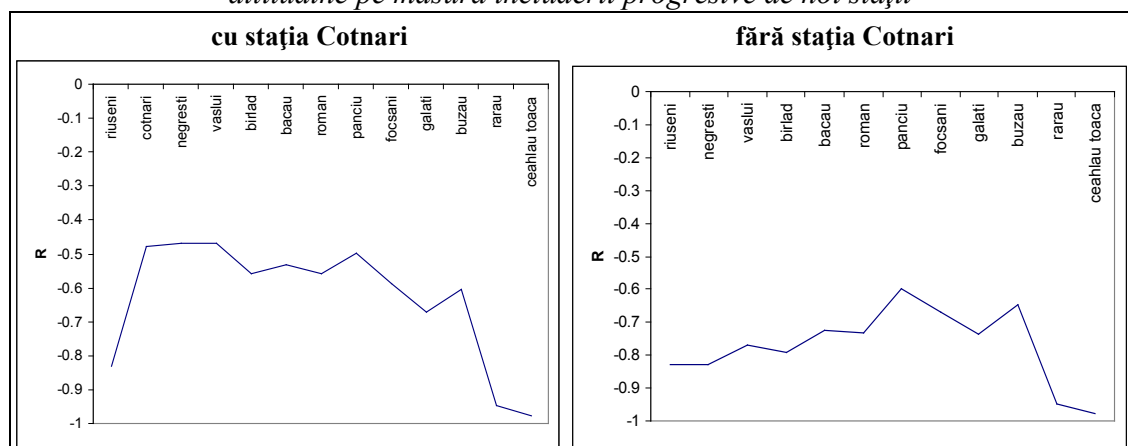
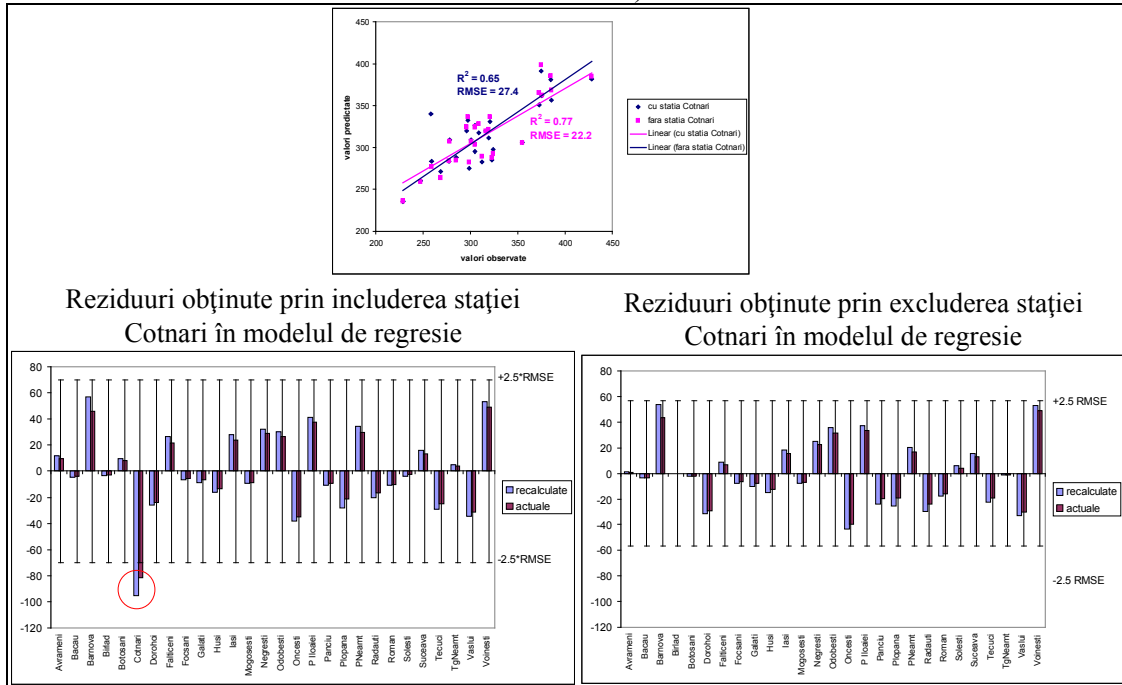


Figura 7. Identificarea outliers prin compararea reziduurilor actuale cu cele recalulate în lipsa stației (exemplu pentru precipitațiile medii din ciclul de vegetație al porumbului în Moldova)



Deși nu este cazul de față, valorile asociate punctelor de tip outliers pot fi valori eronate. Prin urmare, procedurile de identificare a outliers constituie, în același timp, proceduri de identificare a unor eventuale erori în șirurile de date. Cum trebuie procedat în momentul identificării unui outlier? Se impune eliminarea valorii respective din analiză? Dacă spațializarea se bazează doar pe regresie în funcție de predictorul față de care o anumită valoare este outlier, atunci aceasta trebuie eliminată din analiză deoarece ea modifică semnificativ și nerealist relația spațială analizată. Însă, prin această eliminare, trebuie să se aibă în vedere că valorile din zona punctului de tip outlier sunt eronate. Prin urmare, această eliminare nu este soluția optimă a problemei. Două alte soluții sunt posibile în această situație: identificarea unui nou predictor care să explice anomalia spațială din zona punctului de tip outlier (spre exemplu, componenta V-E a orientării versanților pentru cazul stației Cotnari); spațializarea parametrului climatic prin kriging rezidual, metodă care adună reziduurile regresiei, spațializate prin kriging ordinar, la tendința spațială cuantificată pe baza regresiei.

5. Derivarea metodelor optime de spațializare în funcție de natura elementului meteo-climatic, scara de spațiu și timp

5.1 Testarea comparativă a mai multor metode de spațializare (statistice, conceptuale, matematice) cu alegerea metodei optime în raport cu natura elementului meteo-climatic

Scopul spațializării îl constituie transformarea unei reprezentări spațiale discrete a unei variabile într-o reprezentare spațială continuă.

Există o gamă destul de largă de metode de spațializare care pot fi utilizate în scopul modelării informației climatice, diferite prin concepție și complexitate, acestea putând fi grupate după criteriile variate (tabelul 1).

Tabelul 1. Clasificarea metodelor de interpolare

Criterii	Grupe de metode	Exemple de metode
Posibilitatea estimării erorilor introduse de procesul interpolării	<i>Deterministe</i> Nu permit estimarea erorilor	media mobilă ponderată (IDW), spline, poligoane Thiessen-Voronoi, metoda rețelei neregulate de triunghiuri (TIN)
	<i>Stocastice</i> Permit estimarea erorilor	regresie, analiza suprafeței de tendință (TSA), kriging
Extinderea spațială a valorilor pe baza cărora se realizează interpolarea	<i>Globale</i> Utilizează toate datele disponibile din regiunea de interes	regresie, TSA
	<i>Locale</i> Utilizează doar valorile din vecinătatea punctului de interpolat	IDW, spline, poligoane Thiessen-Voronoi, TIN, kriging
Păstrarea/modificarea valorilor în punctele cunoscute	<i>Interpolatori aproximativi</i> Modifică valorile în punctele cunoscute	regresie, TSA
	<i>Interpolatori exacti</i> Păstrează valorile în punctele cunoscute	IDW, spline, poligoane Thiessen-Voronoi, TIN, kriging
Caracterul continuu/discontinuu al reprezentării spațiale rezultate	<i>Interpolatori discreți</i> Output discret (discontinuu)	poligoane Thiessen-Voronoi
	<i>Interpolatori continui</i> Output continuu	regresie, TSA, IDW, spline, TIN, kriging

O abordare recentă în interpolarea climatologică o constituie aplicarea diferențiată a metodelor de interpolare în funcție de tipul situației sinoptice sau de tipul circulației atmosferice, ținându-se cont, în acest fel, de rolul factorului dinamic. Un exemplu în acest sens ne oferă *Tveito O. E.* (2002) pentru temperaturile medii zilnice din sudul Norvegiei.

Metodele deterministe de interpolare, deși sunt mai simple și mai ușor de aplicat, prezintă dezavantajul principal de a nu oferi informații privind erorile introduse în procesul interpolării. Prin urmare, utilizarea acestora în scopul spațializării parametrilor climatici nu este adecvată, deși unele dintre ele sunt destul de frecvent folosite (media mobilă ponderată).

O categorie aparte de metode deterministe sunt cele *conceptuale* (ex: relația Angström pentru estimarea radiației globale, metoda Penmann-Monteith pentru estimarea evapotranspirației potențiale etc). Acestea reprezintă expresiile matematice ale interrelațiilor dintre factorii de control și variabilele meteo-climatice, determinate, de regula,

prin studii experimentale. Aplicarea în cadrul SIG a unui model conceptual este însă rareori deterministă, deoarece variabilele de intrare sunt, în general, spațializate anterior printr-un model statistic, caracterizat printr-un anumit grad de incertitudine. Esențială în aplicarea unui model conceptual este, prin urmare, urmărirea modului de propagare a erorilor până la nivelul variabilei de ieșire.

Alegerea metodei optime de interpolare trebuie să țină cont de o serie de criterii:

- natura variabilei:
 - caracter spațial continuu (dependență principală radiativă): regresie, spline, TSA;
 - caracter spațial discontinuu (dependență principală dinamică): kriging, kriging rezidual, Aurelhy, PRISM.
- scara de timp:
 - valori cvasi-momentane (zilnice, lunare): kriging, kriging rezidual, PRISM;
 - valori medii multianuale (lunare, anuale): regresie, spline, kriging rezidual, Aurelhy.
- scara de spațiu (complexitatea terenului):
 - locală (analiză topoclimatică, topo-agroclimatică): kriging rezidual, Aurelhy, PRISM;
 - regională: regresie, spline, IDW.
- acuratețea dorită (necesitatea estimării erorilor):
 - redusă: IDW, spline;
 - ridicată: regresie, kriging rezidual, Aurelhy, PRISM.
- necesitatea explicării distribuției spațiale:
 - nu (interesează doar elementul de interpolat): kriging, IDW, spline;
 - da (interesează atât elementul interpolat cât și factorii de control): regresie, kriging rezidual, Aurelhy, PRISM.

Spațializarea **radiației solare globale** presupune cuplarea a 2 categorii de modele: unul pentru spațializarea pe suprafață orizontală, altul pentru spațializarea pe suprafețe cu diferite înclinări și expoziții. Modelele din cea de-a 2-a categorie, unele implementate și în cadrul SIG, sunt în general modele matematice precise, pentru care erorile sunt minime sau chiar absente, acestea fiind mai adesea generate nu de modelul în sine ci de rezoluția la care se lucrează. Modelele din prima categorie sunt mult mai mult supuse incertitudinii, erorile putând rezulta, spre exemplu, din alegerea coeficienților care redau raportul radiație directă / radiație difuză în cadrul formulei Angström, din modul de spațializare a duratei efective de strălucire a Soarelui etc.

Alegerea metodei optime de spațializare a radiației globale trebuie să se bazeze pe compararea valorilor estimate cu valorile reale măsurate la anumite stații meteorologice. În cazul prezentat în figura 8, valorile medii lunare ale radiației globale pe suprafață orizontală estimate prin 3 modele diferite au fost comparate cu valorile reale măsurate la stația meteorologică Iași, rezultând metoda Angström ca fiind optimă pentru această regiune. Aceasta, cuplată cu un model precis de variație funcție de panta și expoziția versanților, cum este modelul *ray-tracing* incorporat în softul SAGA-GIS, poate constitui metoda optimă de spațializare a radiației globale în estul României.

Figura 8. Exemplu de aplicare a 2 metode conceptuale diferite pentru spațializarea radiației globale medii anuale pentru un decupaj din Podișul Central Moldovenesc

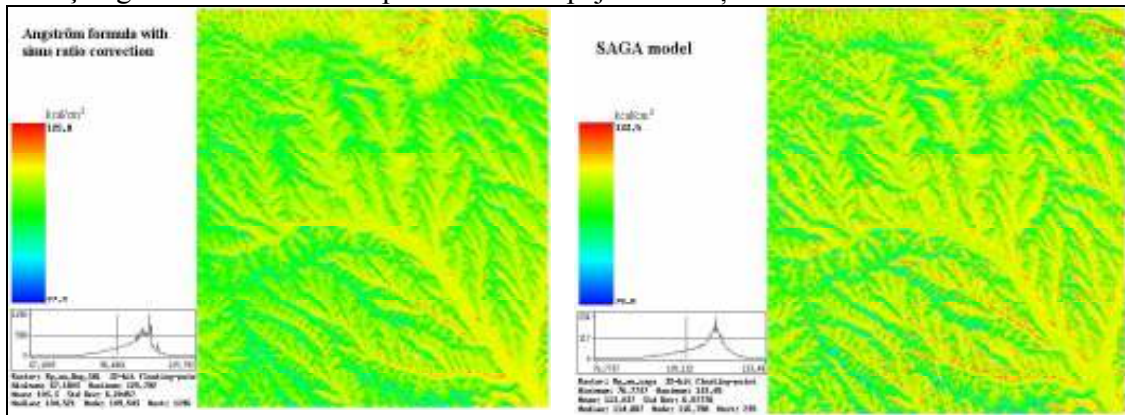
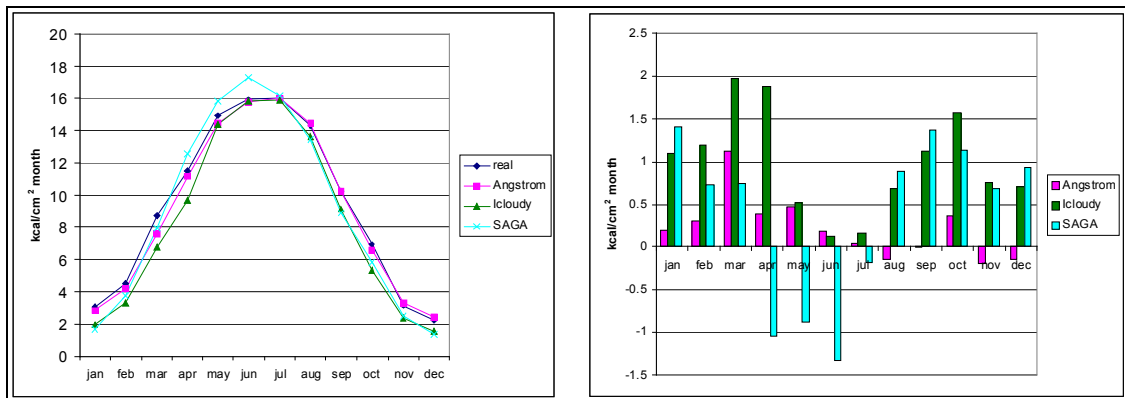


Figura 9. Comparație între valorile reale și cele estimate, prin diferite metode, ale radiației globale pe suprafață orizontală pentru stația meteorologică Iași: regimul mediu anual real și estimat (stânga); diferențe între valorile reale și estimate (dreapta)



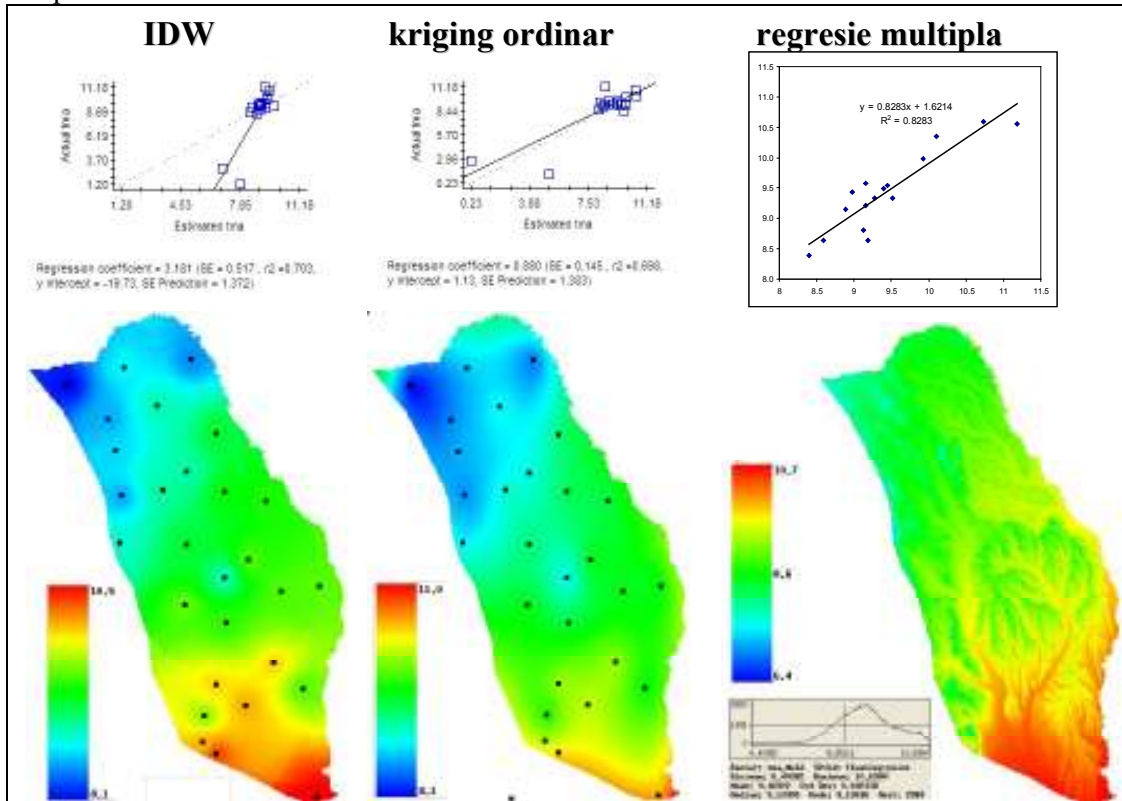
Pentru **cei alți parametri meteo-climatici**, metodele statistice de spațializare sunt, în general, cele mai adecvate. Ne referim aici la regresia și kriging, cu numeroasele lor variante de aplicare, precum și la analiza componentilor principali, ca o etapă preliminară de transformare a datelor brute în scopul reducerii redundanței și/sau obținerii de predictorii sintetici necorelați.

Figura 10 redă un exemplu de spațializare a temperaturii medii anuale în estul României folosind 3 metode diferite: o metodă deterministă (matematică), respectiv metoda mediei mobile ponderate (inversului distanței – IDW), o metodă statistică locală (krigingul ordinar) și o metodă statistică globală (regresia multiplă).

Atât aspectul spațializărilor rezultate, cât și graficele de validare încrucișată, indică metoda regresiei multiple ca fiind optimă. În cazul IDW, dreapta de corelație dintre reziduurile actuale și cele recalculat în lipsa stațiilor este mult deviată de la traseul ideal, datorită incapacității metodei de a reda corect valorile de temperatură la două dintre stațiile analizate. Kringingul ordinar estimează mai bine temperaturile de la stații atunci când acestea sunt excluse succesiv din modelul statistic, însă cel mai bine se comportă

metoda regresiei multiple, care prezintă cea mai bună corelație între cele 2 categorii de reziduuri.

Figura 10. Rezultate obținute prin diferite metode de spațializare – exemplu pentru temperaturile medii anuale



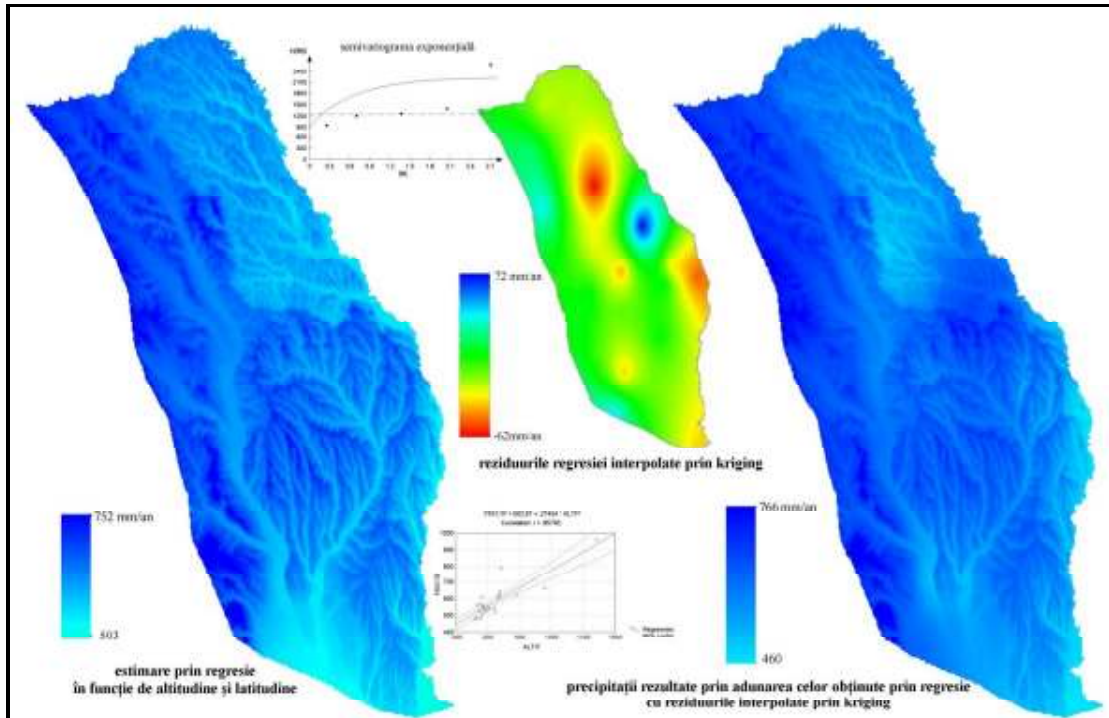
În plus, aspectul spațializărilor pledează net în favoarea regresiei multiple, care ia în considerare și redă influența altitudinii și latitudinii asupra temperaturii aerului.

Pe de altă parte, regresia multiplă fiind un interpolator global, nu este capabilă să redea eventualele anomalii spațiale în distribuția elementului analizat, decât în măsura în care acestea pot fi cuantificate prin predictorii utilizați. În cazul valorilor medii de temperatură, aceste anomalii sunt destul de șterse, dar totuși există. În cazul unui parametru care depinde în mare măsură de factorii dinamici, cum sunt precipitațiile atmosferice, anomaliile spațiale sunt mult mai accentuate, motiv pentru care regresia multiplă devine inadecvată. În exemplul redat în figura 11, se observă că reziduurile regresiei sunt importante, evidențiindu-se clar 2 zone de anomalie principale în care modelul nu este capabil să estimeze corect valorile de precipitații, corespunzătoare ariei de foehnizare din Dealul Mare-Hârlău (cu reziduuri negative) și ariei de potențare orografică a precipitațiilor de pe Coasta Iașilor din Depresiunea subsecventă Bârnova-Voinești (cu reziduuri pozitive).

Soluția în această situație este de a aplica regresia multiplă, într-o primă etapă a spațializării, de a interpola reziduurile regresiei prin kriging ordinar și de a adăuna modelul tendinței spațiale (regresiei) cu modelul reziduurilor pentru a obține spațializarea finală. Acest demers este cunoscut sub denumirea de *kriging rezidual* (sau kriging cu

model de tendință, regresie-kriging) și este considerată *metoda optimă de spațializare a parametrilor climatici*.

Figura 11. Metoda kriging-ului rezidual – exemplu pentru precipitațiile medii anuale din Moldova

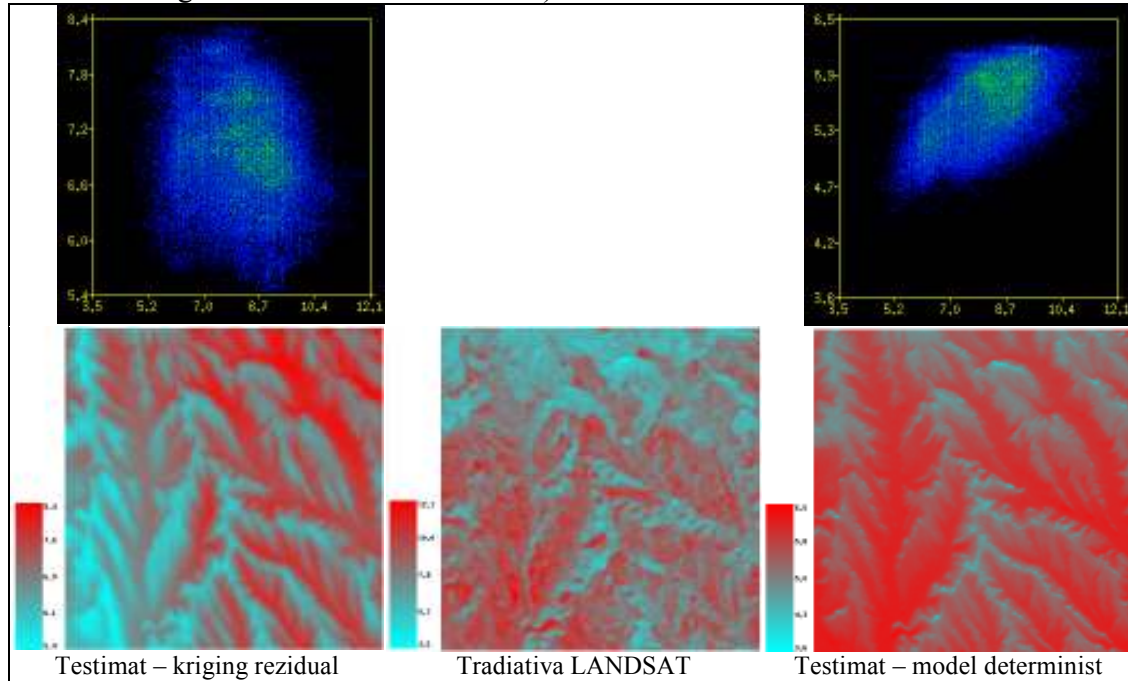


Referindu-ne la predictibilitatea spațială a parametrilor climatici, se poate afirma, în general, că variabilele cu dependență principală radiativă, cum este temperatura aerului, durata de stralucire a Soarelui, sunt mai ușor de spațializat în raport cu variabilele care depind în principal de factorii dinamici, cum sunt precipitațiile, în cazul cărora gradul de incertitudine implicat de modelele spațiale este mai mare.

5.2. Analiza influenței scării de spațiu și timp în alegerea metodei optime de spațializare

Scara de spațiu și timp exercită o influență importantă asupra spațializării informației meteo-climatică. În general, se poate afirma că valorile medii (lunare, anuale) sunt mai predictibile spațial în raport cu valorile momentane (ex., diurne), deci mai ușor de spațializat, iar spațializarea este mai dificilă pe teritorii restrânse (scara de spațiu locală) comparativ cu teritoriile mai extinse. Ultima afirmație este relativă, deoarece, de la un anumit nivel, creșterea eterogenității teritoriului studiat determinată de creșterea suprafeței acestuia face dificilă elaborarea unui model statistic unic pentru întreaga regiune, impunându-se subdivizarea ei în regiuni caracterizate printr-o relativă omogenitate climatică.

Figura 12. Exemplu privind problemele ridicate de spațializarea valorilor momentane de temperatură la scara locala pentru un decupaj din Podișul Central Moldovenesc (data achizitiei imaginii LANDSAT: 20.10.1997)



Exemplul redat în din figura 12 ne edifică asupra problemelor ridicate de spațializarea la scară temporală diurnă și la scară spațială locală. Este vorba despre spațializarea temperaturii aerului din data de 20.10.1997 pentru un decupaj din Podișul Central Moldovenesc. Pentru această dată, s-a utilizat imaginea LANDSAT în infraroșu termic pentru a deriva temperatura radiativă a suprafeței active. De asemenea, s-au utilizat datele de la stațiile din Podișul Moldovei pentru a deriva temperatura aerului prin kriging rezidual. În plus, a fost aplicat un model determinist (*Wilson J.P., Gallant J.C., 2000*) de spațializare a temperaturii la scară locală în funcție de temperatura înregistrată la stația cea mai apropiată (Negrești în cazul nostru), de gradientul termic vertical local (considerat $0.5^{\circ}\text{C}/100\text{m}$), radiația globală și indicele foliar (LAI).

Variațiile locale, de detaliu, ale temperaturii aerului sunt semnificativ influențate de utilizarea terenului și de vegetație, de panta și expoziția versanților. Deși imaginea LANDSAT nu redă temperatura aerului ci temperatura suprafeței active (care, trebuie precizat, nu a fost corectată funcție de emisivitate, motiv pentru care vorbim de o temperatură radiativă), între cei doi parametri ar trebui să fie o corelație statistică foarte bună. Această corelație lipsește în cazul temperaturii spațializate statistic prin kriging rezidual, dovedind incapacitatea modelului statistic de a reda variațiile de detaliu doar pe baza unui eșantion de stații. Modelul determinist, care utilizează corecții funcție de radiația globală și utilizarea terenului, este mult superior celui statistic, fapt dovedit de corelația bună dintre temperatura aerului derivată pe baza acestuia și temperatura radiativă.

Abordând problema influenței scării de spațiu dintr-o altă perspectivă, ne punem întrebarea în ce măsură **informația despre vecinătate** este mai relevantă pentru spațializarea parametrilor meteo-climatici decât informația strict locală asociată stațiilor

meteorologice / posturilor pluviometrice. Cel mai simplu mod de a cuantifica informația despre vecinătate este de a calcula valorile medii ale variabilelor explicative pentru aria înconjurătoare a unei stații și de a testa care este dimensiunea optimă a acestei arii, adică dimensiunea asociată corelației maxime dintre predictor și predictand. În mediu SIG această analiza presupune *filtrarea low-pass a predictorilor* utilizând *ferestre glisante* cu dimensiuni din ce în ce mai mari, urmată de extragerea valorilor medii ale predictorilor asociate eșantionului de stații.

Figura 13. Variația coeficienților de corelație ale parametrilor climatici cu altitudinea și energia locală a reliefului în funcție de talia ferestrei glisante. Exemplu din Podișul Moldovei pentru medii ale parametrilor climatici din cadrul ciclului de vegetație al porumbului (Patriche C. V., 2006)

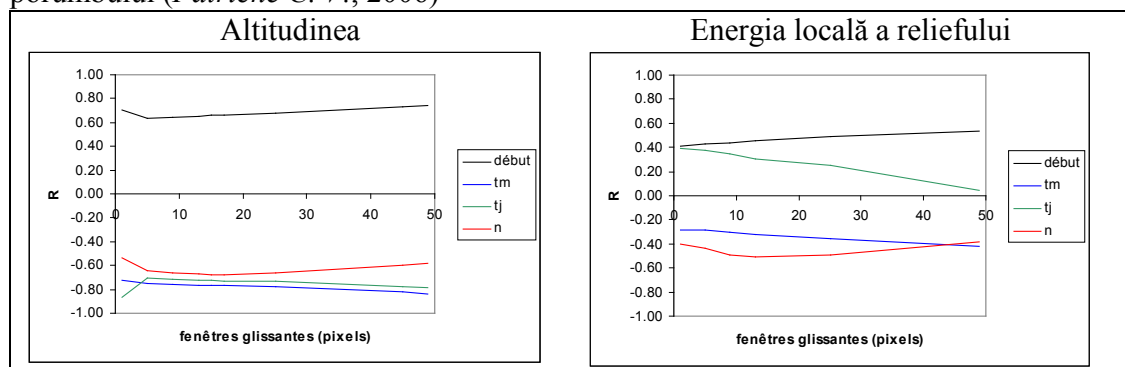
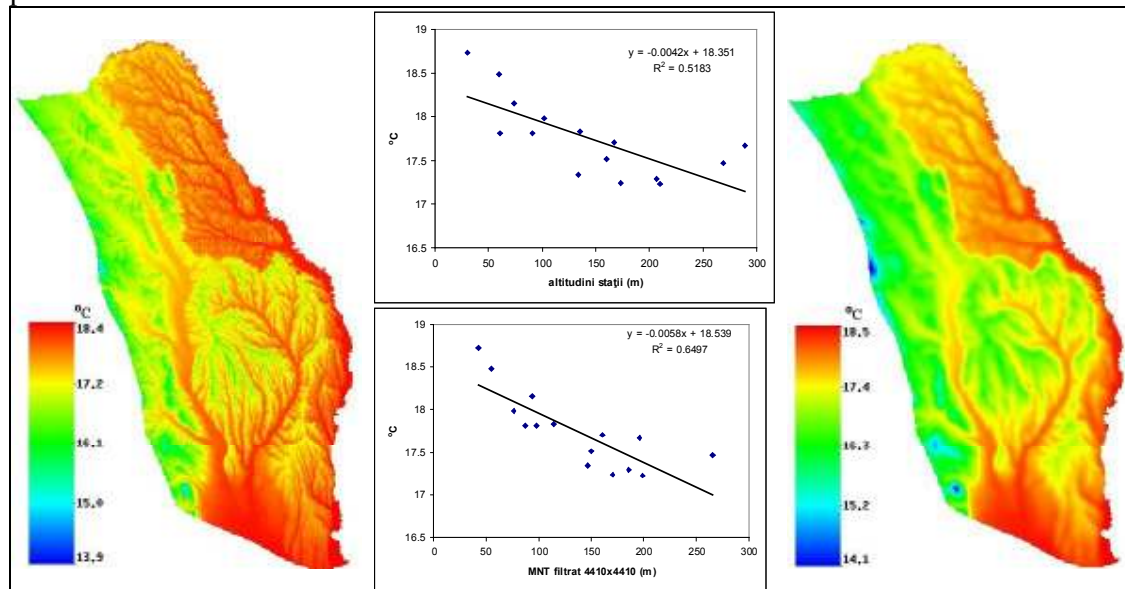


Figura 14. Spațializarea relației altitudine - temperatură folosind altitudinile stațiilor (stânga) și cele preluate din MNT-ul filtrat (dreapta) cu fereastră glisantă de 4410m. Exemplu din Podișul Moldovei pentru temperatura medie din ciclul de vegetație al porumbului



Atât studiile noastre cât și cercetări anterioare (Lhotellier R, 2005, Patriche C. V., Lhotellier R, 2006, Patriche C. V., 2006) demonstrează utilitatea acestei tehnici pentru

îmbunătățirea modelelor de regresie destinate spațializării variabilelor termice și radiative.

În exemplul redat în figura 13 se remarcă faptul că nivelul corelației maxime este în majoritatea cazurilor asociat predictorilor filtrați, nu valorilor brute, strict locale ale acestora.

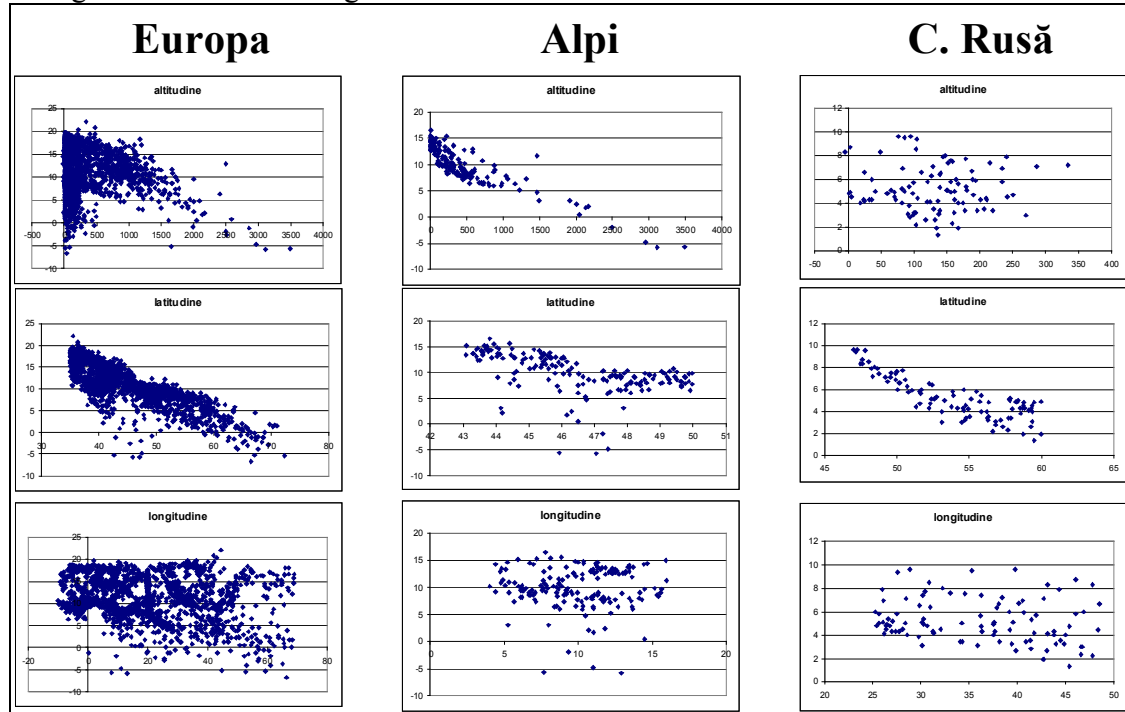
Talia optimă a ferestrei glisante, asociată corelației maxime, variază în limite foarte largi, de la un parametru climatic la altul, de la un moment de timp la altul. Spre exemplu, corelația maximă dintre altitudine și temperatura medie din ciclul de vegetație al porumbului a fost identificată pentru o dimensiune a ferestrei glisante de 4410x4410m (folosind un MNT cu rezoluție de 90x90m), creșterea varianței explicate în raport cu utilizarea MNT-ului brut fiind de 13% (figura 14).

Și alte operații matematice, în afara medierii, aplicate în ferestre glisante asupra predictorilor, se pot dovedi utile pentru spațializarea variabilelor meteo-climatice (ex., ecartul maxim de variație sau deviația standard). Tehnici mult mai complicate utilizează analiza componentelor principali pentru a descompune topografia locală în componente elementare, cum este metoda Aurelhy (*Benichou P., Le Breton O., 1987*) destinată spațializării precipitațiilor atmosferice în zone cu topografie complexă.

O altă problemă legată de influența scării de spațiu este **problema zonelor eterogene**. În general, cu cât o regiune este mai extinsă, cu atât ea este mai eterogenă din punct de vedere fizico-geografic și implicit climatic. Așa cum afirmam anterior, un anumit nivel de eterogenitate este necesar pentru spațializarea informației meteo-climatice. Într-o regiune restrânsă, cu relief șters, în care ecartul altitudinal nu depășește, spre exemplu, 100-200m, variația spațială a câmpurilor climatice nu este suficient de importantă pentru a surprinde corect legile distribuției spațiale. Pe de altă parte, într-o regiune extinsă, eterogenitatea climatică poate fi prea mare pentru a permite unui singur model statistic să explice toate aspectele variației spațiale a câmpurilor climatice. În această situație devine necesară divizarea regiunii studiate în subregiuni mai omogene din punct de vedere climatic, în care relațiile predictor – predictand se mențin aceleași.

Un exemplu în acest sens este redat în figura 15 pentru relațiile dintre temperatura medie anuală a aerului în Europa și altitudine, latitudine, longitudine. La scară continentală, Europa este un teritoriu neomogen climatic, astfel încât relațiile cauzale temperatură – predictorii se modifică cantitativ și calitativ în spațiu. Spre exemplu, gradientul termic vertical nu este același peste tot, mai mult valorile acestuia pot deveni și pozitive în regiuni caracterizate prin frecvente inversiuni de temperatură. Observând configurația câmpurilor de corelație la nivel continental, ne dăm seama că nu putem construi un model statistic unic pentru întreaga regiune pentru nici unul dintre predictorii. Dacă însă divizăm teritoriul Europei în subregiuni mai omogene climatic relațiile predictorii – predictand devin mult mai clare. Spre exemplu, în Alpi, așa cum e de așteptat, altitudinea joacă rolul cel mai important, explicând cea mai mare parte a distribuției spațiale a temperaturii. Latitudinea joacă aici un rol secundar, datorită eșalonării latitudinale reduse a acestei regiuni. Dimpotrivă, în Câmpia Rusă, relieful șters, cu slabe variații altitudinale dar și cu frecvente inversiuni termice, face ca distribuția temperaturii să fie practic independentă de altitudine, aceasta fiind condiționată în primul rând de factorul latitudine.

Figura 15. Exemplu de variație, în cadrul continentului european, a relațiilor dintre temperatura medie anuală și altitudine – latitudine – longitudine în funcție de gradul de eterogenitate climatică a regiunilor



Problema principală ridicată de zonele eterogene este modul de divizare a acestora în subregiuni care nu trebuie să fie prea omogene astfel încât relațiile predictor – predictand să nu mai poată fi corect surprinse. Un posibil mod de abordare îl constituie examinarea parametrilor regresiei și a reziduurilor acesteia pe măsura extinderii sau reducerii suprafeței regiunii studiate. În felul acesta, putem stabili limitele subregiunilor care corespund celui mai stabil model de regresie (corelație maximă, reziduuri minime). Un alt mod posibil de abordare a problemei eterogenității se referă la aplicarea regresiei ca interpolator local, însă acest lucru este adesea împiedicat de slaba densitate a rețelei de stații meteorologice.

O altă problemă legată de influența scării de spațiu, în general și de problema eterogenității, în particular, o constituie **aplicabilitatea modelelor statistice la diferite scări de spațiu**. Întrebarea pe care o adresăm aici este în ce măsură un model elaborat la o anumită scară de spațiu este aplicabil la o scară diferită.

Un exemplu în acest sens este redat în figurile 16 și 17. Acesta se referă la aplicarea unui model de regresie progresivă pentru temperatura medie anuală cu altitudinea și latitudinea ca predictor, derivat la scara întregii Europe, pentru o regiune mult mai mică, respectiv Podișul Moldovei.

Figura 16. Spațializarea temperaturii medii anuale pe baza relației cu altitudinea și latitudinea la nivelul Europei (stânga) și în Podișul Moldovei (dreapta)

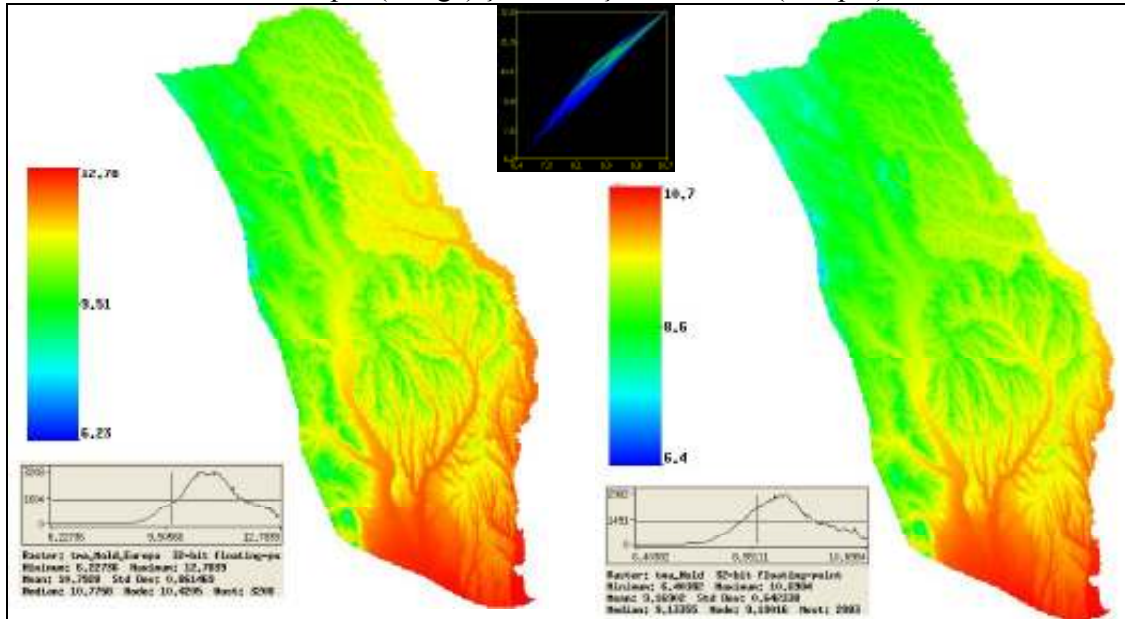
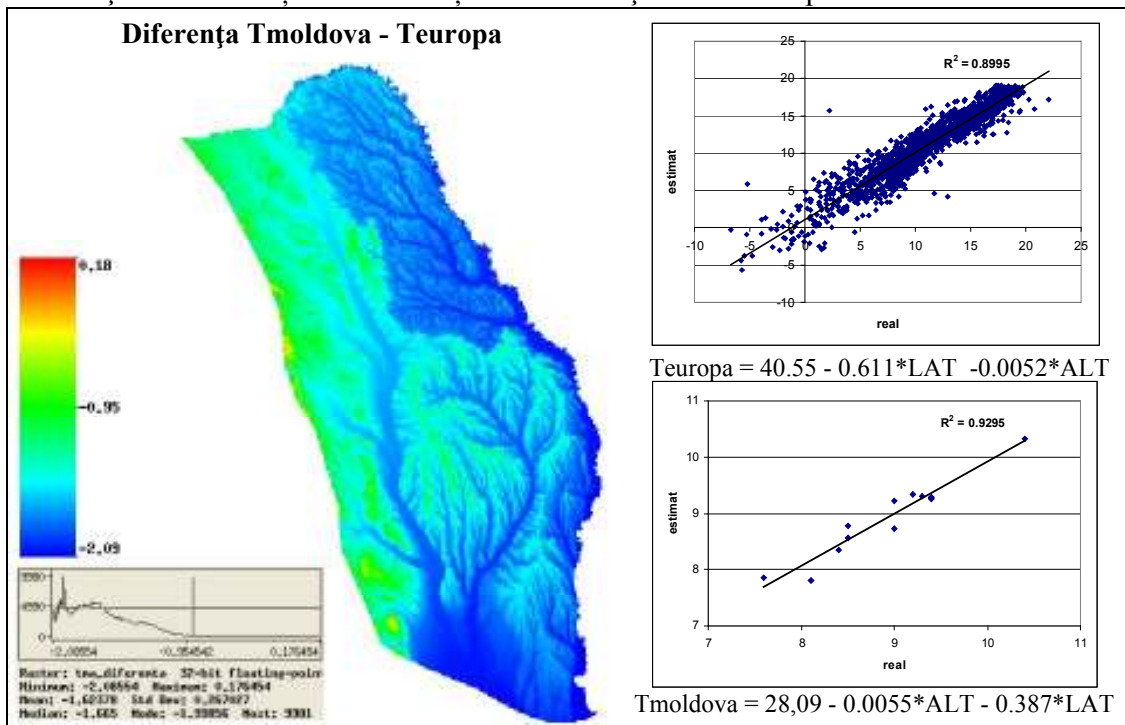


Figura 17. Diferența dintre modelele spațiale ale temperaturii medii anuale obținute pe baza stațiilor din Podișul Moldovei și a tuturor stațiilor din Europa



Analizând ecuațiile de regresie obținute pentru cele 2 regiuni, remarcăm valorile diferite ale gradientilor termici verticali și latitudinali. Dacă gradientii verticali sunt foarte asemănători, cei latitudinali diferă semnificativ. Însă datorită extinderii latitudinale

redușe a Podișului Moldovei (cca 2°), erorile induse de gradientii latitudinali diferiți sunt mici. Totuși modelul elaborat la scara întregii Europe tinde să supraestimeze valorile mari de temperatură, valoarea maximă estimată fiind de 12.8°C, care nu se regăsește pe teritoriul României. Diferența medie dintre cele 2 modele spațiale este de -1.6°C care este semnificativă pentru acest parametru climatic. În consecință, putem afirma că, în cazul de față, modelul de temperatură elaborat la scară continentală nu este aplicabil pentru teritoriul Podișului Moldovei.

Așa cum precizam anterior, delimitarea regiunilor optime pentru interpolare poate fi realizată prin analiza schimbărilor parametrilor regresiei induse de modificarea ariei studiate. Exemplul din figurile 18 și 19 ne arată ce se întâmplă atunci când ne extindem regiunea studiată dintr-o zonă de podiș în spațiul montan. Introducerea în model a 2 stații de altitudine din zona montană modifică semnificativ relația statistică dintre temperatura medie anuală și altitudine. Gradientul termic vertical descrește de la 0.57°C/100m la 0.47°C/100m, iar relația pe ansamblu pare să se îmbunătățească semnificativ prin creșterea varianței explicate de la 36% la 95%. Totuși, analiza reziduurilor de la stațiile situate în zona de podiș indică faptul că valorile de temperatură sunt mai bine estimate de modelul statistic mai slab, respectiv cel care utilizează exclusiv stațiile din zona de podiș. Îmbunătățirea aparentă a regresiei cauzată de inserarea celor 2 stații de altitudine, situate în condiții climatice diferite, caracterizate prin valori mici de temperatură, este determinată de efectul „atragerii” dreptei de regresie de către aceste puncte cu valori foarte diferite.

În consecință, putem afirma că extinderea zonei de studiu dintr-un areal de podiș în spațiul montan, creează o regiune eterogenă pentru care un singur model de regresie nu poate fi aplicat. Dacă regiunea de podiș este cea care ne interesează, atunci trebuie să adoptăm modelul statistic mai slab explicativ care utilizează doar eșantionul de stații din zona de podiș.

Figura 18. Spațializarea temperaturii medii anuale pe baza stațiilor din Podișul Moldovei (stânga) și folosind stații exterioare situate în condiții climatice diferite – Rarău, Ceahlău (dreapta)

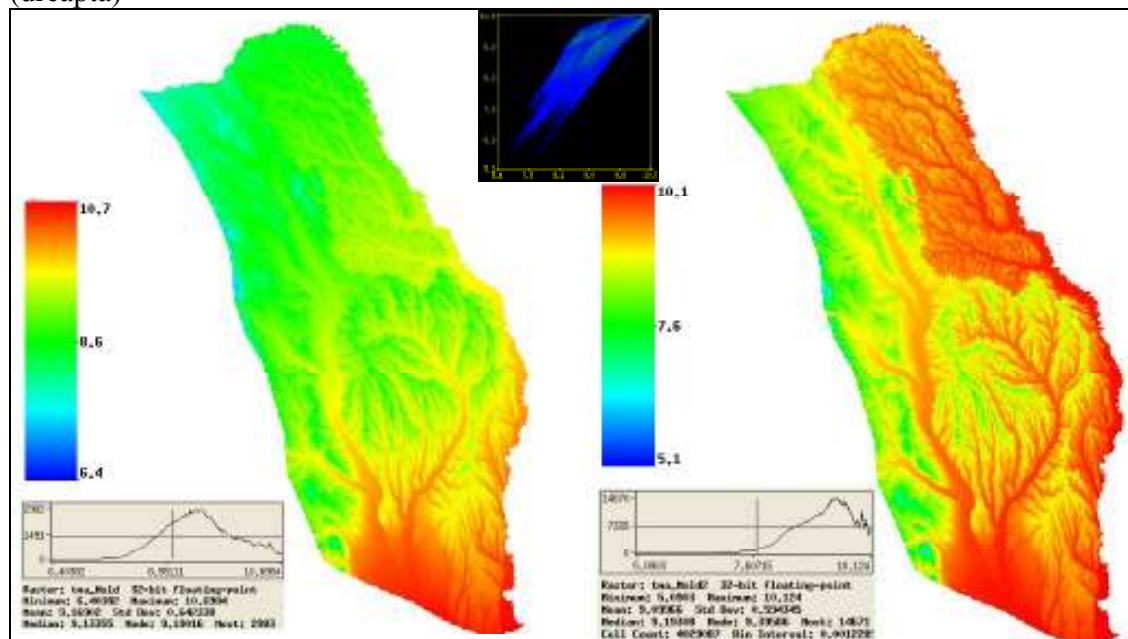
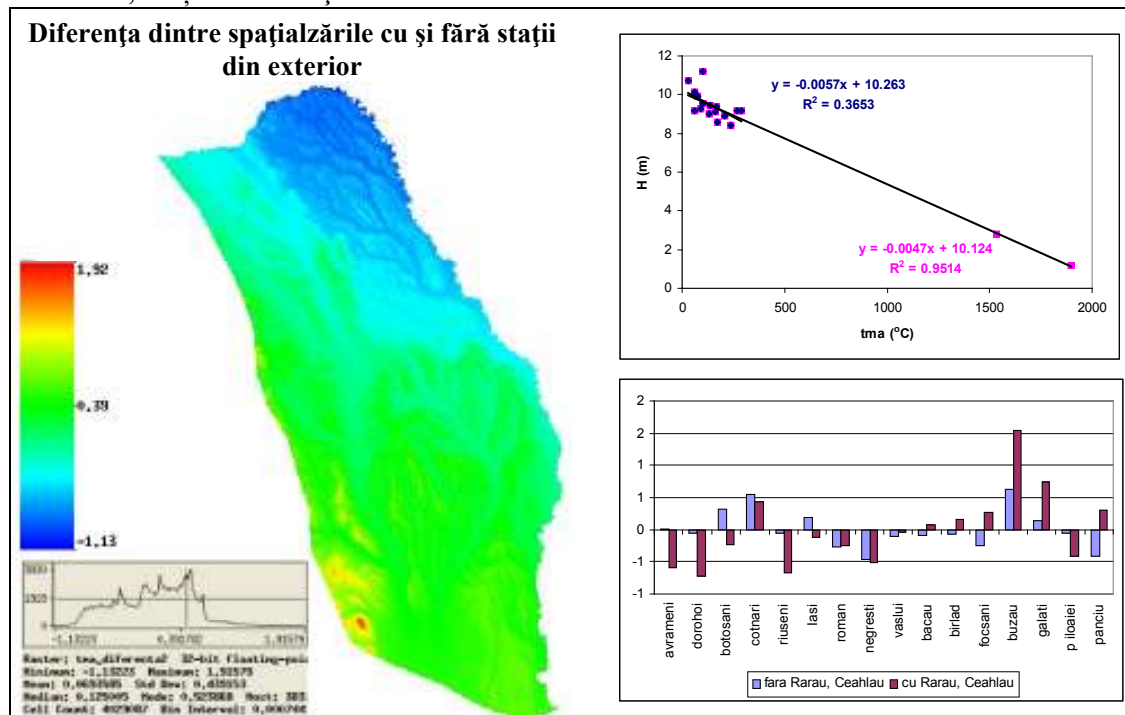


Figura 19. Diferența dintre modelele spațiale ale temperaturii medii anuale funcție de altitudine, cu și fără 2 stații de exterior situate la mare altitudine



O ultimă problemă legată de scara de spațiu pe care o abordăm și care este, de asemenea, în strânsă legătură cu reprezentativitatea spațială a rețelei de stații, o constituie **problema extrapolării**.

Din nefericire, în majoritatea cazurilor, prin poziția și densitatea stațiilor, rețeaua meteorologică nu este suficient de reprezentativă pentru teren, nefiind în măsură să surprindă toate aspectele terenului care condiționează distribuția spațială a parametrilor meteo-climatici. Din rațiuni economice, majoritatea stațiilor sunt așezate în zone joase, pe fundul văilor etc., zonele înalte sau versanții fiind acoperite deficitar.

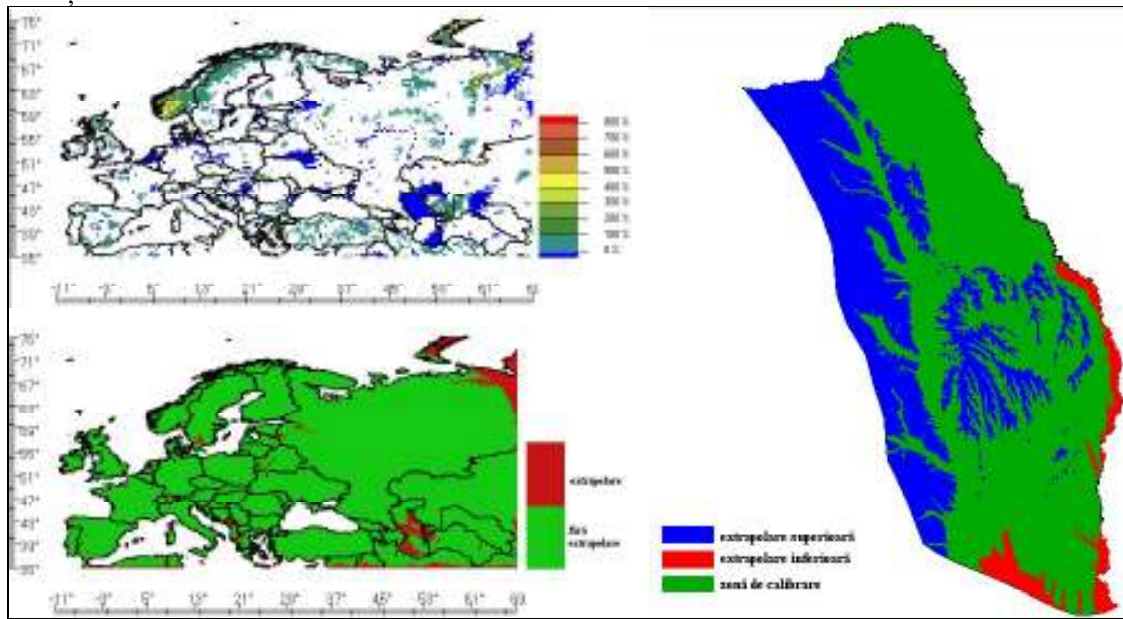
Lipsa stațiilor în anumite zone presupune, prin urmare, extrapolarea modelelor spațiale în aceste areale. Extrapolarea este corectă în măsura în care relațiile predictor – predictand nu se modifică semnificativ în aceste regiuni lipsite de măsurători. Deși, din păcate, nu avem posibilitatea de a verifica în ce măsură extrapolarea este corectă, este totuși necesară cunoașterea extinderii acestor areale pentru a le putea acorda o atenție sporită.

În figura 20 sunt redate câteva modalități de vizualizare a zonelor de extrapolare. În partea dreaptă, teritoriul Moldovei a fost divizat în 2 zone principale, conform cu distribuția spațială a rețelei de posturi pluviometrice: zona de calibrare, care reprezintă zona în care sunt așezate posturile și pentru care modelele statistice sunt valabile; zona de extrapolare, situată fie la altitudini mai mari (extrapolare superioară), fie la altitudini mici (extrapolare inferioară), în cadrul căreia nu există posturi pluviometrice și în consecință, modelele statistice trebuie extrapolate.

În partea stângă sunt reprezentate zonele de extrapolare orizontală (stânga jos) și verticală (stânga sus) pentru modelele statistice bazate pe rețeaua europeană de stații meteorologice. Reprezentarea realizată cu ajutorul softului NewLocClim este mai


complexă, ținându-se cont și de extinderea areală a suprafețelor lipsite de stații. De asemenea, reprezentarea extrapolării verticale, prin raportarea altitudinii terenului din zonele lipsite de măsurători la altitudinea stației celei mai apropiate, ne dă o idee asupra a cât de mult trebuie extrapolat modelul în aria respectivă.

Figura 20. Exemple de reprezentare spațială a zonelor de extrapolare pentru Europa și Podișul Moldovei



Revenind la problema influenței scării de timp, în afara dificultăților relevate în debutul acestui subcapitol privind spațializarea valorilor momentane, remarcăm *modificările calitativ-cantitative ale modelelor statistice* elaborate pentru o aceeași variabilă meteo-climatică *la diferite momente de timp*.

Figura 21. Exemplu privind variația în timp a contribuției predictorilor la explicarea distribuției spațiale a temperaturilor minime medii lunare de iarnă în Alpii francezi



Exemplul prezentat în figura 21 este relevant în acest sens. Este vorba despre spațializarea valorilor de temperatură minime medii lunare în Alpii francezi (*Patriche C.V., Lhotellier R., 2006*) prin modele de regresie multiplă pas cu pas, folosind un număr foarte variat de predictorii. Se remarcă, pe de o parte, modificarea predictorilor de la o lună la alta și variația semnificativă în timp a aportului acestora la explicarea varianței totale, pe de cealaltă parte. Aceste fluctuații se explică, în primul rând, prin condițiile

barice și dinamice particulare din fiecare lună, care modifică în timp, sub aspect calitativ și cantitativ, influența aceluiași predictor asupra aceluiași parametru meteorologic. Remarcăm, în plus, ca regulă generală, o relație inversă între numărul predictorilor și varianța explicată, ceea ce înseamnă că în lunile în care condițiile sinoptice fac ca distribuția spațială a câmpului termic să fie mai complexă, deci mai puțin predictibilă, este necesară luarea în considerație a unui număr mai mare de aspecte ale terenului pentru a explica această complexitate sporită.

6. Incertitudine în modelarea spațială a variabilelor meteo-climatice

Orice transformare a unei variabile discrete (valori ale unui parametru meteo-climatic asociate stațiilor/posturilor) în variabilă continuă este supusă incertitudinii. Din această perspectivă, identificarea și cuantificarea surselor de incertitudine este esențială pentru evitarea interpretărilor eronate privind distribuția spațială a parametrilor analizați.

Principalele surse de incertitudine legate de modelarea spațială statistică a parametrilor meteo-climatici sunt următoarele:

- Erori instrumentale
- Erori de înregistrare a datelor / lacune în șirurile de date
- Modificarea standardelor de măsurare a parametrilor
- Schimbarea sitului stației
- Erori de georeferențiere
- Erori derivate din eterogenitatea zonelor studiate
- Erori derivate din reprezentativitatea spațială a rețelei de stații
- Erori statistice
- Erori cumulate prin calculul unor parametri complecsi (propagarea erorilor)

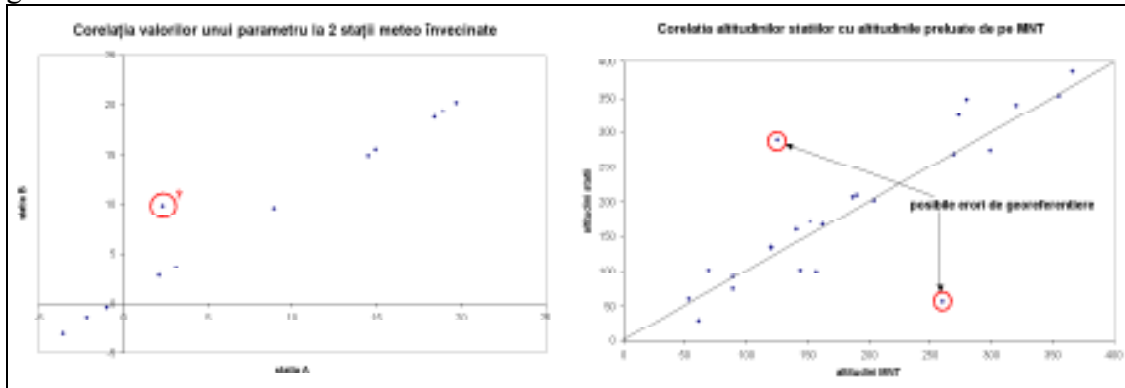
Anterior, am abordat problemele derivate din reprezentativitatea spațială a rețelei meteorologice, eterogenitatea zonelor studiate sau prezența outliers. Vom insista acum doar asupra erorilor legate de calitatea datelor meteorologice, erorilor de georeferențiere, asupra unor aspecte privind valorile de tip outliers, precum și asupra erorilor statistice și propagării erorilor.

Investigarea calității datelor este o etapă preliminară esențială pentru asigurarea calității analizelor ulterioare. Strecurarea unei greșeli în șirurile de date este adesea foarte probabilă. O modalitate simplă și clasică de identificare a valorilor eronate este de a corela șirurile de date provenite de la stații meteorologice învecinate, situate în condiții climatice asemănătoare (figura 22, stânga). Dacă unul sau mai multe puncte ies în afara norului de corelație, atunci putem presupune că valorile corespunzătoare acestora sunt eronate, iar acest lucru trebuie verificat.

Deși simplă, etapa de georeferențiere este foarte importantă. Amplasarea greșită a unei stații pe hartă este potențial generatoare a unui lanț nedorit de erori, deoarece valorile predictorilor sunt preluate automat în mediu SIG din rasterele corespunzătoare acestora. Ca și în cazul anterior, identificarea erorilor de georeferențiere poate fi realizată cu ajutorul graficelor de corelație. De data aceasta însă, punem pe același grafic altitudinile stațiilor, preluate din tabele, și altitudinile preluate de pe MNT după georeferențierea punctelor. În mod normal, între cele 2 șiruri de date trebuie să fie o corelație foarte bună. Aceasta nu este perfectă, deoarece altitudinea preluată de pe MNT este mai mult sau mai puțin generalizată, în funcție de rezoluția modelului. Totuși, dacă o serie de puncte ies semnificativ în afara norului de corelație (figura 22, dreapta), putem

presupune că avem erori de georeferențiere în aceste puncte și acest lucru trebuie verificat.

Figura 22. Modalități de identificare a unor posibile erori legate de calitatea datelor și de georeferențiere



Așa cum spuneam, **problema outliers** a fost deja abordată anterior. Revenim doar cu câteva precizări importante privind rolul acestora în alterarea modelelor statistice.

În primul rând, pentru a elimina orice confuzie, o valoare de tip outliers este o valoare care se abate semnificativ de la modelul statistic (prin urmare cu reziduuri mari), corespunzătoare unor puncte (stații) ce marchează anomalii spațiale în distribuția elementului analizat (ex., zone de foehnizare, de potențare orografică a precipitațiilor, cu inversiuni termice etc.). O astfel de valoare „rebelă” poate fi și o valoare eronată și acest lucru trebuie verificat. Dacă însă nu este vorba despre o eroare, atunci trebuie să stabilim în ce măsură această valoare ne alterează modelele statistice, în principal de regresie. Acest lucru se întâmplă în cazul regresiei deoarece, fiind cel mai adesea folosită ca metodă globală de interpolare, regresia nu este capabilă să redea anomalii spațiale. Dacă acestea există, atunci includerea în model a valorilor care descriu aceste anomalii poate modifica semnificativ relația de regresie, care devine astfel eronată.

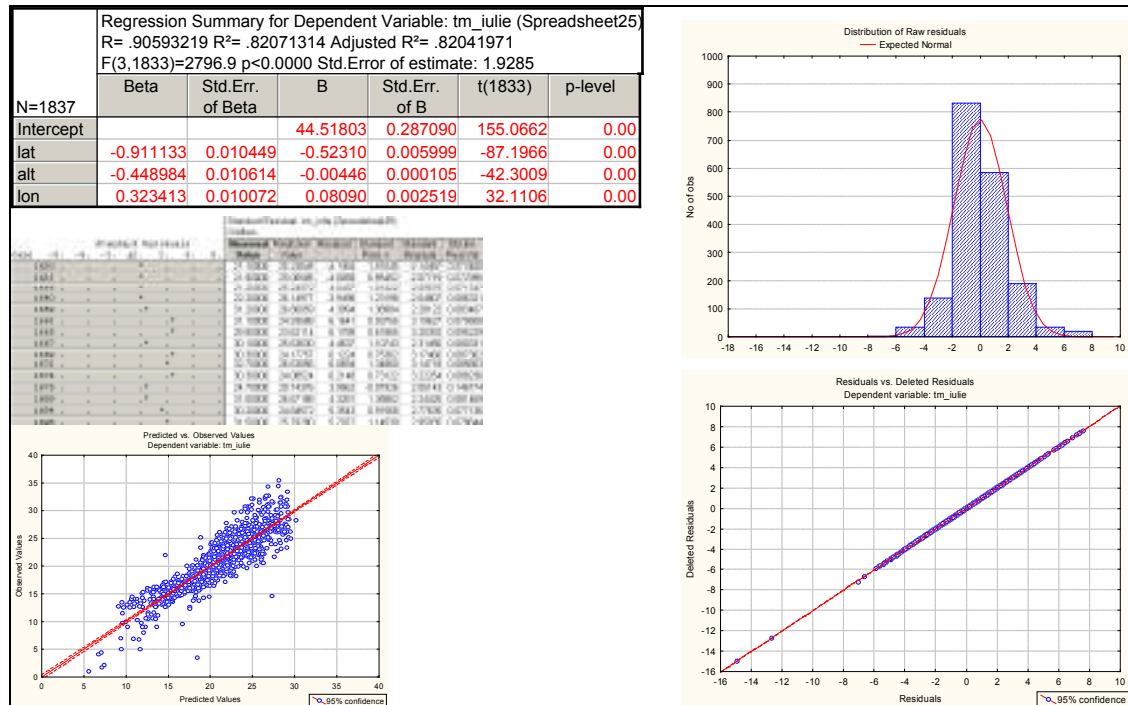
Din această perspectivă, putem identifica 2 tipuri de outliers:

- Cu reziduuri mari, dar *cu valori asemănătoare ale reziduurilor reale și a celor recalculate în lipsa stației* – acestea nu modifică modelul de regresie și pot fi păstrate.
- Cu reziduuri mari, dar *cu diferențe semnificative între valoarea rezidului real și valoarea rezidului recalculat în lipsa stației* – acestea modifică modelul de regresie și trebuie eliminate dacă modificarea este semnificativă.

Problema este că nu putem elimina pur și simplu niște valori reale din analiză, deoarece atunci vom obține o imagine incompletă a distribuției spațiale a elementului climatic în cauză. Soluția este elaborarea modelului de regresie fără valorile de tip outliers, spațializarea reziduurilor prin kriging ordinar, inclusiv a reziduurilor din punctele cu anomalii, urmată de adunarea tendinței spațiale cu reziduurile interpolate pentru a obține spațializarea finală. Remarcăm ca este vorba despre un kriging rezidual, însă care elimină în etapa de regresie valorile de tip outliers dacă acestea aparțin categoriei 2 de mai sus, însă include reziduurile din aceste puncte în etapa de interpolare kriging.

În privința **erorilor statistice**, ne oprim puțin asupra a ceea ce trebuie urmărit pentru asigurarea corectitudinii modelelor de regresie (figura 23).

Figura 23. Exemplu de aspecte ce trebuie urmărite în cadrul regresiei pentru identificarea erorilor statistice



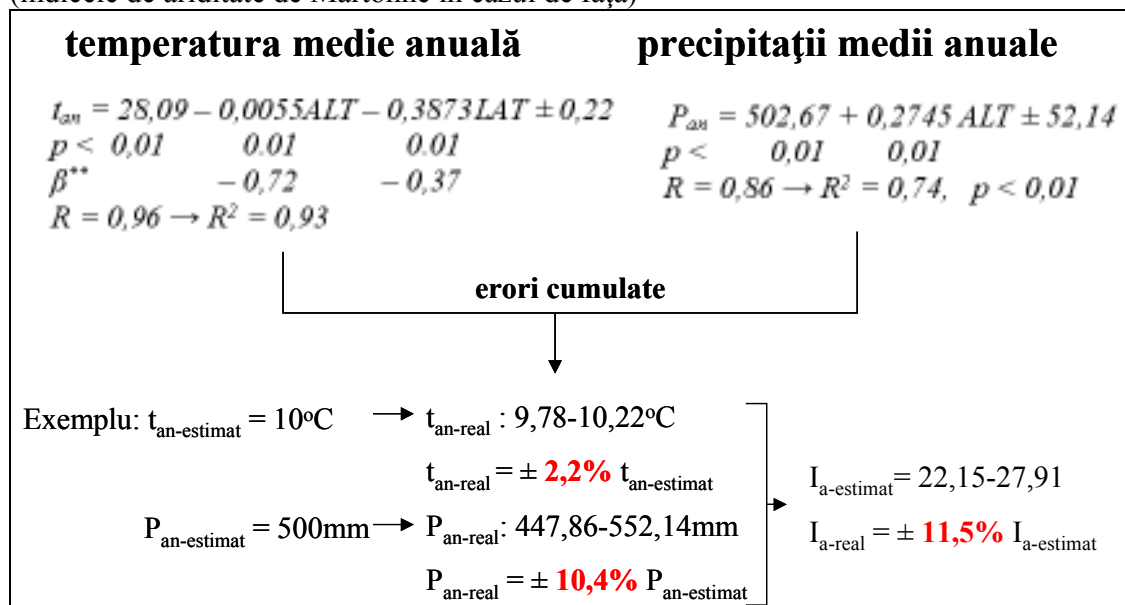
În primul rând trebuie precizat că modelele de regresie multiplă trebuie elaborate în varianta includerii pas cu pas a variabilelor explicative, pentru a minimiza efectul inter-corelațiilor dintre predictorii care sunt, adesea, semnificative. Parametrii statistici care trebuie urmăriți sunt:

- *Coeficientul de determinare (R^2):* indică ponderea varianței explicate din varianța totală. Aprecierea acestui coeficient se face atât după semnificativitatea statistică, cât și după mărimea lui (ex., un coeficient de 0.1 poate fi statistic semnificativ dacă eșantionul de date este mare, însă procentul varianței explicate fiind doar de 10% nu va fi probabil considerat semnificativ pentru spațializare).
- *Eroarea standard a estimării (ϵ):* indică eroarea medie de estimare a variabilei dependente, fiind în fapt deviația standard a reziduurilor.
- *Coeficienții de regresie parțială (B) și termenul liber:* necesită a fi testați pentru semnificativitate statistică. Coeficienții de regresie parțială indică gradientii, respectiv variația variabilei dependente pe unitatea de variație a predictorului.
- *Coeficienții de regresie parțială standardizați:* indică importanța relativă a predictorilor în condiționarea variabilei dependente.
- *Reziduurile regresiei:* reprezintă diferențele dintre valorile reale și cele estimate pentru fiecare punct din eșantionul considerat. Bineînțeles că modelul de regresie este cu atât mai bun, cu cât reziduurile sunt mai mici. Teoretic, pentru o analiză corectă, reziduurile regresiei trebuie să prezinte o distribuție

normală, de unde necesitatea testării normalității. O distribuție ne-gaussiană, poate indica influența unei alte variabile care nu a fost luată în considerare în modelul de regresie. O analiză importantă este cea a confruntării reziduurilor reale cu cele recalculate în lipsa stațiilor (validare încrucișată), care poate indica prezența valorilor de tip outliers, așa cum precizăm anterior.

Spațializarea pe baze statistice se realizează, de regulă, pentru variabile simple, elementare, cu ar fi temperaturile sau precipitațiile. Pentru caracterizarea climatică a unei regiuni avem nevoie să facem apel și la variabile complexe, derivate din cele elementare, cum ar fi indicele de ariditate de Martonne, evapotranspirația potențială, reală etc. Integrarea în relațiile de calcul a variabilelor elementare, fiecare caracterizată prin anumite erori statistice, determină invariabil **propagarea acestor erori la nivelul variabilei derivate**. Cunoașterea acestor erori este foarte importantă pentru aprecierea corectitudinii distribuției spațiale modelate a variabilei derivate.

Figura 24. Exemplu ipotetic de propagare a erorilor la nivelul unei variabile derivate (indicele de ariditate de Martonne în cazul de față)



Un exemplu simplu este prezentat în figura 24. Exemplul se referă la derivarea indicelui de ariditate de Martonne pe baza temperaturilor și precipitațiilor medii anuale modelate statistic prin regresie multiplă. Eroarea standard a estimării temperaturii medii anuale este de $\pm 0.2^{\circ}C$, ceea ce înseamnă că temperatura reală diferă de cea estimată cu $\pm 0.2^{\circ}C$ în peste 60% din cazuri. Dacă considerăm o temperatură medie anuală estimată de $10^{\circ}C$, atunci temperatura reală se va situa cel mai probabil în intervalul $9.8-10.2^{\circ}C$, adică va fi mai mare sau mai mică în raport cu temperatura estimată cu $\pm 2.2\%$. Pe de cealaltă parte, eroarea standard a estimării precipitațiilor medii anuale este de $\pm 52mm$, ceea ce înseamnă că, pentru o valoare estimată a precipitațiilor de $500mm$, valoarea reală se va situa cel mai probabil în intervalul $448-552mm$, adică va diferi de valoarea estimată cu $\pm 10.4\%$. Considerând cele 2 valori estimate de temperatură ($10^{\circ}C$) și precipitații ($500mm$), rezultă un indice de ariditate de 25. Având însă în vedere erorile posibile la estimarea celor 2 parametri de intrare, specificate mai sus, rezultă că, cel mai probabil, valoarea

reală a indicelui de ariditate va fi cupinsă între 22.1 și 27.9, adică va diferi de cea estimată cu $\pm 11.5\%$. Remarcăm astfel propagarea erorilor și conjugarea acestora, de la nivelul variabilelor elementare ($\pm 2.2\%$, $\pm 10.4\%$) la nivelul variabilei derivate ($\pm 11.5\%$).

7. Modelarea evoluției parametrilor meteo-climatici

7.1. Apecte metodologice

Seriile de timp, reprezentând diferiți parametri meteo-climatici, pot fi descompuse (filtrate) într-o serie de componente, care pot fi exprimate cu ajutorul unor ecuații matematice. Aceste componente (proprietăți seriale) sunt:

- tendința (trendul) (T);
- componentele periodice (ciclice) (P);
- componenta aleatoare (reziduu sau zgomotul seriei) (A);

Prin însumarea (modelul aditiv) sau înmulțirea (modelul multiplicativ) acestor componente se regăsește seria inițială reală. Fiecare componentă explică o anumită fracțiune din varianța totală a seriei reale (indicele de determinare). Dacă această fracțiune se dovedește a fi semnificativă, putem trage concluzia că seria cronologică nu este aleatoare, prin urmare este autocorelată temporal, iar componenta analizată este reală.

Tendința este variația lentă, pe termen lung, a parametrului studiat, care ne indică direcția generală de evoluție în timp a acestuia. Statistic, ecuația tendinței se determină, cel mai frecvent, prin metoda celor mai mici pătrate, care presupune minimizarea sumei pătratelor ecarturilor dintre valorile reale ale seriei cronologice și valorile calculate cu ajutorul tendinței. Există mai multe categorii de tendințe, a căror semnificativitate statistică necesită a fi testată:

- Liniară: $y = a_0 + a_1 t$, unde t reprezintă timpul sau o valoare proporțională cu acesta;
- Logaritmică: $y = a_0 + a_1 \log(t)$
- Putere: $y = a_0 t^{a_1}$
- Exponentială: $y = a_0 e^{a_1 t}$
- Polinomiale de diferite grade: $y = a_0 + a_1 t + a_2 t^2 + \dots + a_n t^n$

Tendințele polinomiale sunt, mai degrabă, niste pseudo-tendințe, ele marcând cvasi-ciclicități, cu perioadă lungă, în evoluția parametrului studiat.

Alegerea tendinței optime trebuie realizată atât pe baza măririi indicelui de determinare (R^2), a cărei semnificativitate statistică necesită, în prealabil, a fi testată, care exprimă proporția din varianța totală a seriei cronologice explicată de tendință, cât și pe baza verosimilității predicției. Acest ultim criteriu este supus subiectivismului, însă nu poate fi ignorat. Se constată astfel faptul că, în general, tendințele polinomiale de grad mai mare ca 3, deși explică o mai mare parte din varianța totală a seriei cronologice, oferă predicții puțin verosimile, caracterizate fie prin creșteri, fie prin scăderi accentuate ale valorilor în timp.

Trebuie, de asemenea, să avem în vedere și faptul că termenul de tendință este relativ, fiind dependent de lungimea seriei de timp analizate. Cu alte cuvinte, trendul ajustat unei serii cronologice poate fi parte a unui ciclu de evoluție cu perioadă lungă, care însă nu poate fi pus în evidență datorită intervalului scurt de analiză.

Identificarea *componentelor ciclice* presupune, într-o etapă preliminară, eliminarea trendului din seria inițială sau, în lipsa acestuia, a mediei aritmetice. Seria astfel obținută, va conține efectul combinat al variațiilor ciclice și reziduale (P + A). Identificarea celor mai semnificative perioade ale componentelor ciclice se poate realiza pe baza corelogramei sau periodigramei.

Determinarea *corelogramei* se realizează pe baza coeficienților de corelație serială (autocorelație):

$$r_k = \frac{COV(y_i, y_{i+k})}{\sqrt{\sigma_{y_i}^2 \cdot \sigma_{y_{i+k}}^2}}$$

unde:

- r_k : coeficientul de corelație serială;
- $COV(y_i, y_{i+k})$: covarianța termenilor din seria reală, în care termenii corespunzători sunt separați prin intervalul k ;
- $\sigma_{y_i}^2, \sigma_{y_{i+k}}^2$: varianțele celor două serii.

Reprezentarea grafică a coeficienților de autocorelație în funcție de valorile succesive ale lui k (1 ... n-1) poartă numele de corelogramă și poate fi utilizată la identificarea acelor perioade (valori ale lui k) care separă termeni semnificativ intercorelați.

Determinarea *periodigramei (analiza spectrală)* se bazează pe posibilitatea oricărui serii cronologice, de a fi exprimată ca *serie Fourier*, reprezentând o sumă de componente armonice, sinusoidale. Pentru fiecare armonică, se poate calcula o cantitate proporțională cu amplitudinea pătrată a acesteia, conform relației (Trebeci V. et al., 1985):

$$f(\omega_j) = \frac{1}{n} \left\{ \left[\sum_{t=1}^n x_t \cos(\omega_j t) \right]^2 + \left[\sum_{t=1}^n x_t \sin(\omega_j t) \right]^2 \right\}$$

unde:

- t : numărul de ordine al termenilor seriei cronologice (1 ... n);
- n : numărul total de termeni ai seriei cronologice;
- ω_j : frecvența armonicilor j , egală cu $2\pi / T$, unde T este perioada armonicilor;
- x_t : termenul t al seriei cronologice.

Cu cât valoarea funcției $f(\omega_j)$ este mai mare, cu atât mai mare este contribuția pe care componenta armonică j o aduce la variația seriei cronologice. Reprezentarea grafică a valorilor funcției $f(\omega_j)$ în raport cu frecvența armonicilor (sau perioadele acestora) poartă numele de periodigramă. Deoarece periodigrama poate prezenta vârfuri apropiate ca valoare, care descriu o aceeași componentă cvasi-ciclică, se poate proceda la filtrarea acesteia prin diferite tehnici și folosind ferestre glisante de diferite mărimi pentru a evidenția doar ciclurile principale, obținându-se astfel *densitatea spectrală* a seriei cronologice.

Alegerea componentelor armonice, care ajustează cel mai bine variația seriei cronologice se realizează, prin urmare, pe baza valorilor coeficienților de corelație serială, în cazul corelogramei, sau a cantităților $f(\omega_j)$, în cazul periodigramei, selectându-se armonicile corespunzătoare valorilor celor mai mari. De asemenea, trebuie să se țină

cont și de semnificativitatea aportului armonicilor la explicarea variantei seriei periodice. Astfel, prima armonică identificată se corelează cu seria periodică, a doua armonică, cu seria rezultată din eliminarea primei componente armonice din seria periodică ș.a.m.d. Procedând în acest mod, se poate constata faptul că unele armonice, bine individualizate pe corelograma / periodigrama, sunt ne semnificative la nivelul variantei explicate, fiind, prin urmare, eliminate din calcul.

Odată selectate perioadele, ecuațiile armonicilor (a_j) se determină folosind relațiile:


$$a_j = \sum_{t=1}^n B_j \cos(\omega_j t) + \sum_{t=1}^n C_j \sin(\omega_j t)$$

$$B_j = \frac{2}{n} \sum_{t=1}^n x_t \cos(\omega_j t)$$

$$C_j = \frac{2}{n} \sum_{t=1}^n x_t \sin(\omega_j t)$$

Prin însumarea tendinței sau, în lipsa acesteia, a mediei aritmetice, cu armonicile semnificative identificate vom obține seria periodică inițială minus un reziduu necorelat, reprezentând *seria cronologică ajustată*. Aceasta poate fi corelată cu valorile seriei reale pentru a determina gradul de explicare a variantei totale.

Figura 25. Filtrarea seriei cronologice și obținerea seriei ajustate prin însumarea tendinței și componentelor ciclice semnificative



Seria reziduală (zgomotul) se obține extragând din seria reală valorile seriei ajustate. Magnitudinea reziduuului poate fi apreciată pe baza *erorii standard a estimării*:

$$ES = \pm \sigma_z \sqrt{(1 - r^2)}$$

unde: - σ_y :deviatia standard a seriei de timp reale;
 - r^2 : indicele de determinare, respectiv raportul dintre varianta explicata si varianta totala.

7.2. Medii, medii glisante, abateri și tendințe liniare

Modelarea evoluției în timp a parametrilor meteo-climatici a vizat șiruri lungi de date privind temperaturile și precipitațiile medii lunare și anuale, de peste 100 și chiar peste 200 de ani (<http://www.wetterzentrale.de/klima/index.html>). S-au urmărit tendințele de evoluție și variațiile cvasi-ciclice puse în evidență atât prin mediile glisante cu perioada de 10 ani, pentru temperaturi și de 5 ani pentru precipitații, cât și prin analiză spectrală.

Figura 26. Tendințe de evoluție și variații cvasi-ciclice ale temperaturii aerului. Exemplu pentru lunile ianuarie, iulie și pentru valorile medii anuale înregistrate la stațiile De Bilt și Berlin

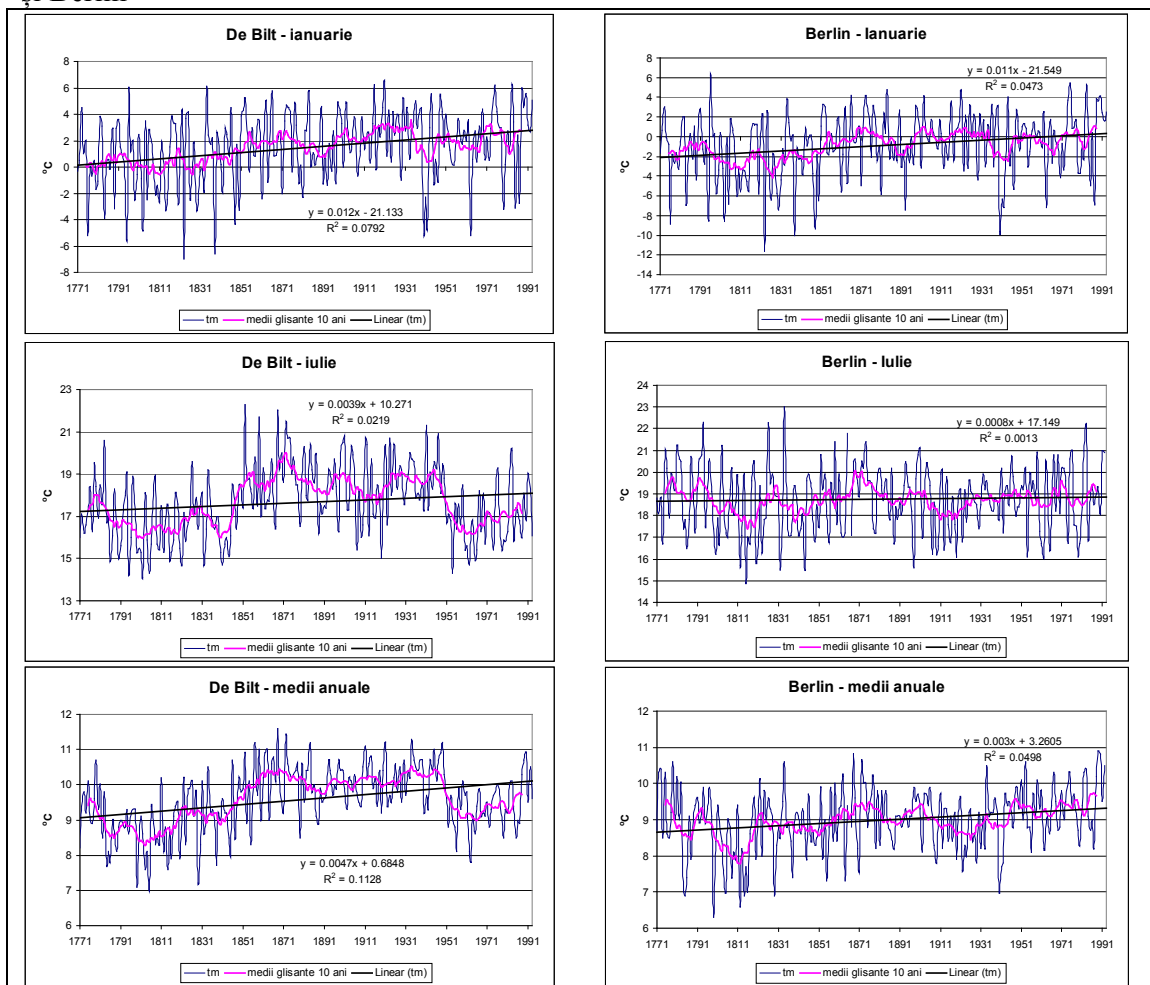



Figura 27. Corelații liniare între șirurile de date de temperatură, indicând evoluția sincronă sau particulară a temperaturii la stațiile considerate

ianuarie					
	<i>De Bilt</i>	<i>Viena</i>	<i>Praga</i>	<i>Paris</i>	<i>Berlin</i>
De Bilt	1				
Viena	0.847711	1			
Praga	0.878887	0.951444	1		
Paris	0.865574	0.820358	0.819855	1	
Berlin	0.932148	0.877091	0.914658	0.788678	1
iulie					
	<i>De Bilt</i>	<i>Viena</i>	<i>Praga</i>	<i>Paris</i>	<i>Berlin</i>
De Bilt	1				
Viena	0.487439	1			
Praga	0.569369	0.87611	1		
Paris	0.650742	0.648288	0.685018	1	
Berlin	0.693189	0.737623	0.781536	0.644889	1
medii anuale					
	<i>De Bilt</i>	<i>Viena</i>	<i>Praga</i>	<i>Paris</i>	<i>Berlin</i>
De Bilt	1				
Viena	0.438707	1			
Praga	0.438328	0.896926	1		
Paris	0.51027	0.655645	0.743852	1	
Berlin	0.700805	0.738087	0.72794	0.605001	1

Figura 28. Valorile coeficienților de corelație asociați tendințelor de evoluție a temperaturii la nivel lunar (stânga) și anual (dreapta)



Datele de temperatură indică tendințe de creștere evidente în lunile ianuarie, martie, noiembrie și decembrie, deci o tendință generală de încălzire a sezonului rece (figurile 26, 28). Pentru sezonul cald, tendințele sunt mai estompate, indicând o scădere a temperaturii, mai bine evidențiată pentru luna august. La nivel anual, au rezultat tendințe evidente de creștere a temperaturii doar la 2 din cele 5 stații analizate, respectiv De Bilt și Berlin.

Coeficienții de corelație liniară dintre șirurile de date de la stațiile considerate (figura 26) indică o evoluție cvasi-sincronă a temperaturii în luna ianuarie, fapt ce generalizează tendința de încălzire din această lună. Pentru luna iulie și la nivel anual, particularitățile de evoluție sunt diferite de la o stație la alta, fapt ce împiedică generalizarea tendințelor identificate.

Pentru precipitațiile atmosferice, analiza șirurilor de date de la 7 stații indică tendințe generale de creștere, atât la nivel lunar cât și anual, mai evidente la stația Oslo, pentru care varianța explicată la evoluția sumelor anuale este de 31% (figurile 29, 30). Deoarece iese net din imaginea de ansamblu creată de restul stațiilor, ne permitem să privim cu rezerve această creștere până când ne vom putea lămuri pe deplin asupra cauzelor. Excepție de la fondul general de creștere a pluviozității face stația Roma, la care tendințele atât lunare, cât și anuale indică o descreștere a precipitațiilor.

Figura 29. Tendințe de evoluție și variații cvasi-ciclice ale precipitațiilor atmosferice. Exemplu pentru Roma (anual, aprilie) și Oslo (anual, noiembrie)

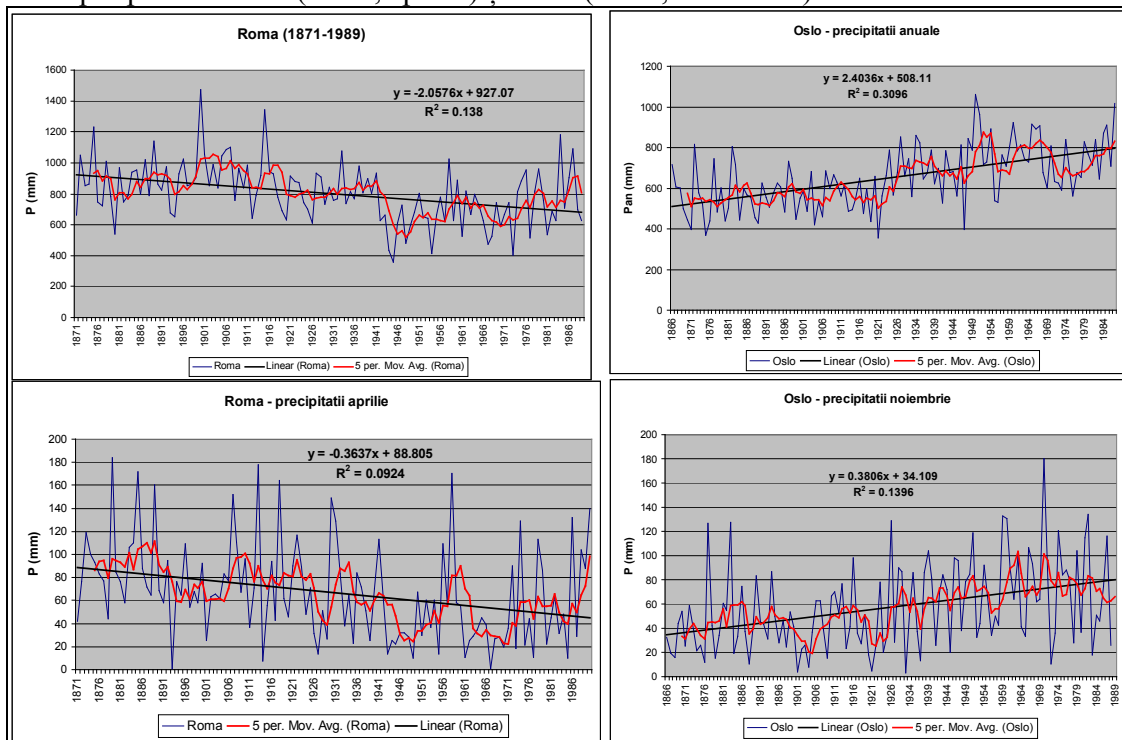



Figura 30. Valorile coeficienților de corelație asociați tendințelor de evoluție ale precipitațiilor la nivel lunar (stânga) și anual (dreapta)



Analiza abaterilor (anomaliilor) valorilor de temperatură și precipitații față de mediile multianuale este utilă pentru evidențierea unor succesiuni de perioade calde și

reci, respectiv umede și uscate. Vizualizarea cu 2 coordonate temporale (figura 31) este sugestivă în privința succesiunilor de perioade mai reci sau mai umede. Se observă clar, pentru stația Iași, perioada mai rece din intervalul 1976-1988 și instalarea fondului general de încălzire semnificativă începând cu anul 2000.

Figura 31. Evoluția anomaliilor termice medii lunare în perioada 1961-2007 la stația meteorologică Iași





Figura 32. Evoluția anomaliilor termice medii anuale în perioada 1894-2007 la stația meteorologică Iași



Procesul de încălzire la care asistăm în perioada actuală este demonstrat și de valorile mai mari ale temperaturilor medii lunare și anuale, ale temperaturilor medii din timpul iernii și verii și din perioada de creștere a plantelor (tabelul 2) ale intervalului 2000-2007, comparativ cu intervalul climatologic de referință 1961-1990. Fondul general

de încălzire este demonstrat și de valorile, în general, pozitive ale coeficienților de corelație asociați tendințele liniare de evoluție ale parametrilor termici menționați pentru perioada 1961-2007.

Tabelul 2. Comparații între mediile termice ale perioadelor 1961-2007, 1961-1990 (perioada climatologică de referință), 2000-2007 și valorile coeficienților de corelație (R) pentru tendințele liniare de evoluție în perioada 1961-2008 pentru stația Iași

	media 1961-2007	media 1961-1990	media 2000-2007	R
Ianuarie	-3,06	-3,73	-1,99	0,356
Februarie	-1,19	-1,71	-0,29	0,200
Martie	3,55	3,16	4,96	0,296
Aprilie	10,45	10,22	11,25	0,119
Mai	16,26	16,01	17,38	0,231
Iunie	19,56	19,17	20,25	0,280
Iulie	21,07	20,45	22,64	0,507
August	20,34	19,87	21,64	0,344
Septembrie	15,75	15,83	15,94	-0,054
Octombrie	10,12	10,02	10,54	0,025
Noiembrie	4,16	4,28	5,11	-0,172
Decembrie	-0,82	-0,56	-0,85	0,006
<i>Media anuală</i>	<i>9,66</i>	<i>9,42</i>	<i>10,50</i>	0,387
<i>Iarna</i>	<i>-1,73</i>	<i>-2,00</i>	<i>-1,20</i>	0,295
<i>Vara</i>	<i>20,32</i>	<i>19,83</i>	<i>21,51</i>	0,511
<i>Aprilie-Octombrie</i>	<i>16,22</i>	<i>15,94</i>	<i>17,12</i>	0,379

Notă: pentru intervalul ianuarie-mai valorile de temperatură merg inclusiv până la nivelul anului 2008; cu bold sunt figurate valorile statistic semnificative ale coeficienților de corelație pentru nivelul de asigurare de 0,05

7.3. Analiza cauzalității în evoluția parametrilor meteo-climatici

Evoluția climei, în general și a parametrilor meteo-climatici, în particular, este rezultanta complexă a interacțiunii unei game foarte variate de factori de control: variații orbitale ale Pământului și Lunii, variații ale activității solare, modificări calitativ-cantitative ale compoziției atmosferei terestre, cicluri ale activității vulcanice etc. Aceștia acționează la diferite scări de timp, imprimând climei o variație complicată, derivată din suprapunerea a numeroase componente cvasi-ciclice, marcată pe alocuri de salturi calitative, determinate de manifestarea mai intensă a unui factor neperiodic.

În studiul nostru, am încercat legarea cauzală statistică a evoluției parametrilor termici (temperaturi medii lunare și anuale), înregistrați la stația meteorologică Iași, de o serie de factori de control cu caracter periodic (variația activității solare, indicele Oscilației Sudice Le Niño) și neperiodic (efectul de seră indus de evoluția ascendentă a concentrației dioxidului de carbon atmosferic).

Analiza corelațiilor liniare ne indică relații statistic semnificative între parametri termici și concentrația CO₂ la nivel global (tabelul 3, figura 34). Seria de date de la observatorul situat în Hawaii (Mauna Loa) a fost luată în considerație datorită șirului mai lung de date, pentru a confirma sau infirma corelațiile cu seria globală, mai scurtă. Remarcăm faptul că relația dintre concentrația CO₂ la nivel global și parametrii termici

poate fi considerată reală cel puțin în cazul temperaturilor medii ale lunilor de vară, pentru care varianța explicată este de 19-42% și la nivelul valorilor medii anuale, caz în care varianța explicată este de 21%.

Tabelul 3. Corelații între temperaturile medii lunare și anuale și o serie de factori potențial explicativi

	CO₂ global (1980-2007)	CO₂ Mauna Loa (1961-2004)	nr. pete solare (1961-2008)	El Niño SOI (1961-2004)
Ianuarie	0,171	0,319	0,164	-0,145
Februarie	0,285	0,192	0,224	0,076
Martie	0,213	0,213	0,250	-0,150
Aprilie	0,328	0,114	0,013	0,191
Mai	0,278	0,226	-0,117	-0,066
Iunie	0,442	0,268	-0,011	0,145
Iulie	0,647	0,485	-0,039	-0,140
August	0,436	0,318	0,102	0,054
Septembrie	-0,051	-0,132	-0,103	-0,069
Octombrie	0,024	-0,009	0,050	0,014
Noiembrie	0,294	-0,160	0,040	-0,154
Decembrie	-0,103	-0,105	0,108	0,119
Annual	0,460	0,341	0,216	0,148

Nota: cu bold sunt marcate corelațiile statistic semnificative pentru nivelul de asigurare de 0,05

Sursa datelor: CO₂ global – Dr. Pieter Tans, NOAA/ESRL (www.esrl.noaa.gov/gmd/ccgg/trends); CO₂ Mauna Loa – C.D. Keeling, T.P. Whorf, and the Carbon Dioxide Research Group, Scripps Institution of Oceanography (SIO), University of California, La Jolla, California USA 92093-0444 (<http://cdiac.ornl.gov/ftp/maunaloa-co2/maunaloa.co2>); nr. pete solare – NCDC / World Data Center for Paleoclimatology (<http://www.ncdc.noaa.gov/paleo/forcing.html>); El Niño, Southern Oscillation Index (SOI) – NOAA / National Weather Service, Climate Prediction Center (<http://www.cpc.ncep.noaa.gov/data/indices/>)

Figura 33. Evoluția temperaturilor medii la stația Iași comparativ cu evoluția CO₂ atmosferic global (1980-2007)




Figura 34. Corelația dintre valorile medii de temperatură de la stația Iași și concentrația CO₂ atmosferic global (1980-2007)




Figura 33 redă comparativ fondul general de creștere a temperaturilor medii în luna iulie și la nivel anual și evoluția ascendentă, mult mai bine evidențiată, a concentrației CO₂ la nivel global. Diferențele dintre ritmurile de evoluție pot fi explicate prin mecanismele de feed-back negativ din cadrul sistemului atmosferă-ocean-suprafață terestră, care acționează în sensul atenuării unei perturbații interne sau externe, respectiv în sesul diminuării concentrației și ritmului de creștere CO₂ atmosferic.

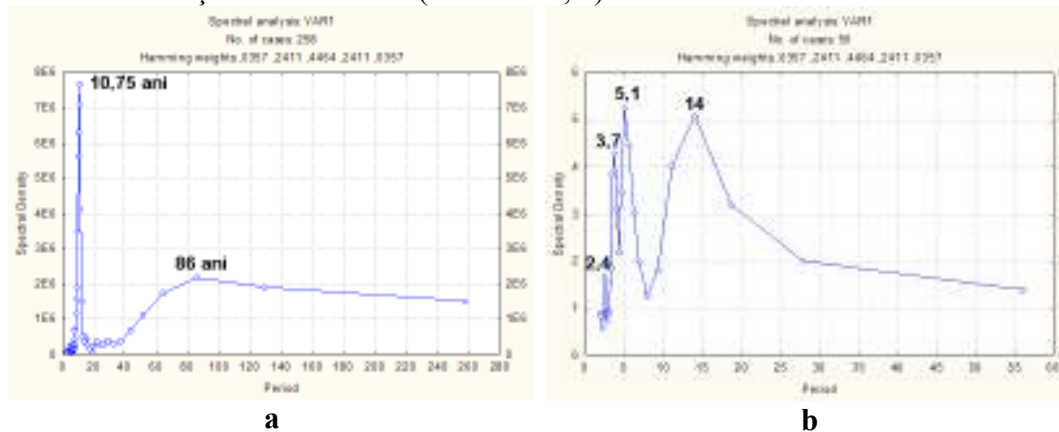
Lipsa corelațiilor statistic semnificative cu ceilalți doi factori potențial explicativi avuți în vedere nu exclude existența unor relații cauzale reale. Reamintim faptul că o serie cronologică poate fi privită ca rezultanta complexă a suprapunerii a numeroase variații ciclice asociate unui număr mare de factori. Un anumit factor, caracterizat prin anumite variații ciclice asociate, deși este un factor de control real, poate avea o contribuție redusă, statistic nesemnificativă și prin prisma lungimii intervalului de analiză, la compunerea seriei cronologice reale. Acest lucru se întâmplă cel puțin în cazul rolului activității solare, cuantificat prin numărul lunar și anual de pete solare, așa cum vom vedea în cele ce urmează.

Metoda analizei spectrale ne oferă posibilitatea de a decide dacă un factor de control cvasi-ciclic este sau nu real. Analiza identifică, în cadrul seriilor cronologice, acele fluctuații ciclice semnificative prin prisma rolului lor la formarea seriei reale. Dacă aceste fluctuații apar atât la nivelul factorului de control, cât și la nivelul variabilei dependente, iar oscilațiile sunt sincrone, putem concluziona că factorul de control influențează în mod real variabila dependentă prin inducerea acestor oscilații.

O problemă legată de analiza spectrală o constituie faptul că o fluctuație cvasi-ciclică va fi evidențiată pe periodogramă, de cele mai multe ori, nu printr-un singur peak,

ci printr-o serie de peak-uri dintr-un interval de perioade redus. Ca urmare, în această situație, nu putem preciza exact valoarea perioadei asociată fluctuației, ci un interval de perioade. O soluție o constituie calculul densității spectrale prin filtrarea periodogramei în scopul grupării peak-urilor apropiate. Chiar și așa vârful rezultat este expresia semnalului ciclic cel mai puternic dintr-un interval de cicluri care împreună compun variația cvasi-ciclică reală. Problema principală care derivă din situația prezentată constă în dificultatea reconstituirii fluctuației cvasi-ciclice pentru care este necesară adăugarea tuturor fluctuațiilor ciclice semnificative care intră în componența acestora.

Figura 35. Curbele spectrale ale numărului anual de pete solare (1749-2007, a) și Indicelui Oscilației Sudice – SOI (1951-2007, b)



Analiza spectrală a datelor privind numărul anual de pete solare pe o perioadă de 258 de ani (1749-2007) (NCDC / World Data Center for Paleoclimatology) relevă prezența a 2 cicluri importante, cu perioade de cca 10-11 ani și respectiv 86 ani, care explică seria cronologică în proporție de 74% (figura 35a). Așa cum precizăm anterior, valoarea de 10,75 ani reprezintă semnalul cel mai puternic dintr-un interval de cicluri cuprinse aproximativ între 9 și 11 ani. Aceste oscilații le regăsim la toate seriile de temperatură analizate, peak-urile corespunzând unor perioade cuprinse între 10 și 14 ani (figura 38). Prin urmare, considerăm influența activității solare asupra temperaturii ca fiind reală, cu mențiunea că aportul acestora la explicarea seriilor de temperatură este redus. Spre exemplu, ciclul de 11,4 ani identificat la stația Iași la nivelul seriei de temperaturi medii anuale se caracterizează printr-o amplitudine de $0,65^{\circ}\text{C}$, aducând un aport de doar 6% la explicarea seriei reale.

Dacă variația dioxidului de carbon atmosferic și fluctuațiile de 10-11 ani ale activității solare sunt factori de control reali, putem proceda la estimarea statistică, prin analiză de regresie a valorilor de temperatură.

Datorită intervalului relativ scurt cu măsurători de CO_2 la nivel global (1980-2007) și pentru a surprinde o imagine mai completă, s-a procedat la elaborarea a 2 modele de regresie, unul folosind valorile de CO_2 la nivel global, celalalt valorile de CO_2 înregistrate în Hawaii. Acest lucru este posibil având în vedere corelația foarte strânsă între cele 2 șiruri (coeficient de corelație de 0,99).

Rezultatele obținute prin cele 2 modele de regresie pas cu pas sunt redată în tabelele 4, 5 și figurile 36, 37. Se remarcă diferențe importante la nivelul gradientilor

estimați (coeficienții B), care indică o creștere mai accentuată a temperaturii medii anuale cu datele de CO₂ globale și mai atenuată cu datele CO₂ – Mauna Loa, deși cele 2 șiruri de date sunt practic identice. Faptul este datorat creșterii semnificativ mai accentuate a valorilor de temperatură în intervalul 1980-2007, comparativ cu intervalul mai larg 1959-2004. Ambele modele au o capacitate de explicare a variațiilor termice destul de scăzută, mai bună în primul caz (29%) și mai redusă în cel de-al doilea caz (15%). Ca urmare și capacitatea de predicție asociată acestora este redusă.

Diferențele între modele pot fi explicate fie prin incapacitatea primului model de a cuantifica relația CO₂ – temperatură, datorită intervalului mai scurt de analiză, fie neliniarității acestei relații, în sensul că o creștere liniară a CO₂ determină o creștere neliniară (de tip exponențial) a temperaturii.

Trebuie menționat că relația CO₂ – temperatură se manifestă, de la un anumit prag neliniar, fiind o relație de tip feed-back pozitiv. Creșterea temperaturii determină mobilizarea carbonului din apa oceanică și transferul acestuia în atmosferă, iar creșterea CO₂ atmosferic determină creșterea temperaturii prin efectul de seră.

Predicțiile pe 10 ani (2008-2017) sunt redată în tabelul 6. Modelul bazat pe datele de CO₂ global prezice valori cu cca 0,6-1°C mai mari decât modelul bazat pe datele de la Mauna Loa, maximul fiind plasat, în ambele cazuri, în intervalul 2012-2014, corepunzător unui vârf de activitate solară.

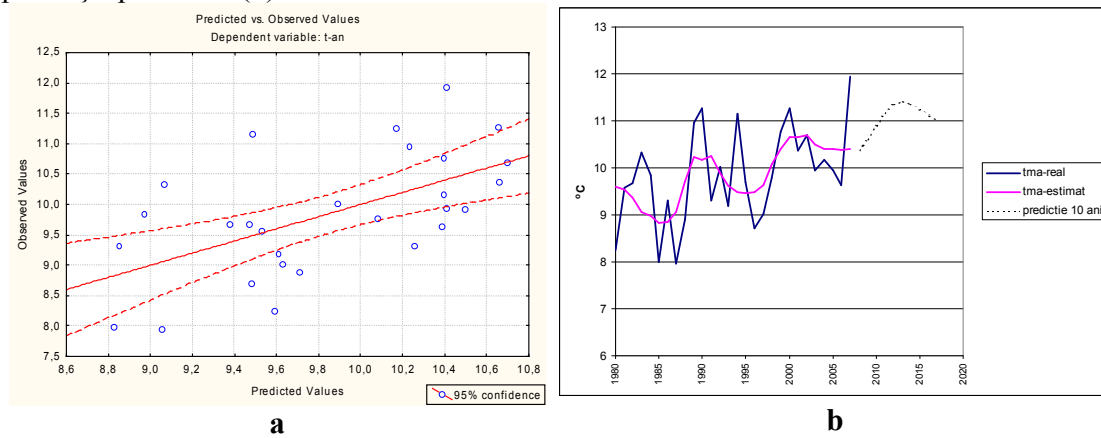
Revenind la analiza spectrală a șirurilor de temperaturi medii anuale, se constată omniprezența unor posibile variații ciclice cu perioadă lungă (200 ani, 111 ani) (figura 38). Având în vedere că, cel puțin în cazul stațiilor De Bilt, Viena, Praga și Paris, acestea corespund exact cu lungimea seriilor cronologice, este foarte posibil ca acestea să fie, în realitate, componente ale unui ciclu cu perioada și mai mare, care nu poate fi surprins în intervalul de timp analizat.

Constatăm, de asemenea, omniprezența ciclurilor de 2,1-2,2 ani care ar putea fi puse în legătură cu ciclicitatea fenomenului El Nino. De asemenea, ciclurile cu perioade de cca 3 ani, de cca 5 ani se regăsesc și pe curba spectrală a indicelui SOI.

Tabelul 4. Parametrii modelului de regresie multiplă progresivă având ca variabile explicative concentrația CO₂ la nivel global și numărul anual de pete solare

R = 0,588 R ² = 0,346 F(2,25) = 6,6054 p<0,00498 eroarea standard a estimării: 0,84402						
	Beta	Er. Std.	B	Er. Std.	t(25)	p-level
Termen liber			-6,67660	4,736412	-1,40963	0,170968
CO₂-an	0,589962	0,171636	0,04449	0,012943	3,43729	0,002065
Nr. pete - an	0,388234	0,171636	0,00064	0,000285	2,26197	0,032647

Figura 36. Corelația dintre valorile observate și estimate prin regresie multiplă progresivă având ca variabile explicative concentrația CO₂ la nivel global și numărul anual de pete solare (a). Seria reală a temperaturilor medii anuale, seria ajustată și predicția pe 10 ani (b)




Tabelul 5. Parametrii modelului de regresie multiplă progresivă având ca variabile explicative concentrația CO₂ – Mauna Loa și numărul anual de pete solare

$R = 0,434$ $R^2 = 0,224$
 $F(2,42) = 4,8666$ $p < 0,01256$ Std.Error of estimate: 0,78353

	Beta	Std.Err.	B	Std.Err.	t(42)	p-level
Termen liber			4,259251	2,192187	1,942923	0,058749
CO₂-an	0,317967	0,139045	0,014562	0,006368	2,286793	0,027314
Nr. pete - an	0,290715	0,139045	0,000436	0,000208	2,090796	0,042636

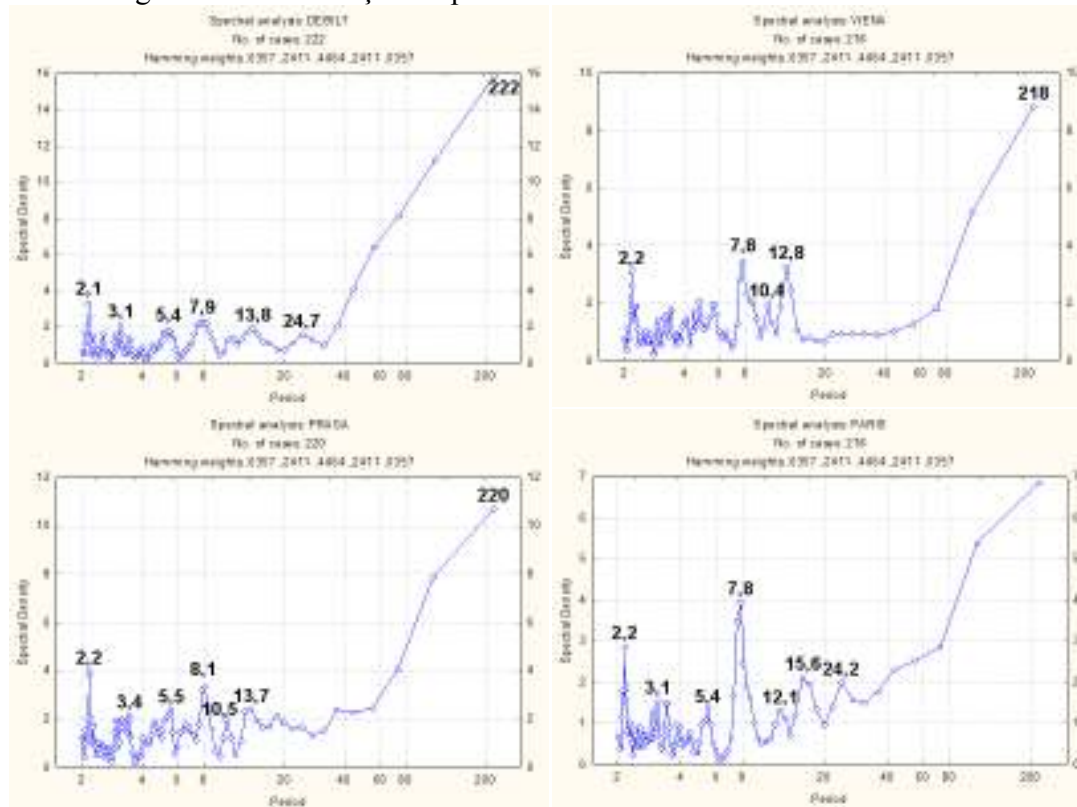
Figura 37. Corelația dintre valorile observate și estimate prin regresie multiplă progresivă având ca variabile explicative concentrația CO₂ – Mauna Loa și numărul anual de pete solare (a). Seria reală a temperaturilor medii anuale, seria ajustată și predicția pe 10 ani (b)




Tabelul 6. Parametri estimați în intervalul de predicție de 10 ani prin modelele de regresie

Interval predicție	CO ₂ global estimat	CO ₂ Mauna Loa estimat	nr. estimat pete solare	tma estimat - CO ₂ global	tma estimat - CO ₂ Mauna Loa
2008	382,51	379,09	25,82	10,36	9,79
2009	384,12	380,47	285,08	10,60	9,92
2010	385,74	381,86	626,99	10,89	10,09
2011	387,35	383,25	940,14	11,16	10,25
2012	388,96	384,63	1122,99	11,35	10,35
2013	390,58	386,02	1117,56	11,42	10,37
2014	392,19	387,40	928,65	11,37	10,31
2015	393,80	388,79	622,26	11,24	10,19
2016	395,42	390,18	303,61	11,11	10,07
2017	397,03	391,56	82,25	11,04	10,00
Media	389,77	385,33	605,53	11,05	10,13
Maxim	397,03	391,56	1122,99	11,42	10,37
Minim	382,51	379,09	25,82	10,36	9,79

Figura 38. Curbele spectrale ale temperaturilor medii anuale pentru diferite stații meteorologice din România și Europa





Alte cauze posibile sunt ciclurile selenare, spre exemplu cele de 4 și 8 ani (Isaia I., 2002), care induc cicluri corespunzătoare la nivelul undelor mareice, care, mai departe, pot influența undele Rosbby.

De asemenea, activitatea vulcanică joacă cu siguranță un rol important în condiționarea evoluției parametrilor termici, fiind însă greu de cuantificat statistic. Activitatea vulcanică se caracterizează prin perioade de intensificare, care alternează cu perioade de relaxare. Astfel, seria temperaturilor lunare medii maxime de la Iași (Patriche C.V., 2002), seamănă destul de mult cu seria anomaliilor de temperatură și radiație ale emisferei boreale (17-90° lat N), pentru intervalul 1881-1960, descrisă de Budyko M. I. (1974). Autorul explică maximum termic de la sfârșitul secolului al XIX-lea (1890-1900) prin curățirea atmosferei după erupția vulcanului Krakatau (1883). Urmează o scădere a temperaturii, cu un minim în jurul anului 1910, pusă pe seama intensificării activității vulcanice, în acest sens putând fi amintită erupția vulcanului Mont Pellé (1902). În continuare, temperatura intră din nou pe un făgaș ascendent, maximum termic din anii 1930-1940 fiind corelat cu lipsa unor erupții vulcanice importante. Intensificarea poluării aerului cu aerosoli de natură industrială, mai ales cu praf rezultat după exploziile nucleare și mai târziu, erupțiile vulcanice din Alaska, Kamceatka etc., au condus la scăderea temperaturii aerului după 1940, minimum plasându-se în anii '70. În fine, creșterea temperaturii după 1970 ar putea fi asociată efectului de seră.

7.4. Evoluția probabilă a climei în contextul modificărilor climatice globale

Procesul actual de încălzire a climei la nivel global nu poate fi contestat. Incertitudinea constă în rolul pe care îl joacă activitățile umane, cu deosebire efectul de seră indus antropic, în explicarea acestui proces de încălzire.


Două categorii principale de modele pot fi utilizate în scopul prognozei evoluției condițiilor climatice: modelele generale ale circulației globale (GCM), care sunt în esență modele conceptuale și modelele statistice bazate pe modelarea seriilor de timp. Primele realizează, în general, prognoze de lungă durată, ordinul sutelor de ani, în timp ce modelele statistice pot efectua prognoze variabile, în funcție de lungimea seriilor cronologice analizate. În cazul nostru, bazându-ne pe un șir de date de 114 ani, am limitat extrapolarea la o perioadă de 10 ani (2008-2017), pentru un plus de verosimilitate.

Modelele statistice au fost utilizate în lucrarea de față, în 3 variante:


- folosind predictorii (CO₂ atmosferic, numărul anual de pete solare). Rezultatele acestui tip de model au fost deja prezentate;

- folosind componente ciclice identificate prin analiză spectrală (figura 39a). Acest tip de modelare presupune că tendințele identificate în seriile de timp sunt, în fapt, componente cvasi-ciclice cu perioadă lungă. Concret, modelul presupune că tendința de creștere a temperaturii care a demarat în anii 70-80 se mulează, în fapt, pe ramura ascendentă a unui ciclu cu perioadă lungă;
- folosind tendințe și componente ciclice (figura 39b). Acest tip de modelare mulează componentele ciclice pe un fond general de creștere / descreștere a valorilor parametrului analizat. Modelul consideră, prin urmare, că procesul actual de încălzire este rezultatul unei perturbații neperiodice în sistemul climatic.

Figura 39. Modelarea evoluției temperaturilor medii anuale la stația Iași (1894-2007) prin componente ciclice (a) și prin tendință polinomială și componente ciclice (b)



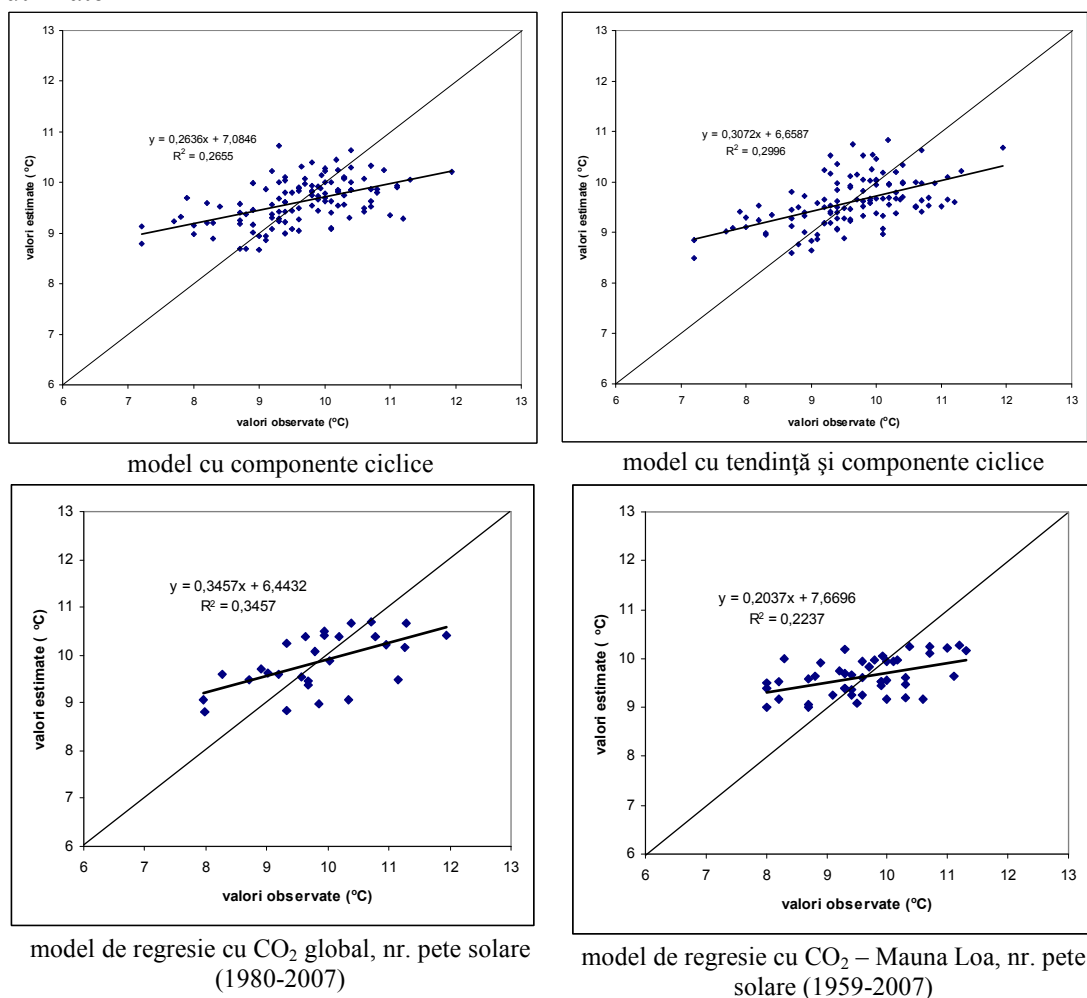
a



b

Prin prisma corelațiilor dintre valorile reale și cele estimate (figura 40) se constată că modelul de regresie cu date de CO₂ global obținut pentru perioada 1980-2007 pare a fi cel mai adecvat, explicând varianța temperaturilor medii anuale în proporție de 34,6%. Trebuie să avem totuși în vedere perioada mai scurtă de analiză. Modelul cel mai slab pare a fi modelul de regresie cu date de CO₂ de la observatorul Mauna Loa. Modelele care includ componente ciclice identificate prin analiză spectrală ocupă un loc intermediar, fiind ușor superior modelul care include tendința polinomială de gradul 2. Deși este mai slab din punct de vedere explicativ, acest model prezintă avantajul de a fi mai stabil, fiind bazat pe un interval de analiză mult mai mare (114 ani).

Figura 40. Corelații între valorile observate și estimate pentru cele 4 modele statistice utilizate



Pe ansamblu însă, modelele au o capacitate destul de scăzută de prognoză, fapt dovedit de valorile reduse ale varianței explicate și orientarea drepte de corelație dintre valorile reale și cele estimate, care în mod ideal ar trebui să urmeze traseul primei bisectoare.

Estimările obținute prin cele 4 metode sunt redată în tabelul 7. Așa cum este firesc, modelul bazat exclusiv pe componente ciclice estimează valorile cele mai mici

(8,9-10,3°C), iar modelul bazat pe creșterea recentă a CO₂ la nivel global estimează valorile cele mai ridicate (10,4-11,4).

Tabelul 7. Valori estimate pentru intervalul de predicție folosind cele 4 modele statistice

Interval predicție	tma estimat - cicluri	tma estimat - tendință, cicluri	tma estimat – predictorii	
			CO ₂ global	CO ₂ Mauna Loa
2008	9,66	10,17	10,36	9,79
2009	8,96	9,50	10,60	9,92
2010	9,40	9,98	10,89	10,09
2011	9,28	9,89	11,16	10,25
2012	10,19	10,83	11,35	10,35
2013	9,61	10,29	11,42	10,37
2014	9,99	10,69	11,37	10,31
2015	10,29	11,03	11,24	10,19
2016	9,43	10,20	11,11	10,07
2017	9,85	10,67	11,04	10,00
Media	9,67	10,33	11,05	10,13
Maxim	10,29	11,03	11,42	10,37
Minim	8,96	9,50	10,36	9,79

Bibliografie

- Anselin L. (2003), *An introduction to variography using Variowin*, University of Illinois.
- Apetrei, M., Groza, O., Grasland, C. (1996) *Elemente de statistică cu aplicații în geografie*, Edit. Univ. „Al. I. Cuza” Iași.
- Barceló A. M. (2001), *Report on rainfall spatialisation*, COST718/WG1, INM, Madrid, 2001, 22 pp.
- Benichou, P., Le Breton, O. (1987), *Prise en compte de la topographie pour la cartographie de champs pluviométriques statistiques*, La Météorologie, 1987, 7, 19, 23-35.
- Burrough P.A., McDonnell R.A. (1998), *Principles of Geographical Information Systems*, Oxford University Press, 1998.
- Cheval S., Baciú M., Breza T. (2003), An investigation into the precipitation conditions in Romania using a GIS-based method, *Theor. Appl. Climatol.* 76, 77–88.
- Ciulache S., Cismaru C. (2000), *Climatic changes in Romania (air temperature)*, *Anal. St. Univ. “Al. I. Cuza” Iași*, tom XLVI, s. II. c., Geografie, p. 37-43.
- Cressie N. (1991), *Statistics for Spatial Data*, Wiley, New York, 1991, 900 pp.
- Daly C., Neilson R.P., Phillips D. L. (1994), *A Statistical-Topographic Model for Mapping Climatological Precipitation over Mountainous Terrain*, *J. Appl. Meteorol.*, 1994, 33, 140–158.
- Dobesch H., Tveito O.E., Bessemoulin P. (2002), *Geographic Information Systems in Climatological Application*, Project no. 5/ECSN, Report no. 13/01, DNMI, Oslo, 49 pp.
- Dobesch H., Dumolard P., Dyras I. (editors, 2007), *Spatial Interpolation for Climate Data. The Use of GIS in Climatology and Meteorology, Chapter 10. Aspects Concerning the Spatialization of Radiation Balance Components – Patriche C.V.*, p. 121-138, , ISTE, 320 pp.
- Dragan J. C., Airinei S. (1993), *Geoclima și istoria*, Edit. Europa Nova, București, 301 pp.
- Dragotă Carmen, Măhăra Gh., Drăgănescu Adriana (2002), *Tendința de evoluție a temperaturii aerului în Depresiunea Sibiului în contextul teoriei privind încălzirea atmosferică globală*, *Lucr. Sem. Geogr. “D. Cantemir”*, nr. 21-22, Univ. “Al. I. Cuza” Iași.
- Erhan Elena (1979), *Clima și microclimatele din zona orașului Iași*, Edit. Junimea, Iași.
- Erhan Elena, Harjoaba I., Patriche C. V. (2007), *The annual precipitations regime in Europe*, *Lucr. Sem. Geografic “Dimitrie Cantemir”*, nr. 27, Univ. „Al. I. Cuza” Iași.

- Haidu I.** (2004), *Modèle de variabilité climatique indépendant de l'échelle temporelle*, Vol. Climat, mémoire du temps. Les relations climat-espace-société. Université de Caen Basse-Normandie, 43-46.
- Haidu I., Mercier J.L.** (2004), *Stochastic way for climate predictability*, The 30-th Congress of the International Geographical Union. Glasgow, CD-ROM.
- Hengl T.** (2007), *A Practical Guide to Geostatistical Mapping of Environmental Variables*, JRC Scientific and Technical Research series, Office for Official Publications of the European Communities, Luxembourg, EUR 22904 EN, 143 pp.
- Isaaks E. H., Strivastava R. M.**, *An Introduction to Applied Geostatistics*, Oxford University Press, 1989, 561 pp.
- Johnston R. J.** (1978), *Multivariate Statistical Analysis in Geography*, Longman, New York.
- Keeling C.D., Whorf T.P., and the Carbon Dioxide Research Group**, Scripps Institution of Oceanography (SIO), University of California, La Jolla, California USA 92093-0444 (<http://cdiac.ornl.gov/ftp/maunaloa-co2/maunaloa.co2>)
- Lhotellier, R.** (2005), *Spatialisation des températures en zone de montagne alpine*, thèse de doctorat, SEIGAD, IGA, Univ. J. Fourier, Grenoble, France, 350 p.
- Lhotellier R., Patriche C. V.** (2005), *Short Term Scientific Mission Report*, COST719.
- Lhotellier R., Patriche C.V.** (2007), *Dérivation des paramètres topographiques et influence sur la spatialisation statistique de la température*, Actes du XXème Colloque de l'Association Internationale de Climatologie, 3-8 septembre 2007, Carthage, Tunisie, p. 357-362
- Marica Adriana, Busuioc Aristita** (2004), *The potential impacts of climate change on the water balance*, COST Action 718 MC meeting – WG 2, 4-5 March 2004, Brussels, Belgium.
- Mudelsee M.** (2000), *Ramp function regression: a tool for quantifying climate transitions*, Computers & Geosciences 26, 2000, 293-307.
- Olaya V.** (2004), *A gentle introduction to SAGA GIS*, Edition 1.1, Rev. December 9.
- Patriche C.V.** (2002), *Long-term annual evolution analysis of air temperature at Iași*, Lucrările Seminarului Geografic „Dimitrie Cantemir”, nr. 21-22, Univ. „Al. I. Cuza” Iași.
- Patriche C.V.** (2003), *Abordarea pe baze statistice a problemei spațializării informației climatice*, în *Indici și metode cantitative utilizate în climatologie* (coord. Sorin Cheval), Edit. Univ. din Oradea, 92-102.
- Patriche C.V.** (2003), *Identificarea tendințelor și ciclicităților în evoluția parametrilor climatici*, în *Indici și metode cantitative utilizate în climatologie*, Cheval S. (coord.), Edit. Universității din Oradea.
- Patriche C.V.** (2004), *Considerații privind abordarea statistică și geoinformațională a cartografiei tematice în climatologie*, Simpoz. „Sisteme informaționale geografice”, 10, supliment. Anal. Șt. Univ. „Al. I. Cuza” Iași, tom L, s. II c., Geogr., 85-92.
- Patriche C.V.** (2005), *Spațializarea precipitațiilor atmosferice folosind regresia multiplă și krigingul rezidual în cadrul SIG*, Simpoz. „Sisteme informaționale geografice”, 11, supliment. Anal. Șt. Univ. „Al. I. Cuza” Iași, tom LI, s. II c., Geogr., 57-70.
- Patriche C.V.** (2005), *Analyse statistique des températures minimums dans les régions de Savoie et Haut Savoie (France)*, An. Șt. Univ. „Al. I. Cuza” Iași, tom LI, s. II c., Geografie, p. 27-34.
- Patriche C.V.** (2005), *Aportul metodelor statistice de interpolare la ameliorarea spațializării parametrilor climatici*, Memoriile Secțiilor Științifice, seria IV, tom XXVIII, Edit. Academiei Române, p. 93-107.
- Patriche C.V.** (2006), *Modélisation de quelques variables agro-climatiques*, Actes du Colloque International: „Observation et analyse des territoires ruraux”, Simona Niculescu (editor), Edit. Sedcom Libris, Iasi, p. 102-120.
- Patriche C.V.** (2007), *About the influence of space scale on the spatialisation of meteo-climatic variables*, Geographia Technica, Nr. 1 / 2007, Cluj University Press.
- Patriche C.V.** (2007), *Spatialisation methods for (agro)climatic and soil parameters at regional and local scales*, Poster Papers Proceedings of the 6th European Conference on Precision Agriculture, 3-6 June 2007, Skiathos, Greece, Fountas S., Gemtos T.A., Aggelopoulou K.D., Blackmore B.S. (editors).
- Patriche C.V., Sfiică L., Roșca B.** (2008), *About the problem of digital precipitations mapping using (geo)statistical methods in GIS*, Geographia Technica, nr. 1, p. 82-91.

- Patriche C.V., Lhotellier R.** (2006), *Possibilities of improving the regression models used for climatic parameters spatialisation. Study case: winter mean minimum temperatures in the French Alps*, An. Șt. Univ. „Al. I. Cuza” Iași, s. II c., Geografie, tom LII, p. 28-39.
- Patriche C.V., Lhotellier, R.** (2008), *Aspects concerning the identification and assessment of the errors affecting statistical spatial models of climatic parameters (abstract)*, European Geosciences Union, Viena, Geophysical Research Abstracts, Vol. 10, EGU2008-A-02355.
- Patriche Emilia-Isabela** (2002), *Considerații asupra regimului termic multianual în Câmpia Moldovei*, Lucrările Seminarului Geografic „Dimitrie Cantemir”, nr. 21-22/2002, Univ. „Al. I. Cuza” Iași.
- Pebesma E. J., Wesseling C. G.** (1998) – *Gstat, a Program for Geostatistical Modelling, Prediction and Simulation*, Computers and Geosciences, 24(1), 17-31.
- Pieter Tans**, NOAA/ESRL (www.esrl.noaa.gov/gmd/ccgg/trends)
- Rădoane M., Rădoane N., Ichim I., Dumitrescu Gh., Ursu C.** (1996), *Analiza cantitativă în geografia fizică*, Edit. Univ. „Al. I. Cuza”, Iași, 249 pp.
- Sfîcă L., Patriche C.V.** (2007), *Global radiation in the Siret corridor. A spatial distribution analysis using GIS methods*, Lucrările Simpozionului International “Sisteme Informaționale Geografice, NR. 13, supl. Anal. Șt. Univ. “Al. I. Cuza” Iași, Tom LIII, s. II c., Geografie, p. 41-46.
- Trebici V.** (coord., 1985), *Mică enciclopedie de statistică*, Ed. Științifică și Enciclopedică, București.
- Tveito O. E.** (2002), *Spatial Distribution of Winter Temperatures in Norway Related to Topography and Large-Scale Atmospheric Circulation*, IAHS PUB KICK-OFF Workshop, Brasilia, 20-22 nov.
- Tveito O. E., Ustrnul Z.** (2003), *A review of the use of large-scale atmospheric circulation classification in spatial climatology*, Report no. 2/WG2 Spatialisation/ COST719, DNMI, Oslo, 2003, 17 pp.
- Tveito O. E., Schöner W.** (2001, editors) – *Applications of Spatial Interpolation of Climatological and Meteorological Elements by the Use of Geographical Information Systems (GIS)*, Report no. 1/WG2 Spatialisation/ COST-719, DNMI, Oslo, 45 pp.
- Tveito O.E., Wegehenkel M., van der Wel F., Dobesch H.** (editors, 2008), *The Use of Geographic Information Systems in Climatology and Meteorology*, COST Action 719 final report, EUR 23461, Luxembourg: Office for Official Publications of the European Communities, ISBN 987-92-898-0045-7, 246 pp.
- Ustrnul Z., Czekierda Danuta** (2005), *Application of GIS for the development of climatological air temperature maps: an example from Poland*, Meteorol. Appl. 12, 2005, 43-50.
- Wilson J.P., Gallant J.C.** (editors, 2000), *Terrain Analysis. Principles and Applications*, John Wiley & Sons Inc., 479 pp.
- *** - *ArcGIS Desktop Help*, <http://webhelp.esri.com/arcgisdesktop/9.2/index.cfm?TopicName=welcome>
- *** - *IDRISI Andes technical support*, <http://www.clarklabs.org/support/IDRISI-Andes-Help-System.cfm>
- *** - *StatSoft Electronic Textbook*, <http://www.statsoft.com/textbook/stathome.html>
- *** - *XLSTAT Tutorial*, <http://www.xlstat.com/en/support/tutorials/>
- *** (1961) *Clima Republicii Populare Române*. Vol. II. Date climatologice, I.M. București.
- *** (2000) – *Reference Manual for the TNT products V6.4*, Lincoln, MicroImages Inc.
- NCDC / World Data Center for Paleoclimatology (<http://www.ncdc.noaa.gov/paleo/forcing.html>)
- NOAA / National Weather Service, Climate Prediction Center (<http://www.cpc.ncep.noaa.gov/data/indices/>)
- <http://www.wetterzentrale.de/klima/index.html>