



**Universitatea
Transilvania
din Brașov**

TEZĂ DE ABILITARE

**Titlu: Utilizarea metodelor moderne de lucru în vederea estimării
susceptibilității la viituri rapide și inundații**

Domeniul: Inginerie Civilă și Instalații

**Autor: CS Dr. Romulus-Dumitru COSTACHE
Institutul Național de Hidrologie și Gospodărire a Apelor**

BRAȘOV, 2026

Cuprins

(A) SUMMARY.....	4
(A) REZUMAT	7
(B) Realizări științifice și profesionale și planuri de evoluție și dezvoltare a carierei.....	10
(B-i) Realizări științifice și profesionale	10
Introducere.....	10
Capitolul 1. Utilizarea Fuzzy-Analytical Hierarchy Process pentru estimarea susceptibilității la inundații	14
1.1. Introducere	14
1.2. Studiu de caz	15
1.3. Date	17
1.4. Metode	23
1.4.1. Linear Support Vector Machine (LSVM)	23
1.4.2. Fuzzy Analytical Hierarchy Process.....	23
1.4.3. Curba ROC – pentru validarea rezultatelor	27
1.5. Rezultate.....	28
1.5.1. Capacitatea de predicție a factorilor geografici	28
1.5.2. Modelarea susceptibilității la inundații rezultate utilizând modelul Fuzzy-AHP.....	29
1.5.3. Validarea rezultatelor	34
1.6. Discuții.....	35
1.7. Concluzii	37
Capitolul 2. Determinarea potențialului de formare a viiturilor rapide prin intermediul metodelor bazate pe arbori de decizie	39
2.1. Introducere	40
2.2. Studiu de caz	41
2.3. Date	42
2.4. Metode	49
2.4.1. Correlation-based feature selection (CFS) pentru selecția predictorilor	49
2.4.2. Weights of Evidence	50
2.4.3. Rotation forest (RF)	52
2.4.4. Logistic Model Tree (LMT)	53
2.4.5. Alternating Decision Tree (ADT)	54
2.4.6. Validarea rezultatelor	55

2.5. Rezultate	55
2.5.1. Capacitatea de predicție a factorilor de condiționare a viiturilor rapide	55
2.5.2. Aplicarea modelului individual Weights of Evidence	56
2.5.3. Aplicarea modelului LMT individual și LMT-WOE hibrid	59
2.5.4. Aplicarea modelului RF individual și a modelului RF-WOE hibrid	62
2.5.5. Aplicarea modelului ADT individual și a modelului ADT-WOE hibrid	64
2.5.6. Validarea rezultatelor	66
2.5.6.1. Densitatea zonelor torențiale în cadrul claselor FFPI	66
2.5.6.2. Curba ROC	67
2.6. Discuții	70
2.7. Concluzii	71
Capitolul 3. Detectarea zonelor susceptibile la viituri rapide în bazine hidrografice mici cu ajutorul inteligenței artificiale	73
3.1. Introducere	73
3.2. Studiu de caz	74
3.3. Date	76
3.4. Metode	79
3.4.1. Evaluarea multicoliniarității	80
3.4.2. Information Gain (IG) pentru estimarea capacității de predicție	80
3.4.3. Statistical Index (SI)	81
3.4.4. Regresia Logistică (Logistic Regression)	82
3.4.5. Classification and regression tree (CART)	83
3.4.6. Multilayer Perceptron (MLP)	83
3.4.7. Random Forest (RAF)	84
3.4.8. Support Vector Machine (SVM)	84
3.5. Configurarea modelelor hibrid pentru calcularea FFPI	85
3.5.1. LR-SI	85
3.5.2. CART-SI	86
3.5.3. MLP-SI	86
3.5.4. RAF-SI	87
3.5.5. SVM-SI	87
3.6. Evaluarea performanțelor modelelor și validarea rezultatelor	88
3.7. Rezultate	88

3.7.1. Evaluarea multicolarității și selectarea factorilor	88
3.7.2. Calcularea Statistical Index	89
3.7.3. Performanțele procesului de modelare	90
3.7.4. Cartografierea Flash-Flood Potential Index (FFPI).....	91
3.7.4.1. Modelul Statistical Index (SI) individual	92
3.7.4.2. Modelul hibrid LR-SI	93
3.7.4.3. Modelul hibrid CART-SI.....	96
3.7.4.4. Modelul hibrid MLP-SI	97
3.7.4.5. Modelul hibrid RAF-SI.....	98
3.7.4.6. Modelul hibrid SVM-SI	99
3.7.5. Validarea rezultatelor	100
3.8. Discuții	101
3.9. Concluzii	103
(B-ii) Planuri de evoluție și dezvoltare a carierei.....	105
Capitolul 4. Evoluția academică anterioară anului 2026.....	105
4.1. Introducere	105
4.2. Studiile universitare absolvite	105
4.3. Activitatea profesională.....	106
4.4. Activitatea de cercetare științifică	107
Capitolul 5. Plan de dezvoltare profesională a carierei universitare.....	110
5.1. Dezvoltarea Direcțiilor de Cercetare Științifică	110
5.2. Carieră academică și dezvoltare didactică	112
5.3. Consolidarea colaborării naționale și internaționale	114
5.4. Vizibilitate și impact științific.....	114
5.5. Obiective pe termen lung.....	115
(B-iii) Bibliografie	116

(A) SUMMARY

The habilitation thesis entitled "Using modern working methods to estimate susceptibility to flash floods and inundations", developed in the field of Civil Engineering and Installations, summarizes the scientific and professional activity carried out by the author in recent years and highlights future research directions. The work is part of a highly topical field, given the increase in the frequency and intensity of extreme hydrological phenomena due to climate change, as well as their significant impact on the environment, infrastructure and society. The general research direction of the present research work refers to the use of modern methods to estimate susceptibility to flash floods and floods.

The thesis is structured according to the requirements of CNATDCU, being organized into two major components: (i) presentation of scientific and professional achievements and (ii) plans for the evolution and development of the academic career. The first part represents the scientific core of the work and includes the results of research published in prestigious journals, indexed in international databases (Web of Science, Q1 and Q2), as well as contributions obtained within national and international research projects.

The introductory chapter presents the general context of the research, highlighting the importance of studying flash floods and floods as some of the most frequent and destructive natural hazards. The need to develop modern and efficient methods for identifying vulnerable areas and supporting the decision-making process in risk management is emphasized. At the same time, the scientific works that underlie the thesis are presented, which constitute the foundation of the author's original contributions.

Chapter 1 addresses the estimation of flood susceptibility using the Fuzzy-Analytical Hierarchy Process (Fuzzy-AHP) method. This approach combines multi-criteria analysis with fuzzy logic, allowing the integration of uncertainty and subjectivity associated with expert judgment. Relevant geospatial data are analyzed, and the results are validated by statistical methods, such as the ROC curve. The study demonstrates that the proposed model provides robust and reliable results, being suitable for mapping flood-prone areas and supporting authorities in decision-making.

Chapter 2 is dedicated to the assessment of flash flood potential using decision tree methods and hybrid models. Techniques such as Weights of Evidence, Logistic Model Tree, Rotation Forest and Alternating Decision Tree are used, in combination with predictor selection methods. The results highlight the superiority of hybrid models over individual models, offering higher predictive capacity and better identification of susceptible areas. Validation of the

models through statistical indicators confirms their accuracy and usefulness in the analysis of hydrological hazards.

Chapter 3 extends the analysis by integrating artificial intelligence and machine learning techniques in the assessment of flash flood susceptibility. Models such as logistic regression, Random Forest, Support Vector Machine, Classification and Regression Tree and artificial neural networks (Multilayer Perceptron) are applied, as well as hybrid combinations thereof. The results show that artificial intelligence-based models, especially hybrid ones, achieve high performance in predicting and mapping vulnerable areas, demonstrating the potential of these techniques in the field of applied hydrology.

An important aspect of the thesis is the rigorous validation of the results, achieved by using ROC curves and other statistical indicators, which gives credibility and robustness to the conclusions obtained. Also, the limitations of the research are discussed, such as the dependence on the quality of the input data or the influence of subjectivity in expert-based methods, and directions for improvement for future research are proposed.

The author's original contributions consist in the development and application of innovative hybrid models for assessing susceptibility to floods and flash floods, the integration of multi-criteria analysis techniques with machine learning methods and the use of complex geospatial data sets. These contributions have been validated through impactful scientific publications and through the practical applicability of the results obtained. The paper also highlights the author's ability to coordinate and implement research projects, as well as to integrate their results into solutions applicable at the institutional level.

From an application point of view, the results of the thesis can be used by institutions such as the National Institute of Hydrology and Water Management and by local and central public authorities, in order to develop early warning systems, evacuation plans and risk reduction strategies. Thus, the thesis contributes not only to the development of scientific knowledge, but also to the improvement of natural hazard management practices.

The second part of the thesis is dedicated to presenting the author's academic and professional development, highlighting the educational path, research activity and achievements. University studies (bachelor, master, doctorate), professional experience and involvement in research and publication activities are presented. This section demonstrates the continuity and coherence of the author's scientific concerns, as well as the consolidation of a solid academic profile.

Finally, the chapter dedicated to the career development plan outlines future research directions, focused on the integration of emerging technologies, such as artificial intelligence, in

the analysis of natural hazards, the development of advanced predictive models and the expansion of international collaborations. The intention to contribute to the development of operational decision support systems and the training of new generations of specialists in the field is also emphasized.

In conclusion, the habilitation thesis demonstrates the scientific maturity of the author and his ability to develop independent and relevant research directions at national and international level. Through its interdisciplinary nature, complex methodological approach and applicability of the results, the work makes significant contributions in the field of hydrological risk assessment and aligns with the requirements and standards imposed by CNATDCU.

(A) REZUMAT

Teza de abilitare intitulată „Utilizarea metodelor moderne de lucru în vederea estimării susceptibilității la viituri rapide și inundații”, elaborată în domeniul Inginerie Civilă și Instalații, sintetizează activitatea științifică și profesională desfășurată de autor în ultimii ani și evidențiază direcțiile viitoare de cercetare. Lucrarea se înscrie într-un domeniu de mare actualitate, având în vedere creșterea frecvenței și intensității fenomenelor hidrologice extreme pe fondul schimbărilor climatice, precum și impactul semnificativ al acestora asupra mediului, infrastructurii și societății. Direcția generală de cercetare din prezenta lucrare se referă la utilizarea metodelor moderne în vederea estimării susceptibilității la viituri rapide și inundații.

Teza este structurată conform cerințelor CNATDCU, fiind organizată în două componente majore: (i) prezentarea realizărilor științifice și profesionale și (ii) planurile de evoluție și dezvoltare a carierei academice. Prima parte reprezintă nucleul științific al lucrării și cuprinde rezultatele cercetărilor publicate în reviste de prestigiu, indexate în baze de date internaționale (Web of Science, Q1 și Q2), precum și contribuțiile obținute în cadrul unor proiecte de cercetare naționale și internaționale.

Capitolul introductiv prezintă contextul general al cercetării, evidențiind importanța studierii viiturilor rapide și a inundațiilor ca unele dintre cele mai frecvente și distructive hazarde naturale. Se subliniază necesitatea dezvoltării unor metode moderne și eficiente pentru identificarea zonelor vulnerabile și pentru sprijinirea procesului decizional în managementul riscurilor. Totodată, sunt prezentate lucrările științifice care stau la baza tezei, acestea constituind fundamentul contribuțiilor originale ale autorului.

Capitolul 1 abordează estimarea susceptibilității la inundații prin utilizarea metodei Fuzzy-Analytical Hierarchy Process (Fuzzy-AHP). Această abordare combină analiza multicriterială cu logica fuzzy, permițând integrarea incertitudinii și a subiectivității asociate judecății experților. Sunt analizate date geospațiale relevante, iar rezultatele sunt validate prin metode statistice, precum curba ROC. Studiul demonstrează că modelul propus oferă rezultate robuste și fiabile, fiind adecvat pentru cartografierea zonelor predispuse la inundații și pentru sprijinirea autorităților în luarea deciziilor.

Capitolul 2 este dedicat evaluării potențialului de formare a viiturilor rapide prin intermediul metodelor bazate pe arbori de decizie și al modelelor hibride. Sunt utilizate tehnici precum Weights of Evidence, Logistic Model Tree, Rotation Forest și Alternating Decision Tree, în combinație cu metode de selecție a predictorilor. Rezultatele evidențiază superioritatea

modelelor hibride în raport cu cele individuale, acestea oferind o capacitate predictivă mai ridicată și o mai bună identificare a zonelor susceptibile. Validarea modelelor prin indicatori statistici confirmă acuratețea și utilitatea acestora în analiza hazardelor hidrologice.

Capitolul 3 extinde analiza prin integrarea tehnicilor de inteligență artificială și învățare automată în evaluarea susceptibilității la viituri rapide. Sunt aplicate modele precum regresia logistică, Random Forest, Support Vector Machine, Classification and Regression Tree și rețele neuronale artificiale (Multilayer Perceptron), precum și combinații hibride ale acestora. Rezultatele arată că modelele bazate pe inteligență artificială, în special cele hibride, ating performanțe ridicate în ceea ce privește predicția și cartografierea zonelor vulnerabile, demonstrând potențialul acestor tehnici în domeniul hidrologiei aplicate.

Un aspect important al tezei îl constituie validarea riguroasă a rezultatelor, realizată prin utilizarea curbelor ROC și a altor indicatori statistici, ceea ce conferă credibilitate și robustețe concluziilor obținute. De asemenea, sunt discutate limitările cercetării, precum dependența de calitatea datelor de intrare sau influența subiectivității în metodele bazate pe expertiză, fiind propuse direcții de îmbunătățire pentru cercetările viitoare.

Contribuțiile originale ale autorului constau în dezvoltarea și aplicarea unor modele hibride inovatoare pentru evaluarea susceptibilității la inundații și viituri rapide, integrarea tehnicilor de analiză multicriterială cu metode de învățare automată și utilizarea unor seturi complexe de date geospațiale. Aceste contribuții au fost validate prin publicații științifice de impact și prin aplicabilitatea practică a rezultatelor obținute. De asemenea, lucrarea evidențiază capacitatea autorului de a coordona și implementa proiecte de cercetare, precum și de a integra rezultatele acestora în soluții aplicabile la nivel instituțional.

Din punct de vedere aplicativ, rezultatele tezei pot fi utilizate de instituții precum Institutul Național de Hidrologie și Gospodărire a Apelor și de autoritățile publice locale și centrale, în vederea dezvoltării sistemelor de avertizare timpurie, a planurilor de evacuare și a strategiilor de reducere a riscurilor. Astfel, teza contribuie nu doar la dezvoltarea cunoașterii științifice, ci și la îmbunătățirea practicilor de management al hazardelor naturale.

A doua parte a tezei este dedicată prezentării evoluției academice și profesionale a autorului, evidențiind parcursul educațional, activitatea de cercetare și realizările obținute. Sunt prezentate studiile universitare (licență, master, doctorat), experiența profesională și implicarea în activități de cercetare și publicare. Această secțiune demonstrează continuitatea și coerența preocupărilor științifice ale autorului, precum și consolidarea unui profil academic solid.

În final, capitolul dedicat planului de dezvoltare a carierei conturează direcțiile viitoare de cercetare, axate pe integrarea tehnologiilor emergente, precum inteligența artificială, în analiza hazardelor naturale, dezvoltarea de modele predictive avansate și extinderea colaborărilor internaționale. Se subliniază, de asemenea, intenția de a contribui la dezvoltarea unor sisteme operaționale de suport decizional și la formarea de noi generații de specialiști în domeniu.

În concluzie, teza de abilitare demonstrează maturitatea științifică a autorului și capacitatea acestuia de a dezvolta direcții de cercetare independente și relevante la nivel național și internațional. Prin caracterul interdisciplinar, abordarea metodologică complexă și aplicabilitatea rezultatelor, lucrarea aduce contribuții semnificative în domeniul evaluării riscurilor hidrologice și se aliniază cerințelor și standardelor impuse de CNATDCU.

(B) Realizări științifice și profesionale și planuri de evoluție și dezvoltare a carierei

(B-i) Realizări științifice și profesionale

Introducere

Aspecte generale

Viiturile rapide și inundațiile reprezintă printre cele mai răspândite hazarde naturale la nivel mondial. Odată cu intensificarea schimbărilor climatice globale, frecvența și severitatea celor 2 hazarde naturale a crescut semnificativ în ultimele decade. Acest fapt este atestat de numeroasele evenimente care s-au produs în ultimii 25 de ani atât la nivel global cât și în România și care au cauzat importante pagube materiale și pierderi de vieți omenești. La nivel global inundațiile sunt responsabile pentru pierderi economice ce totalizează în fiecare an peste 20 de miliarde de euro și pentru pierderea a nu mai puțin de 3000 de vieți omenești (Costache et al., 2020). Conform lui Liu et al. (2022), între 1985 și 2019 cele mai afectate zece țări din lume de inundații au fost: SUA, China, India, Indonezia, Filipine, Australia, Vietnam, Rusia, Brazilia și Bangladesh. În această perioadă, în SUA au avut loc 467 de evenimente semnificative de inundații, în vreme ce China s-a situat pe locul al doilea cu 396 de evenimente semnificative de inundații. Pentru documentare Liu et al. (2022) a folosit baza de date Dartmouth Flood Observatory (DFO) care conține informații la nivel global referitoare la evenimentele semnificative de inundații produse începând cu anul 2019. Sursele de informare pentru baza de date DFO sunt: mass-media, surse guvernamentale sau observații din imagini satelitare și procesări în softuri de teledetecție. În mod particular, pe continental European se așteaptă o creștere de aproximativ 5 ori a pagubelor generate de inundații până în anul 2050 și de 17 ori până în anul 2080 (Costache et al., 2020). Dat fiind faptul că România este una din țările europene cele mai afectate de inundații se poate afirma că previziunile generale referitoare la continental European reflectă o situație foarte îngrijorătoare pentru teritoriul României.

În cazul țării noastre, pentru perioada recentă, anul 2005 a consemnat cele mai grave fenomene de inundații cu un impact devastator asupra comunităților afectate. Astfel, la nivelul întregului teritoriu național, în 2005 s-au înregistrat 6 valuri de inundații în perioada aprilie-septembrie (Săgeată et al., 2013). Principalele zone afectate au fost Banatul și partea de sud-est a României. Conform Administrației Naționale Apele Române, pagubele economice totale au fost de 1,5 miliarde de euro, ceea ce echivala la momentul respectiv cu un procent de 1,5% din Produsul Intern Brut al României. Conform autorităților române, din cauza dezastrelor

provocate de inundații în acel anu, un număr de peste 70 de persoane și-au pierdut viața, au fost afectate circa 93000 de gospodării și inundate 600000 de hectare de teren.

În ceea ce privește viiturile rapide, trebuie menționat faptul că acestea se produc în general în cuprinsul bazinelor hidrografice mici, fiind caracterizate de un timp de creștere între 6 și 9 ore. Acestea sunt provocate de obicei de ploi torențiale manifestate pe o suprafață relativ redusă. Bazinele hidrografice din zona montană, de deal sau podiș sunt cele mai afectate din cauza topografiei caracterizate de o pantă accentuată a reliefului. În ceea ce privește România, cel mai recent eveniment sever de viituri rapide, care s-a soldat inclusiv cu victime omenești, s-a produs în noaptea de 13-14 septembrie 2024 în județele Galați și Vaslui. Fenomenele extreme au cauzat moartea a 6 persoane din cele 2 județe afectate.

Ținând de potențialul distructiv foarte ridicat al celor 2 fenomene naturale care de cele mai multe ori sunt asociate, dezvoltarea unor măsuri de combatere a efectelor negative ale viiturilor rapide și inundațiilor sunt obligatorii. O primă etapă în dezvoltarea și adoptarea unor astfel de măsuri, o reprezintă identificarea zonelor expuse la cele 2 hazarde naturale. La nivel european Directiva Inundații 2007/60/EC stabilește un cadru pentru evaluarea și gestionarea riscurilor de inundații, cu scopul de a reduce consecințele negative pentru sănătatea umană, mediu, patrimoniul cultural și activitatea economică în cadrul Comunității.

În contextul celor expuse mai sus direcția generală de cercetare se referă la utilizarea metodelor moderne în vederea estimării susceptibilității la viituri rapide și inundații. Totodată, menționez că din această direcție generală s-au desprins următoarele 3 subdirecții:

1. Utilizarea combinată a metodelor fuzzy cu cele de tip analiză multicriterială decizională (Fuzzy-Analytical Hierarchy Process) pentru estimarea susceptibilității la inundații;
2. Utilizarea metodelor bazate pe arbori de decizie pentru estimarea susceptibilității la viituri rapide;
3. Utilizarea metodelor bazate pe inteligența artificială pentru estimarea susceptibilității la viituri rapide în bazine hidrografice mici.

Lucrări cuprinse în teza de abilitare

Teza de abilitare este rezultatul activității de cercetare desfășurate după obținerea titlului de doctor conform Ordinului Ministrului Educației Naționale și Cercetării Științifice nr. 3769/20.04.2017. Per ansamblu, teza de abilitare se bazează în principal pe rezultatele obținute în 6 articole științifice publicate în reviste incluse în Q1 și Q2 – Web of Science, din punct de vedere al Factorului de Impact și AIS, precum și pe rezultatele obținute în 2 proiecte de cercetare desfășurate la Universitatea Transilvania din Brașov, după cum urmează:

Articole:

1. **Costache R.** (2019). *Flash-flood Potential Index mapping using weights of evidence, decision Trees models and their novel hybrid integration*. Stochastic Environmental Research and Risk Assessment, 33(7), 1375 – 1402. DOI: <https://doi.org/10.1007/s00477-019-01689-9>. **ISI I.F. = 2.667 (Q1).**
2. **Costache R.** (2019). *Flash-Flood Potential assessment in the upper and middle sector of Prahova river catchment (Romania). A comparative approach between four hybrid models*. Science of The Total Environment, 659, 1115 – 1134. **ISI I.F. = 5.589 (Q1).** DOI: <https://doi.org/10.1016/j.scitotenv.2018.12.397>.
3. **Costache R.,** Popa M.C., Tien Bui D., Diaconu D.C., Ciubotaru N., Minea G., Pham Q.B. (2020) *Spatial predicting of flood potential areas using novel hybridizations of fuzzy decision-making, bivariate statistics, and machine learning*, Journal of Hydrology, 585, 124808. DOI: <https://doi.org/10.1016/j.jhydrol.2020.124808>. **ISI I.F. = 4.5 (Q1).** – **Highly Cited paper – Included in the Top 1% of the academic field of Environment/Ecology according to Web of Science (Clarivate Analytics).**
4. **Costache, R.,** Hong, H., & Pham, Q. B. (2020). *Comparative assessment of the flash-flood potential within small mountain catchments using bivariate statistics and their novel hybrid integration with machine learning models*. Science of the Total Environment, 711, 134514. DOI: <https://doi.org/10.1016/j.scitotenv.2019.134514>. **ISI I.F. = 6.551 (Q1).** – **Highly Cited paper – Included in the Top 1% of the academic field of Environment/Ecology according to Web of Science (Clarivate Analytics).**
5. Abedi R., **Costache R.#,** Shafizadeh-Moghadam H., Pham Q.B. (2022) *Flash-flood susceptibility mapping based on XGBoost, Random Forest and Boosted Regression Trees*, Geocarto International. 37(19), 5479-5496. DOI: <https://doi.org/10.1080/10106049.2021.1920636>. **ISI I.F. = 3.8 (Q2).** (**#co-first author**). - **Highly Cited paper – Included in the Top 1% of the academic field of Geosciences according to Web of Science (Clarivate Analytics). (November/December 2023).**
6. Diaconu D.C., **Costache R.*,** Islam A.R.M.T., Pandey M., Pal S.C., Mishra A.P., Pande C.B. (2024) *Developing flood mapping procedure through optimized machine learning techniques. Case study: Prahova river basin, Romania*, Journal of Hydrology: Regional Studies, 54, 101892, DOI: <https://doi.org/10.1016/j.ejrh.2024.101892>. **ISI I.F. = 5 (Q1).**

Proiecte de cercetare (Director):

- **PN-III-P1-1.1-PD-2019-0424-P** - Analiza integrată a susceptibilității la viituri rapide și inundații la nivelul României utilizând algoritmi de învățare automată și statistici bivariate (acronim: **RO-FLOOD-SUSCEP**); **Contract nr.:** PD226 / 08.04.2021; **Proiect de Cercetare Postdoctorală** finanțat de UEFISCDI prin **Programul 1** - Dezvoltarea sistemului național de cercetare-dezvoltare din **PN III. Perioada:** 08.04.2021 – 31.12.2022.

Director de proiect la Universitatea Transilvania din Brașov.

- **PN-IV-P8-8.1-PRE-HE-ORG-2023-0135** - Tehnologii bazate pe emisii scăzute de carbon rezistente la hazarde multiple, și servicii digitale la scară multiplă destinate unui mediu construit durabil și centrat pe utilizator (acronim: **MULTICARE**); **Contract nr.:** 50PHE / 03.01.2024; **Proiect Premiere Orizont Europa - Instituții** finanțat de UEFISCDI prin **Programul 5.8 - Cooperare Europeană și Internațională** din **PN IV. Perioada:** 03.01.2024 – 31.12.2025.

Director de proiect la Universitatea Transilvania din Brașov.

În continuare, capitolele 1, 2 și 3 constituie nucleul științific al lucrării, fiecare fiind structurat similar: introducere, studiu de caz, date, metode, rezultate, discuții și concluzii. Aceste capitole tratează utilizarea unor metode moderne (precum modelele fuzzy combinate cu analiza multicriterială, arbori de decizie și inteligență artificială) pentru evaluarea susceptibilității la inundații și viituri rapide, evidențiind contribuțiile originale ale autorului. La începutul fiecărui capitol, înaintea secțiunii de Introducere, vor fi menționate explicit lucrările și proiectele de cercetare care au stat la baza realizării acestora.

După partea de cercetare, teza include o secțiune dedicată evoluției academice și profesionale, unde sunt prezentate succint studiile, activitatea științifică precum și experiența acumulată. În final, este inclus un capitol privind planul de dezvoltare a carierei, în care sunt conturate direcțiile viitoare de cercetare și obiectivele pe termen lung.

Scopul principal al tezei este utilizarea unor metode moderne și avansate pentru estimarea susceptibilității la viituri rapide și inundații, contribuind astfel la îmbunătățirea managementului riscurilor naturale. Prin rezultatele obținute, lucrarea urmărește dezvoltarea unor modele predictive eficiente și furnizarea unor instrumente utile pentru autorități în vederea prevenirii și reducerii efectelor acestor fenomene.

În ansamblu, teza îmbină cercetarea aplicată cu perspectiva de dezvoltare academică, având atât valoare științifică, cât și utilitate practică.

Capitolul 1. Utilizarea Fuzzy-Analytical Hierarchy Process pentru estimarea susceptibilității la inundații

Capitolul 1 scoate în evidență modul în care combinarea metodelor de analiză multicriterială decizională cu modelele fuzzy pot ajuta la estimarea susceptibilității la inundații. Acesta este direct relaționat cu prima subdirecție de cercetare din prezenta lucrare. Prezentul capitol s-a bazat pe rezultatele obținute în cadrul articolului științific și al proiectului de cercetare menționate mai jos:

Costache R., Popa M.C., Tien Bui D., Diaconu D.C., Ciubotaru N., Minea G., Pham Q.B. (2020) *Spatial predicting of flood potential areas using novel hybridizations of fuzzy decision-making, bivariate statistics, and machine learning*, Journal of Hydrology, 585, 124808. DOI: <https://doi.org/10.1016/j.jhydrol.2020.124808>.

- **PN-III-P1-1.1-PD-2019-0424-P** - Analiza integrată a susceptibilității la viituri rapide și inundații la nivelul României utilizând algoritmi de învățare automată și statistici bivariate (acronim: **RO-FLOOD-SUSCEP**); **Contract nr.:** PD226 / 08.04.2021; **Proiect de Cercetare Postdoctorală** finanțat de UEFISCDI prin **Programul 1** - Dezvoltarea sistemului național de cercetare-dezvoltare din **PN III. Perioada:** 08.04.2021 – 31.12.2022.

Director de proiect la Universitatea Transilvania din Brașov.

1.1. Introducere

Cartografierea zonelor predispuse la inundații este un pas crucial pentru îmbunătățirea gestionării acestor riscuri și pentru a sprijini autoritățile responsabile de adoptarea măsurilor de apărare împotriva dezastrelor naturale. Aceste hărți pot oferi echipelor de gestionare a situațiilor de urgență informații esențiale pentru dezvoltarea sistemelor de avertizare timpurie, a planurilor de evacuare și a planurilor de pregătire a comunității (Costache, 2025). În acest fel, pierderile materiale și umane pot fi reduse semnificativ.

Una din metodele recunoscute de comunitatea științifică internațională ca fiind rapidă și eficientă în ceea ce privește detectarea zonelor susceptibile la inundații și viituri rapide este Analiza Multicriterială Decizională (AMD) (Akay, 2021). Cel mai răspândit model de AMD este Analytical Hierarchy Process (AHP) sau Procesul Analitic de Ierarhizare. Acesta a fost folosit pe scară largă în vederea estimării susceptibilității la hazarde naturale, atât pe plan național

(Albulescu et al., 2022) cât și pe plan internațional în țări precum: China (Wang et al., 2018), Iran (Shahiri Tabarestani and Afzalimehr, 2022), India (Swain et al., 2020), Arabia Saudită (AlAli et al., 2023), Slovacia (Vojtek and Vojteková, 2019), Tunisia (Hammami et al., 2019), Bangladesh (Kader et al., 2024), Algeria (Bouamrane et al., 2022), Austria (Nachappa et al., 2020), Brazilia (Pimenta et al., 2025), Italia (Varra et al., 2024), SUA (Tikuye et al., 2025), Vietnam (Nguyen et al., 2024), Grecia (Lappas and Kallioras, 2019), Turcia (Yilmaz, 2022), Camerun (Nsangou et al., 2022) etc. Fiind un model bazat pe expert judgment (judecata de expert/opinie de expert), AHP implică un anumit grad de subiectivism în ceea ce privește criteriile de acordare a ponderilor pentru factorii care influențează procesul de inundabilitate sau de formare a viiturilor rapide. Combinarea AHP cu modelul Fuzzy Logic scade gradul de subiectivism în ceea ce privește analiza modului în care variabilele geografice influențează cele 2 hazarde naturale (Costache et al., 2022). Astfel, în ultimii ani, modelul combinat Fuzzy-Analytical Hierarchy Process (Fuzzy-AHP) a devenit din ce în ce mai utilizat pentru determinarea susceptibilității la hazarde naturale (Crăciun et al., 2022; Mokhtari et al., 2024; Shaikh et al., 2024).

Având în vedere cele menționate mai sus în capitolul de față vor fi prezentate rezultatele obținute în urma aplicării modelului combinat Fuzzy-AHP pentru evaluarea susceptibilității la inundații în bazinul hidrografic al râului Buzău.

1.2. Studiu de caz

Bazinul hidrografic al râului Buzău este situat în partea central-sud-estică a României acoperind toate cele trei forme de relief, respectiv munte, deal și câmpie (Fig. 1.1). Zona studiată are o suprafață de 5350 km² și este caracterizată de altitudini cuprinse între 1 m și 1925 m. Prezența unei pante a reliefului care depășește 25° în zona superioară a bazinului, precum și a unei suprafețe plane în zona inferioară a bazinului, evidențiază existența formării atât a viiturilor rapide în zona înaltă cât și posibilitatea propagării acestora și formarea inundațiilor în zona joasă. În conformitate cu clasificarea geologică a zonei studiate, în regiunea montană a zonei pot fi întâlnite depozite de fliș cretacic intern, în timp ce în zona deluroasă predomină depozitele miocene și sarmato-pliocene. Argilele, pietrișurile și nisipurile sunt unele dintre rocile sedimentare comune în regiunea de câmpie. Mai multe fenomene geomorfologice strâns legate de viiturile rapide cum ar fi eroziunea solului și alunecările de teren, au apărut din cauza structurii geologice a zonei și a influenței factorilor exogeni.




Fig. 1.1. Localizarea bazinului hidrografic al râului Buzău în România

Din punct de vedere climatic, zona studiată se caracterizează printr-o medie multianuală de precipitații de aproximativ 750 mm/an. Cu toate acestea, conform lui Minea (2013) precipitația maximă în 24 de ore fost de 115,4 mm și s-a înregistrat la stația meteorologică Lăcăuți pe 12 iulie 1969. Din punct de vedere hidrologic, este de reținut faptul că cele mai mari inundații produse în zona studiată au avut loc în anii 1970, 1975, 2005, 2010, 2016 și 2019 și au afectat numeroase localități, dar și elemente importante de infrastructură, cum ar fi Drumul Național 2 (E85) și Drumul Național 10. Este de reținut faptul că cel mai important eveniment hidrologic s-a produs în anul 1975 și este reprezentat de atingerea debitului maxim al râului Buzău de 2100 m³/s la stația hidrometrică Măgura. Acest eveniment a fost cauzat de ploile torențiale care au căzut pe suprafața de bazin afaltă în amonte de stația hidrometrică Măgura. În ceea ce privește afluenții principali, trebuie menționat că unele dintre cele mai importante inundații au avut loc în anul 2005, când valorile maxime ale debitelor pentru râurile Călnău și Slănic au atins 56,2 m³/s, respectiv 54 m³/s.

O altă variabilă de mediu care afectează puternic potențialul inundabil în zona studiată este utilizarea terenurilor din zonă, fie că este vorba de pădure (40,7%), teren arabil (30,9%) sau zone construite (4,6%).

1.3. Date

Primul set de date colectate pentru studiul de caz se referă la locațiile afectate de inundații în perioada 1970 – 2019. Acestea au fost necesare în vederea validării rezultatelor obținute în urma modelării, dar și pentru testarea abilității de predicție a factorilor geografici în ceea ce privește contribuția la formarea inundațiilor. În total a fost identificat un număr de 205 locații afectate în trecut de inundații. Identificarea acestora s-a bazat pe datele furnizate de Inspectoratul General pentru Situații de Urgență (IGSU) și Administrația Națională Apele Române (ANAR). Pentru o parte din locații s-a făcut și validarea acestora prin utilizarea tehnicilor de teledetecție. Astfel, a fost calculat și utilizat indicele normalizat de diferențiere a zonelor acoperite de apă (NDWI), precum și clasificarea supravegheată a pixelilor în vederea extragerii suprafețelor inundate. Pentru inundațiile anterioare anului 2014 au fost utilizate imaginile Landsat 5, 7 și 8, în timp ce pentru evenimentele de după 2014 au fost utilizate suplimentar imaginile Sentinel 1, 2 și 3. În vederea construirii Ratei de Succes și a Ratei de Predicție, utilizate pentru validarea rezultatelor, eșantionul de 205 locații a fost divizat în două eșantioane diferite: 70% pentru Rata de Succes și 30% pentru Rata de Predicție. De asemenea construirea celor doi indicatori statistici a necesitat crearea unui nou eșantion ce conține alte 205 locații care nu au fost afectate în trecut de inundații. Și acest eșantion suplimentar a fost divizat în două eșantioane diferite: 70% pentru Rata de Succes și 30% pentru Rata de Predicție. Cel de-al doilea set de date utilizat în prezentul studiu de caz a fost format din 12 factori geografici care influențează procesul de apariție a inundațiilor. Procesul de selecție a factorilor de condiționare a inundațiilor este o etapă esențială în generarea rezultatelor analizelor propuse în acest studiu. Selectarea și spațializarea acestora pe zona de studiu s-a făcut în softul ArcGIS 10.8. După o atentă analiză a literaturii de specialitate (Tehrany et al., 2015; Varra et al., 2024) au fost selectați următorii factori de condiționare a inundațiilor: Altitudine, Pantă, Orientarea versanților, Curbura în plan, TPI (Topographic Position Index), TWI (Topographic Wetness Index), Indicele de Convergență (IC) a rețelei hidrografice, Grupa Hidrologică de Sol, Utilizarea terenului, Distanța față de râuri, Precipitațiile și Litologia.

Pentru derivarea unei părți din factorii geografici amintiți a fost folosit un Model Digital de Teren (MDT) extras, pentru zona studiată, din baza de date Shuttle Radar Topography Mission (SRTM), o bază de date de 30 m (Farr et al., 2007). MDT-ul inclus în baza de date SRTM a fost obținut pe baza măsurătorilor efectuate prin interferometrie radar cu apertură sintetică (SAR). Din MDT au fost derivate altitudinea, panta, orientarea pantei, curbura planului, TPI și TWI. Astfel, putem afirma că tehnicile de teledetecție au jucat un rol crucial în obținerea unui MDT

cu o precizie bună și, în consecință, în obținerea celor 6 factori de condiționare a inundațiilor. Panta (Fig. 1.2a) este unul dintre cei mai utilizați și importanți factori, influențând atât scurgerea, cât și procesul de acumulare a apei (Costache et al., 2015; Tien Bui et al., 2019; Zaharia et al., 2017a). Acestea au fost clasificate în 5 clase, clasa între 0 – 3 grade ocupând 35% din suprafață. De asemenea, în aceste zone se regăsesc 65% din locațiile afectate de inundație. Aproximativ 52% din suprafața bazinului este caracterizată de pante cuprinse între 7 și 25 de grade, fiind prezente în partea mijlocie și superioară a bazinului hidrografic.

Curbura în plan (Fig. 1.2b) este un alt factor morfometric cu influență directă în generarea inundațiilor, care ne arată zonele cu scurgere divergentă și convergentă. Pentru această cercetare, acest factor a fost clasificat în 3 clase. Clasa cuprinsă între (-0,09) – 0,1 ocupă 71% din suprafața studiată și este, de asemenea, zona în care se află cele mai multe locații de inundație, 83%.

Un factor de condiționare a inundațiilor foarte important, care are un impact asupra procesului de infiltrare a apei, sunt Grupele Hidrologice de Sol (Fig. 1.2c). Textura lor joacă un rol important în procesul de scurgere. Conform Natural Resources Conservation Service (NRCS, 2009), pe baza texturii lor, solurile au fost împărțite în patru grupe hidrologice, după cum urmează: A, B, C și D. Clasa de sol B este grupa de sol predominantă, ocupând 54% din suprafață și 58% din locațiile de inundație. Atunci când sunt saturate, solurile din grupa B au o conductivitate hidraulică între 10 și 40 $\mu\text{m/s}$, rezultând un potențial de scurgere scăzut. Pe baza caracteristicilor lor, grupa hidrologică de sol A are cel mai scăzut potențial de scurgere și o rată mare de infiltrare atunci când este complet saturată și o conductivitate hidraulică de peste 40 $\mu\text{m/s}$. Solurile din grupa A acoperă 6% din zona studiată. Solurile din grupa C au o conductivitate hidraulică între 1 - 10 $\mu\text{m/s}$ și un potențial de scurgere relativ ridicat. Acestea acoperă 18% din suprafața bazinului hidrografic. Grupa hidrologică de sol D acoperă 22% din suprafață și are cel mai mare potențial de scurgere și o rată de infiltrare scăzută. Conductivitatea hidraulică a solurilor din grupa D este sub 1 $\mu\text{m/s}$.

TPI (Fig. 1.2d) este un factor care arată diferențele de altitudine dintre o anumită celulă și cele vecine (Jenness et al., 2004). Valorile acestui factor morfometric au fost grupate în 5 clase folosind metoda Natural Breaks, conform lucrării lui Costache et al. (2020). Clasa cuprinsă între (-11,4) – (-10,1) ocupă 54% din suprafața bazinului hidrografic al râului Buzău și 37% din locațiile afectate de inundație, în timp ce clasa cuprinsă între (-34,1) – (-11,5) și are 41% din totalul locațiilor afectate de inundație.




Fig. 1.1. Factorii care influențează procesul de formare a inundațiilor: (a) Panta; (b) Curbura în plan; (c) Grupele hidrologice de sol; (d) Topographic Position Index; (e) Topographic Wetness Index; (f) Indicele de convergență a rețelei hidrografice

Topographic Wetness Index (TWI) (Fig. 1.2e) arată tendința unei anumite suprafețe din bazinul hidrografic al unui râu de a acumula apă. Acesta a fost clasificat în 5 clase. Clasa cuprinsă între 3,06 – 4,8 este cea mai răspândită, ocupând 41% din suprafața totală a bazinului hidrografic, în timp ce clasa (-0,37) – 3,05 ocupă 36%. În clasa cuprinsă între 4,81 – 7,02 se află cele mai multe locații afectate de inundație, aproximativ 35%.




Fig. 1.3. Factorii care influențează procesul de formare a inundațiilor: (a) Orientarea versanților; (b) Litologia; (c) Utilizarea terenurilor; (d) Distanța față de râuri; (e) Altitudinea; (f) Precipitațiile

Indicele de Convergență a rețelei hidrografice (Fig. 1.2f) este un factor de condiționare a inundațiilor utilizat în analizele efectuate pentru evaluarea susceptibilității și a fost clasificat în 5 clase așa cum s-a sugerat într-un studiu anterior (Costache, 2019a). Peste 50% dintre locațiile afectate de inundație se încadrează în clasa (100) – (-3). Clasa între 0,1 – 100 reprezintă 50% din suprafața bazinului hidrografic.

Orientarea versanților (Fig. 1.3a) reprezintă un factor de condiționare a inundațiilor, deoarece acesta impune un anumit regim de umiditate a solului. Majoritatea locațiilor afectate de inundație, 18%, se suprapun peste versanții cu orientare estică, în timp ce pe versanții cu

orientare sudică, conțin aproximativ 45% dintre locațiile afectate de inundație. Versanții cu orientare sudică sunt răspândiți pe circa 40% din bazinul hidrografic al râului Buzău.

Litologia (Fig. 1.3b) a fost derivată din Harta Geologică a României (Linzer et al., 1998) și a fost clasificată în 12 categorii de roci. Aproximativ 25% din suprafața bazinului hidrografic este acoperită de fliș, în timp ce aproape 49% din inundații au loc în zonele cu gresii și argile.

Utilizarea terenurilor (Fig. 1.3c) este un alt set de date derivat prin tehnici de teledetecție. Mai precis, în prezentul studiu, utilizarea terenurilor a fost extrasă din baza de date CORINE Land Cover 2018 (Popovici et al., 2013), obținută pe baza clasificării supervizate a imaginilor satelitare. Pentru a obține setul de date CORINE Land Cover, s-au utilizat imagini satelitare Sentinel-2 și Landsat 8. Pentru zona studiată, utilizarea terenurilor a fost clasificată în 9 categorii de utilizare a terenurilor. Terenurile forestiere acoperă 44% din suprafața bazinului hidrografic, fiind urmată de zonele agricole cu 31%. Aproximativ 31% dintre locațiile afectate de inundații se suprapun peste zonele agricole. Distanța față de râuri (Fig. 1.3d) a fost grupată în 8 clase. Peste 56% dintre locațiile afectate în trecut de inundații sunt situați la o distanță mai mică de 50 m de râuri, iar 18% la o distanță cuprinsă între 50 și 100 m.




Fig. 1.4 Distribuția procentuală a locațiilor afectate de inundații în cadrul claselor/categoriilor de factori geografici (a. Panta; b. Curbura în plan; c. Grupa hidrologică de sol; d. TPI; e. TWI; f. Indicele de Convergență a rețelei hidrografice)

Altitudinea (Fig. 1.3e), unul dintre cei mai importanți factori, a fost utilizată și în numeroase studii care au același scop. În prezentul studiu a fost clasificată în 8 clase hipsometrice. Cea mai răspândită clasă în zona studiată este caracterizată de altitudini cuprinse între 2 și 200 m, reprezentând 33% din suprafața bazinului hidrografic, în timp ce aproximativ 65% din locațiile afectate de inundație sunt situate între 2 și 400 m.

Precipitațiile sunt un factor de influență a inundațiilor cu impact direct în geneza acestora (Al-Kindi and Alabri, 2024). Pentru această cercetare, harta precipitațiilor a fost construită folosind datele furnizate de Administrația Națională de Meteorologie. Acest factor a fost clasificat în 8 clase (Fig. 1.3f). Clasa cuprinsă între 600 și 700 mm/an se suprapune peste 30% din locațiile afectate de inundații.

Distribuția procentuală a locațiilor afectate de inundație (flood pixels) pe fiecare clasă sau categorie de factori este prezentată în Figurile 1.4 și 1.5.




Fig. 1.5 Distribuția procentuală a locațiilor afectate de inundații în cadrul claselor/categoriilor de factori geografici (a. Orientarea versanților; b. Litologia; c. Utilizarea terenurilor; d. Distanța față de râuri; e. Altitudinea; f. Precipitațiile)

Pentru a fi mai ușor de prelucrat, datele privind factorii geografici care influențează apariția inundațiilor au fost convertiți în format raster cu o dimensiune a celulei de 30 x 30 m.

1.4. Metode

1.4.1. Linear Support Vector Machine (LSVM)

Linear Support Vector Machine (LSVM) este utilizat în prezentul studiu pentru testarea a factorilor geografici în ceea ce privește capacitatea de predicție în cazul calculării susceptibilității la inundații. Acest pas este foarte util pentru a reduce posibilele incertitudini asociate cu analiza și rezultatele acesteia. Atunci când capacitatea de predicție a unui factor de condiționare a inundațiilor este egală cu 0, acel factor va fi eliminat din analizele ulterioare. Linear Support Vector Machine este o metodă foarte puternică utilizată pentru a estima capacitatea de predicție, deoarece prin rezultatele sale pot fi eliminate variabilele de intrare irelevante și inutile (Costache et al., 2022).

Capacitatea de predicție a fiecărui factor, prin intermediul acestei metode, se evaluează folosind următoarea ecuație:

$$f(x) = \text{sign}(w^T * a + b) \quad (2.1)$$

unde w^T este matricea inversă a matricei de ponderi atribuite fiecărui factor de inundație, $a = (a_1, a_2, \dots, a_{12})$ este vectorul de intrare care conține 12 factori de condiționare a inundației, iar b este deplasarea față de originea hiperplanului (Costache et al., 2020).

Fără îndoială, dacă un factor de condiționare a inundațiilor are o pondere (w) apropiată de 0, acest factor va avea o rată de predicție mai mică decât un factor cu o valoare a ponderii (w) mai mare.

1.4.2. Fuzzy Analytical Hierarchy Process

Fuzzy Analytical Hierarchy Process (FAHP) reprezintă o combinație între teoria mulțimilor fuzzy și algoritmul AHP, menit să crească calitatea analizei prin reducerea subiectivității în procesarea estimării ponderilor criteriale (Feizizadeh et al., 2014). În prezentul studiu, modelul FAHP va fi utilizat pentru a determina ponderile fiecărui factor de condiționare a inundațiilor în cadrul ecuației de susceptibilitate la inundații. Totodată algoritmul AHP de sine stătător va fi utilizat pentru derivarea coeficienților care vor fi atribuiți fiecărei clase/categorii de factori. În continuare, vom prezenta principalele aspecte ale teoriei mulțimilor fuzzy și ale algoritmului AHP, precum și modul în care aceste două modele sunt combinate.

Teoria seturilor Fuzzy

Teoria mulțimilor fuzzy, introdusă de Zadeh (1965), este utilizată în principal în sisteme complexe care permit utilizarea unor informații de intrare imprecise, vagi și ambigue (Balezentiene et al., 2013). În teoria mulțimilor fuzzy, gradul de apartenență este reflectat de un obiect candidat care ia valori de apartenență între 0 și 1.

Conform lui Feizizadeh et al. (2014), o mulțime fuzzy este descrisă după cum urmează: când Z denotă un spațiu de obiecte, atunci mulțimea fuzzy (A) din (Z) este o mulțime de perechi ordonate: $A(z, MF(z))$, $z \in Z$, în timp ce funcția de apartenență $MF(z)$ arată gradul de apartenență al mulțimii A la Z .

Un număr triunghiular fuzzy (TFN) M' este notat printr-un număr de trei parametri: m_1 , m_2 și m_3 (Fig.4b). Primul parametru, m_1 , evidențiază cea mai mică valoare posibilă, m_2 denotă valoarea cea mai promițătoare, în timp ce m_3 indică prezența celei mai mari valori posibile care descrie un obiect fuzzy (Kahraman et al., 2003). Pe baza reprezentării liniare a TFN pe partea stângă și dreaptă a acestuia, funcția sa de apartenență este definită după cum urmează (Kahraman et al., 2003):

$$\mu(x|M') = \begin{cases} 0, & x < m_1 \\ \frac{x-m_1}{m_2-m_1}, & m_1 \leq x \leq m_2 \\ \frac{m_3-x}{m_3-m_2}, & m_2 \leq x \leq m_3 \\ 0, & x > m_3 \end{cases} \quad (1.2)$$

Un număr fuzzy specific este dat de reprezentarea corespunzătoare la stânga și la dreapta a fiecărui grad de apartenență (Kahraman et al., 2003):

$$M' = (M^{l(y)}, M^{r(y)}) = (m_1 + (m_2 - m_1)y, m_3 + (m_2 - m_3)y), y \in [0,1],$$

unde $l(y)$ și $r(y)$ reprezintă reprezentarea din partea stângă, iar partea dreaptă este reprezentarea unui număr fuzzy, respectiv.

Combinarea algoritmului AHP cu Teoria seturilor Fuzzy

Analytical Hierarchy Process (AHP) este un algoritm semicantitativ utilizat frecvent în evaluarea susceptibilității la hazarde naturale (Gigović et al., 2017). Scopul principal al modelului AHP este de a calcula ponderile straturilor relevante ale hărții criteriilor printr-o matrice de comparație pereche construită pe baza cunoștințelor experților. Având în vedere că algoritmul AHP convențional nu poate reflecta stilul de gândire uman, s-a aplicat FAHP, care este o extensie fuzzy a AHP, pentru a rezolva problemele fuzzy ierarhice (Kahraman et al., 2003). Ponderile criteriilor în cadrul modelului FAHP pot fi determinate prin următorii doi pași:

- i) Toți factorii de condiționare ai inundațiilor au fost utilizați pentru a construi matricile de comparație perechi. Pentru a stabili care dintre cele două elemente/criterii este mai

important, au fost atribuiți termeni lingvistici comparației perechi după cum urmează (Feizizadeh et al., 2014):

$$A' = \begin{bmatrix} 1' & a'_{12} & \cdots & a'_{1n} \\ a'_{21} & 1' & \cdots & a'_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a'_{n1} & a'_{n2} & \cdots & 1' \end{bmatrix} = \begin{bmatrix} 1' & a'_{12} & \cdots & a'_{1n} \\ 1/a'_{21} & 1' & \cdots & a'_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 1/a'_{n1} & 1/a'_{n2} & \cdots & 1' \end{bmatrix} \quad (1.3)$$

unde factorul a'_{nij} conține o pereche de criterii i și j , având $1'$ egal cu $(1,1,1)$ unde i este egal cu j (e.g. $i=j$); dacă următoarea înșiruire $1', 2', 3', 4', 5', 6', 7', 8', 9'$ este măsura variabilei i are o importanță relativă mai mare în comparație cu variabila j dacă aceasta este măsurată prin înșiruirea $1/1', 1/2', 1/3', 1/4', 1/5', 1/6', 1/7', 1/8', 1/9'$ (Chen et al., 2013).

Comparația pe perechi între parametrii fuzzy s-a bazat pe numărul triunghiular ale variabilelor lingvistice definite în Tabelul 1.1.

Tabel 1.1 Numărul triunghiular fuzzy ale variabilelor lingvistice (Vahidnia et al., 2009)

Variabile lingvistice	Numere triunghiulare fuzzy	Numere triunghiulare fuzzy reciproce
Extrem de puternic	(9,9,9)	(1/9, 1/9, 1/9)
Foarte puternic	(6,7,8)	(1/8, 1/7, 1/6)
Puternic	(4,5,6)	(1/6, 1/5, 1/4)
Moderat de puternic	(2,3,4)	(1/4, 1/3, 1/2)
La fel de puternic	(1,1,1)	(1,1,1)
Intermediar	(7,8,9), (5,6,7), (3,4,5), (1,2,3)	(1/9, 1/8, 1/7), (1/7, 1/6, 1/5), (1/5, 1/4, 1/3), (1/3, 1/2, 1)

ii) Media geometrică fuzzy și ponderea fuzzy pentru fiecare criteriu au fost calculate prin metoda Buckley (Buckley, 1985) după cum urmează:

$$r'_i = (a'_{i1} \otimes a'_{i2} \otimes \dots \otimes a'_{in})^{1/n}, \text{ și apoi}$$

$$w'_i = r'_i \otimes (r'_1 \otimes \dots \otimes r'_n)^{-1},$$

unde a'_{in} este valoarea fuzzy de comparație dintre perechea criteriu i și criteriul n , r'_i este media geometrică a valorilor fuzzy de comparație pentru criteriul i comparativ cu fiecare dintre celelalte criterii, iar w'_i este ponderarea fuzzy a criteriului i , care poate fi reprezentată și printr-un TFN, $w'_i = (lw_i, mw_i, uw_i)$, unde lw_i , mw_i and uw_i sunt valorile inferioară, medie și superioară ale ponderării fuzzy a criteriului i (Feizizadeh et al., 2014).

Metoda extinsă FAHP

Pentru a determina valorile finale ale ponderilor factorilor care influențează producerea inundațiilor, s-a recurs la aplicarea algoritmului analizei extinse. Primul pas al acestui algoritm

este construirea unei matrice de comparație triunghiulare fuzzy care are următoarea formă (Wang and Chen, 2008):

$$A' = (a'_{ij})_{n \times n} = \begin{bmatrix} (1,1,1) & (l_{12}, m_{12}, u_{12}) & \cdots & (l_{1n}, m_{1n}, u_{1n}) \\ (l_{21}, m_{21}, u_{21}) & (1,1,1) & \cdots & (l_{2n}, m_{2n}, u_{2n}) \\ \vdots & \vdots & \ddots & \vdots \\ (l_{n1}, m_{n1}, u_{n1}) & (l_{n2}, m_{n2}, u_{n2}) & \cdots & (1,1,1) \end{bmatrix} \quad (1.4)$$

unde $a'_{ij} = (l_{ij}, m_{ij}, u_{ij}) = a'^{-1}_{ji} = (1/l_{ji}, 1/m_{ji}, 1/u_{ji})$ for $i, j = 1, \dots, n$ and $i \neq j$.

Se va aplica metoda de analiză extinsă și se va calcula vectorul de prioritate al matricei triunghiulare. Astfel, într-o primă etapă, se va utiliza funcția aritmetică fuzzy pentru a însuma fiecare rând al matricei A' :

$$RS_i = \sum_{j=1}^n a'_{ij} = (\sum_{j=1}^n l_{ij}, \sum_{j=1}^n m_{ij}, \sum_{j=1}^n u_{ij}), \quad i = 1, \dots, n \quad (1.5)$$

Prin normalizarea relației de mai sus, valoarea extinderii sintetice fuzzy în funcție criteriul i poate fi obținută după cum urmează (Roodposhti et al., 2014):

$$S'_i = \sum_j a'_{ij} \otimes [\sum_{k=1}^n \sum_{j=1}^n a'_{kj}]^{-1} = \left(\frac{\sum_{j=1}^n l_{ij}}{\sum_{k=1}^n \sum_{j=1}^n u_{kj}}, \frac{\sum_{j=1}^n m_{ij}}{\sum_{k=1}^n \sum_{j=1}^n m_{kj}}, \frac{\sum_{j=1}^n u_{ij}}{\sum_{k=1}^n \sum_{j=1}^n l_{kj}} \right), \quad i = 1, \dots, n. \quad (1.6)$$

Calculul gradului de posibilitate al lui $S'_i \geq S'_j$ (Fig. 1.6) reprezintă a treia etapă și se realizează prin următoarea formulă:

$$V(S'_i \geq S'_j) = \begin{cases} 1, & \text{if } m_i \geq m_j, \\ \frac{u_i - l_j}{(u_i - m_i) + (m_j - l_j)}, & l_j \leq u_i, \quad i, j = 1, \dots, n; j \neq i \\ 0, & \text{others} \end{cases} \quad (1.7)$$

unde $S'_i = (l, m_i, u_i)$ și $S'_j = (l_j, m_j, u_j)$.




Fig. 1.6. Gradul de posibilitate al lui $S'_i \geq S'_j$; b. Număr triunghiular fuzzy corespunzător variabilelor lingvistice în funcție de nivelul de preferință.

Considerând că:

$$w'(a_i) = \min\{V(S'_i \geq S'_k)\}, \quad k = 1, 2, \dots, n; \quad k \neq i \quad (1.8)$$

Apoi calculul vectorilor de ponderare va fi calculat după cum urmează:

$$w'(a_i) = [w'(a_i), w'(a_i), \dots, w'(a_i)]^T \quad (1.9)$$

După procesul de normalizare, vectorii de ponderare pot fi obținuți folosind următoarea relație:

$$w(a_i) = [w(a_1), w(a_2), \dots, w(a_n)]^T \quad (1.10)$$

unde w este un număr non-fuzzy.

1.4.3. Curba ROC – pentru validarea rezultatelor

Modelul curbei ROC este implicat în procedura de validare a rezultatelor în majoritatea studiilor legate de evaluarea susceptibilității la un hazard natural pentru o anumită zonă (Khosravi et al., 2018; Siahkamari et al., 2018; Termeh et al., 2018). Împreună cu indicatorul său statistic, Aria

de sub Curbă (AUC), Curba ROC este utilizată în principal pentru a evalua capacitatea de discriminare a modelelor statistice care combină diferite rezultate ale testelor în scopuri predictive. În studiul de față, Curba ROC va descrie capacitatea modelelor de a prezice corect apariția fenomenelor de inundații. Reprezentarea Cubei ROC va fi posibilă prin reprezentarea grafică a Sensitivității pe axa Y în funcție de Specificitatea de pe axa X. Cu cât valoarea AUC se apropie mai mult de 1, cu atât modelul este mai bun (Costache et al., 2024). Următoarea ecuație poate fi utilizată pentru a calcula valorile AUC (Chen et al., 2018b):

$$AUC = \frac{(\sum TP + \sum TN)}{(P+N)} \quad (1.11)$$

unde TP (cazurile Adevărat Pozitiv) și TN (cazurile Adevărat Negativ) reprezintă numărul de pixeli clasificați corect d, P este numărul total de locații care au fost afectate de inundație, iar N este numărul total de locații care nu au fost afectate de inundație.

1.5. Rezultate

1.5.1. Capacitatea de predicție a factorilor geografici

Prin utilizarea modelului Linear Support Vector Machine, a fost stabilită ierarhia factorilor geografici în ceea ce privește capacitatea de predicție (CP) a acestora în cazul inundațiilor. Trebuie menționat faptul că în general valorile CP sunt cuprinse între 0 și 1. În cazul de față cea mai ridicată valoare a fost obținută de pantă (0,766), urmată de distanța față de râuri (0,668), TPI (0,495), litologie (0,473), TWI (0,41), indicele de convergență a rețelei hidrografice (0,393), altitudinea (0,356), precipitațiile (0,266), gupa hidrologică de sol (0,138) și orientarea versanților (0,089) (Fig. 1.7).




Fig. 1.7 Valorile capacității de predicție a factorilor geografici în ceea ce privește fenomenul de inundație

Conform rezultatelor prezentate mai sus, toți factorii de condiționare ai inundațiilor au valori ale capacității de predicție mai mari de 0. Prin urmare, toate variabilele vor fi utilizate în analiză pentru a determina susceptibilitatea la inundații.

1.5.2. Modelarea susceptibilității la inundații rezultate utilizând modelul Fuzzy-AHP

Estimarea ponderilor AHP pentru fiecare clasă/categorie de condiționare a inundațiilor a fost primul pas în aplicarea modelului a Fuzzy-AHP. Ponderile AHP incluse în Tabelul 1.2 au fost obținute prin construirea unui număr de 12 matrici de comparație perechi pentru fiecare factor geografic. Cele mai mari valori ale ponderilor AHP (0,587) au fost atribuite clasei de Curbură Plan între 0,11 și 0,48, urmată de grupa hidrologică de sol D (0,582), clasa indicelui de convergență între (-100) și (-3) etc.

Tabel 1.2. Matrice de comparație pe perechi AHP

Factori și clase/categorii	Matrice de comparație pe perechi												Ponderi normalizate
	[1]	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]	
<i>Clasă/categorie</i>													
<i>Panta</i>													
[1] < 3°	1												0.439
[2] 3 – 7°	1/2	1											0.246
[3] 7 – 15°	1/4	1/2	1										0.181
[4] 15 – 25°	1/5	1/3	1/3	1									0.089
[5] > 25°	1/6	1/5	1/6	1/3	1								0.045
<i>TPI</i>													
[1] (-20) – (-3.8)	1												0.458
[2] (-3.7) – (-1.1)	1/2	1											0.258
[3] (-1) – 1.3	1/4	1/2	1										0.158
[4] 1.4 – 4.5	1/6	1/4	1/3	1									0.082
[5] 4.6 – 20	1/7	1/5	1/3	1/3	1								0.045
<i>TWI</i>													
[1] -9.7 – 4.5	1												0.408
[2] 4.6 – 8.4	1/2	1											0.299
[3] 8.5 – 12	1/3	1/2	1										0.159
[4] 13 -15	1/4	1/5	1/2	1									0.084
[5] 16 – 25	1/6	1/6	1/4	1/2	1								0.049
<i>Utilizarea terenurilor</i>													
[1] Zone construite	1												0.241
[2] Zone agricole	1/3	1											0.116
[3] Vii	1/5	1/2	1										0.076
[4] Livezi	1/3	1/3	1/5	1									0.067
[5] Pășuni	1/2	3	4	2	1								0.203
[6] Păduri	1/8	1/5	1/4	1/5	1/5	1							0.023
[7] Pajiști	1/3	1/3	2	2	1/3	5	1						0.070
[8] Mlaștini	1/3	1/3	1/2	1/2	1/4	2	1	1					0.051
[9] Arbuști	1/2	3	4	1/3	1/3	4	2	2	1				0.152
<i>Litologie</i>													
[1] 1	1												0.031
[2] 2	1/2	1											0.076
[3] 3	1	1/3	1										0.094

[4] 4	1/4	2	3	1										0.128
[5] 5	1/8	1/4	1	1/4	1									0.042
[6] 6	1/7	1/4	1	1/3	2	1								0.074
[7] 7	1/6	1	2	1/2	3	1	1							0.064
[8] 8	1/2	6	8	6	9	8	6	1						0.194
[9] 9	1/3	3	5	4	8	6	4	1/3	1					0.095
[10] 10	1/6	2	3	2	4	4	3	1/5	1/2	1				0.084
[11] 11	1/7	1/3	1/2	1/3	1	1/2	1/3	1/9	1/7	1/4	1			0.062
[12] 12	1/9	1/	1/2	1/3	1	1/2	1/3	1/9	1/7	1/4	1	1		0.057
Precipitații														
[1] 460 – 500	1													0.023
[2] 500 - 600	2	1												0.027
[3] 600 - 700	3	3	1											0.048
[4] 700 - 800	4	4	2	1										0.063
[5] 800 - 900	5	5	3	2	1									0.091
[6] 900 - 1000	6	6	4	4	2	1								0.132
[7] 1000 - 1100	7	7	5	6	5	4	1							0.253
[8] 1100 - 1160	8	9	7	8	6	5	2	1						0.362
Curbura în plan														
[1] -11.8 – 0	1													0.089
[2] 0.1 – 0.5	4	1												0.324
[3] 0.6 – 8.5	6	2	1											0.587
Orientarea versanților														
[1] Zone plate	1													0.032
[2] Nord	5	1												0.072
[3] Nord-Est	4	3	1											0.104
[4] Est	4	4	5	1										0.218
[5] Sud-Est	4	3	3	4/5	1									0.164
[6] Sud	5	2	2	5/7	2/3	1								0.144
[7] Sud-Vest	2	4	2/3	3/8	3/4	4/5	1							0.113
[8] Vest	3	5/4	4/3	4/9	2/3	3/5	4/5	1						0.090
[9] Nord-Est	3	1/2	1/3	1/2	1/2	1/3	4/9	2/3	1					0.063
IC														
[1] (-100) – (-3)	1													0.489
[2] (-2.9) – (-2)	1/3	1												0.272
[3] (-1.9) – (-1)	1/4	1/3	1											0.122
[4] (-1) – 0	1/6	1/4	1/2	1										0.074
[5] 0 – 100	1/8	1/7	1/3	1/2	1									0.044
GHS														
[1] A	1													0.072
[2] B	2	1												0.145
[3] C	3	2	1											0.201
[4] D	7	3	5	1										0.582
DFR (m)														
0 – 50	1													0.319
50 – 100	1/2	1												0.226
100 – 150	1/3	1/2	1											0.156
150 – 200	1/4	1/3	1/2	1										0.108
200 – 400	1/5	1/4	1/3	1/2	1									0.068
400 – 700	1/6	1/5	1/4	1/3	1/2	1								0.062
700 – 1000	1/7	1/6	1/5	1/4	1/3	1/4	1							0.038
> 1000	1/7	1/8	1/7	1/6	1/3	1/5	1/4	1						0.022
Altitudinea (m)														
2 – 200	1													0.310
200 – 400	1/2	1												0.208
400 – 600	1/3	1/2	1											0.171

600 – 800	1/4	1/3	1/3	1								0.107
800 – 1000	1/5	1/3	1/4	1/2	1							0.088
1000 – 1200	1/6	1/5	1/5	1/3	1/3	1						0.058
1200 – 1400	1/6	1/6	1/5	1/5	1/4	1/3	1					0.038
> 1400	1/8	1/7	1/6	1/7	1/8	1/7	1/5	1				0.019

*DFR – Distanța față de râuri; TPI – Topographic Position Index; TWI – Topographic Wetness Index; IC – Indicele de Convergență; GHS – Grupa hidrologică de sol.

Construirea matricei fuzzy de comparație pe perechi (Tabelul 1.3) a fost al doilea pas al fluxului de lucru dezvoltat prin intermediul modelului FAHP. Astfel, un număr de 12 criterii (factori geografici de condiționare a inundațiilor) au fost comparate în cadrul matricei.

Tabel 1.3. Matricea de evaluarea Fuzzy-AHP

	1	2	3	4	5	6	7	8	9	10	11	12
Altitudine (1)												
l_1	1	1	1	1	2	0.33	3	1	2	2	4	9
m_1	1	1	1	2	3	0.5	4	2	3	3	5	9
u_1	1	1	1	3	4	1	5	3	4	4	6	9
DFR (2)												
l_2	1	1	1	1	2	0.25	2	1	2	2	3	7
m_2	1	1	1	2	3	0.33	3	2	3	3	4	8
u_2	1	1	1	3	4	0.5	4	3	4	4	5	9
Utilizarea terenurilor (3)												
l_3	1	1	1	1	2	0.33	2	1	3	2	3	7
m_3	1	1	1	2	3	0.5	3	2	4	3	4	8
u_3	1	1	1	3	4	1	4	3	5	4	5	9
GHS (4)												
l_4	0.33	0.33	0.33	1	1	0.16	1	1	1	1	2	5
m_4	0.5	0.5	0.5	1	2	0.2	2	1	2	2	3	6
u_4	1	1	1	1	3	0.25	3	1	3	3	4	7
TPI (5)												
l_5	0.25	0.25	0.25	0.33	1	0.14	1	0.33	1	1	1	2
m_5	0.33	0.33	0.33	0.5	1	0.16	2	0.5	1	1	2	3
u_5	0.5	0.5	0.5	1	1	0.2	3	1	1	1	3	4
Panta (6)												
l_6	1	2	1	4	5	1	5	2	4	3	6	9
m_6	2	3	2	5	6	1	6	3	5	4	7	9
u_6	3	4	3	6	7	1	7	4	6	5	8	9
IC (7)												
l_7	0.2	0.2	0.2	0.33	0.33	0.14	1	0.33	1	1	1	2
m_7	0.25	0.25	0.25	0.5	0.5	0.16	1	0.5	1	1	2	3
u_7	0.33	0.33	0.33	1	1	0.2	1	1	1	1	3	4
Litologie (8)												
l_8	0.33	0.33	0.33	1	1	0.25	1	1	1	2	3	5
m_8	0.5	0.5	0.5	1	2	0.33	2	1	2	3	4	6
u_8	1	1	1	1	3	0.5	3	1	3	4	5	7
TWI (9)												
l_9	0.25	0.25	0.2	0.33	1	0.16	1	0.33	1	1	1	3
m_9	0.33	0.33	0.25	0.2	1	0.2	1	0.5	1	1	2	4
u_9	0.5	0.5	0.33	1	1	0.25	1	1	1	1	3	5
Precipitații (10)												
l_{10}	0.25	0.25	0.25	0.33	1	0.2	1	0.25	1	1	2	4

m_{10}	0.33	0.33	0.33	0.5	1	0.25	1	0.33	1	1	3	5
u_{10}	0.5	0.5	0.5	1	1	0.33	1	0.5	1	1	4	6
Curbura în plan (11)												
l_{11}	0.16	0.2	0.2	0.25	0.33	0.12	0.33	0.33	0.33	0.25	1	2
m_{11}	0.2	0.25	0.25	0.33	0.5	0.14	0.5	0.5	0.5	0.33	1	3
u_{11}	0.25	0.33	0.33	0.5	1	0.16	1	1	1	0.5	1	4
OV (12)												
l_{12}	0.11	0.11	0.11	0.14	0.25	0.11	0.25	0.14	0.2	0.16	0.25	1
m_{12}	0.11	0.12	0.12	0.16	0.33	0.11	0.33	0.16	0.25	0.2	0.33	1
u_{12}	0.11	0.14	0.14	0.2	0.5	0.11	0.5	0.2	0.33	0.25	0.5	1

*DFR – Distanța față de râu; TPI – Topographic Position Index; TWI – Topographic Wetness Index; IC – Indicele de Convergență; GHS – Grupa hidrologică de sol; OV - Orientarea versanților

În plus, valorile sintetice fuzzy, derivate conform metodologiei anterior descrise, au fost calculate pentru a fi incluse în procesul de calcul al ponderilor finale ale predictorilor de inundații. În acest sens, analiza a fost efectuată conform următorilor pași:

$$\left[\sum_{k=1}^n \sum_{j=1}^n a'_{kj} \right]^{-1} = (194.17 \ 254.58 \ 323.77)^{-1} = (0.003 \ 0.004 \ 0.005) \quad (1.12)$$

$S_{\text{Altitudine}} = (27.3 \ 34.5 \ 42) \times (0.003 \ 0.004 \ 0.005) = (0.084 \ 0.135 \ 0.216)$, $S_{\text{DFR}} = (23.25 \ 31.33 \ 38.5) \times (0.003 \ 0.004 \ 0.005) = (0.071 \ 0.123 \ 0.198)$, $S_{\text{Utilizarea terenurilor}} = (24.33 \ 32.5 \ 41) \times (0.003 \ 0.004 \ 0.005) = (0.08 \ 0.13 \ 0.21)$, $S_{\text{GHS}} = (14.16 \ 20.7 \ 28.25) \times (0.003 \ 0.004 \ 0.005) = (0.04 \ 0.08 \ 0.15)$, $S_{\text{TPI}} = (8.55 \ 12.16 \ 18) \times (0.003 \ 0.004 \ 0.005) = (0.03 \ 0.05 \ 0.09)$, $S_{\text{Pantă}} = (43 \ 53 \ 63) \times (0.03 \ 0.05 \ 0.09) = (0.13 \ 0.21 \ 0.32)$, $S_{\text{IC}} = (7.84 \ 10.58 \ 14.53) \times (0.03 \ 0.05 \ 0.09) = (0.02 \ 0.04 \ 0.07)$, $S_{\text{Litologie}} = (16.25 \ 22.83 \ 30.5) \times (0.03 \ 0.05 \ 0.09) = (0.05 \ 0.09 \ 0.16)$, $S_{\text{TWI}} = (9.53 \ 12.11 \ 15.58) \times (0.03 \ 0.05 \ 0.09) = (0.03 \ 0.05 \ 0.08)$, $S_{\text{Precipitații}} = (11.53 \ 14.08 \ 17.33) \times (0.03 \ 0.05 \ 0.09) = (0.04 \ 0.06 \ 0.09)$, $S_{\text{Curbura în plan}} = (5.525 \ 7.5 \ 11.08) \times (0.03 \ 0.05 \ 0.09) = (0.02 \ 0.03 \ 0.06)$, $S_{\text{OV}} = (2.84 \ 3.25 \ 3.99) \times (0.03 \ 0.05 \ 0.09) = (0.01 \ 0.01 \ 0.02)$.

Odată calculate, numerele fuzzy (TFN's) au fost comparate prin intermediul procedurii gradului de posibilitate. Rezultatele acestor comparații sunt introduse în Tabelul 1.4 și au fost utilizate ulterior pentru a determina vectorul de ponderi după cum urmează:

$$w'(a_i) = \{0.53 \ 0.43 \ 0.49 \ 0.09 \ 0.05 \ 1 \ 0.03 \ 0.16 \ 0.07 \ 0.04 \ 0.03 \ 0.02\}^T \quad (1.13)$$

$$w(a_i) = \{0.196 \ 0.157 \ 0.179 \ 0.033 \ 0.018 \ 0.367 \ 0.011 \ 0.058 \ 0.025 \ 0.146 \ 0.011 \ 0.007\}^T \quad (1.14)$$

Table 1.4. Ordonata celui mai înalt punct de intersecție, gradului de posibilitate pentru TFN-uri și ponderile factorilor geografici

Altitudine = 1	DFR = 2	Utilizarea terenurilor = 3	GHS = 4
$V(S_1 \geq S_2) = 1$	$V(S_2 \geq S_1) = 0.9$	$V(S_3 \geq S_1) = 0.94$	$V(S_4 \geq S_1) = 0.52$
$V(S_1 \geq S_3) = 1$	$V(S_2 \geq S_3) = 0.96$	$V(S_3 \geq S_2) = 1$	$V(S_4 \geq S_2) = 0.64$
$V(S_1 \geq S_4) = 1$	$V(S_2 \geq S_4) = 1$	$V(S_3 \geq S_4) = 1$	$V(S_4 \geq S_3) = 0.6$
$V(S_1 \geq S_5) = 1$	$V(S_2 \geq S_5) = 1$	$V(S_3 \geq S_5) = 1$	$V(S_4 \geq S_5) = 1$
$V(S_1 \geq S_6) = 0.53$	$V(S_2 \geq S_6) = 0.43$	$V(S_3 \geq S_6) = 0.49$	$V(S_4 \geq S_6) = 0.09$
$V(S_1 \geq S_7) = 1$	$V(S_2 \geq S_7) = 1$	$V(S_3 \geq S_7) = 1$	$V(S_4 \geq S_7) = 1$
$V(S_1 \geq S_8) = 1$	$V(S_2 \geq S_8) = 1$	$V(S_3 \geq S_8) = 1$	$V(S_4 \geq S_8) = 0.91$

$V(S_1 \geq S_9) = 1$	$V(S_2 \geq S_9) = 1$	$V(S_3 \geq S_9) = 1$	$V(S_4 \geq S_9) = 1$
$V(S_1 \geq S_{10}) = 1$	$V(S_2 \geq S_{10}) = 1$	$V(S_3 \geq S_{10}) = 1$	$V(S_4 \geq S_{10}) = 1$
$V(S_1 \geq S_{11}) = 1$	$V(S_2 \geq S_{11}) = 1$	$V(S_3 \geq S_{11}) = 1$	$V(S_4 \geq S_{11}) = 1$
$V(S_1 \geq S_{12}) = 1$	$V(S_2 \geq S_{12}) = 1$	$V(S_3 \geq S_{12}) = 1$	$V(S_4 \geq S_{12}) = 1$
$\min \{V(S_1 \geq S_k)\} = 0.53$	$\min \{V(S_2 \geq S_k)\} = 0.43$	$\min \{V(S_3 \geq S_k)\} = 0.49$	$\min \{V(S_4 \geq S_k)\} = 0.09$
Weight = 0.196	Weight = 0.157	Weight = 0.179	Weight = 0.033
TPI = 5	Panta = 6	Indicele de convergență = 7	Lithologie = 8
$V(S_5 \geq S_1) = 0.08$	$V(S_6 \geq S_1) = 1$	$V(S_7 \geq S_1) = 0.04$	$V(S_8 \geq S_1) = 0.61$
$V(S_5 \geq S_2) = 0.21$	$V(S_6 \geq S_2) = 1$	$V(S_7 \geq S_2) = 0.03$	$V(S_8 \geq S_2) = 0.71$
$V(S_5 \geq S_3) = 0.18$	$V(S_6 \geq S_3) = 1$	$V(S_7 \geq S_3) = 0.05$	$V(S_8 \geq S_3) = 0.68$
$V(S_5 \geq S_4) = 0.59$	$V(S_6 \geq S_4) = 1$	$V(S_7 \geq S_4) = 0.44$	$V(S_8 \geq S_4) = 1$
$V(S_5 \geq S_6) = 0.05$	$V(S_6 \geq S_5) = 1$	$V(S_7 \geq S_5) = 0.88$	$V(S_8 \geq S_5) = 1$
$V(S_5 \geq S_7) = 1$	$V(S_6 \geq S_7) = 1$	$V(S_7 \geq S_6) = 0.06$	$V(S_8 \geq S_6) = 0.16$
$V(S_5 \geq S_8) = 0.5$	$V(S_6 \geq S_8) = 1$	$V(S_7 \geq S_8) = 0.34$	$V(S_8 \geq S_7) = 1$
$V(S_5 \geq S_9) = 1$	$V(S_6 \geq S_9) = 1$	$V(S_7 \geq S_9) = 0.88$	$V(S_8 \geq S_9) = 1$
$V(S_5 \geq S_{10}) = 0.88$	$V(S_6 \geq S_{10}) = 1$	$V(S_7 \geq S_{10}) = 0.74$	$V(S_8 \geq S_{10}) = 1$
$V(S_5 \geq S_{11}) = 1$	$V(S_6 \geq S_{11}) = 1$	$V(S_7 \geq S_{11}) = 1$	$V(S_8 \geq S_{11}) = 1$
$V(S_5 \geq S_{12}) = 1$	$V(S_6 \geq S_{12}) = 1$	$V(S_7 \geq S_{12}) = 1$	$V(S_8 \geq S_{12}) = 1$
$\min \{V(S_5 \geq S_k)\} = 0.05$	$\min \{V(S_6 \geq S_k)\} = 1$	$\min \{V(S_7 \geq S_k)\} = 0.03$	$\min \{V(S_8 \geq S_k)\} = 0.16$
Weight = 0.018	Weight = 0.367	Weight = 0.011	Weight = 0.058
TWI = 9	Precipitații = 10	Curbura în plan = 11	OV = 12
$V(S_9 \geq S_1) = 0.09$	$V(S_{10} \geq S_1) = 0.05$	$V(S_{11} \geq S_1) = 0.03$	$V(S_{12} \geq S_1) = 0.07$
$V(S_9 \geq S_2) = 0.1$	$V(S_{10} \geq S_2) = 0.2$	$V(S_{11} \geq S_2) = 0.06$	$V(S_{12} \geq S_2) = 0.04$
$V(S_9 \geq S_3) = 0.05$	$V(S_{10} \geq S_3) = 0.16$	$V(S_{11} \geq S_3) = 0.04$	$V(S_{12} \geq S_3) = 0.02$
$V(S_9 \geq S_4) = 0.51$	$V(S_{10} \geq S_4) = 0.63$	$V(S_{11} \geq S_4) = 0.23$	$V(S_{12} \geq S_4) = 0.03$
$V(S_9 \geq S_5) = 0.99$	$V(S_{10} \geq S_5) = 1$	$V(S_{11} \geq S_5) = 0.62$	$V(S_{12} \geq S_5) = 0.05$
$V(S_9 \geq S_6) = 0.07$	$V(S_{10} \geq S_6) = 0.04$	$V(S_{11} \geq S_6) = 0.03$	$V(S_{12} \geq S_6) = 0.03$
$V(S_9 \geq S_7) = 1$	$V(S_{10} \geq S_7) = 1$	$V(S_{11} \geq S_7) = 0.73$	$V(S_{12} \geq S_7) = 0.04$
$V(S_9 \geq S_8) = 0.41$	$V(S_{10} \geq S_8) = 0.53$	$V(S_{11} \geq S_8) = 0.1$	$V(S_{12} \geq S_8) = 0.08$
$V(S_9 \geq S_{10}) = 0.85$	$V(S_{10} \geq S_9) = 1$	$V(S_{11} \geq S_9) = 0.6$	$V(S_{12} \geq S_9) = 0.02$
$V(S_9 \geq S_{11}) = 1$	$V(S_{10} \geq S_{11}) = 1$	$V(S_{11} \geq S_{10}) = 0.45$	$V(S_{12} \geq S_{10}) = 0.13$
$V(S_9 \geq S_{12}) = 1$	$V(S_{10} \geq S_{12}) = 1$	$V(S_{11} \geq S_{12}) = 1$	$V(S_{12} \geq S_{11}) = 0.17$
$\min \{V(S_9 \geq S_k)\} = 0.07$	$\min \{V(S_{10} \geq S_k)\} = 0.04$	$\min \{V(S_{11} \geq S_k)\} = 0.03$	$\min \{V(S_{12} \geq S_k)\} = 0.02$
Weight = 0.025	Weight = 0.146	Weight = 0.011	Weight = 0.007

*DFR – Distanța față de râuri; TPI – Topographic Position Index; TWI – Topographic Wetness Index; GHS – Grupa hidrologică de sol; OV - Orientarea versanților

Astfel, prin procesul de defuzzificare, TFN-urile au fost convertite în valori ale ponderilor precise, care vor fi ulterior atribuite fiecărui factor geografic pentru a estima susceptibilitatea la inundații. Valorile Indicelui de Susceptibilitate la Inundații (ISI) au fost obținute prin înmulțirea valorilor ponderilor precise cu coeficienții AHP (Fig. 1.8). Valorile ISI pe suprafața bazinului hidrografic al râului Buzău sunt cuprinse între 0,04 și 0,81. Ecartul de valori ale ISI Fuzzy-AHP a fost împărțit în cinci clase utilizându-se metoda de clasificare *Natural Breaks (Pragurilor Naturale)*. Astfel, valorile foarte scăzute ale ISI sunt cuprinse între 0,04 și 0,17 și ocupă circa 17,51% din bazinul hidrografic al râului Buzău. Conform Fig. 1.8, acestea ocupă suprafețe extinse în bazinul superior și mijlociu. Un grad de susceptibilitate scăzut la inundații se înregistrează pe o suprafață echivalentă cu 32,09% din total zonei de studiu. Din nou prezența acestor areale se remarcă în partea superioară și mijlocie a bazinului hidrografic al râului Buzău, acolo unde există un grad ridicat de împădurire și pante accentuate ce nu favorizează acumularea apei din precipitații. Valorile medii ale ISI sunt răspândite pe 33,86% din zona supusă cercetării.




Fig. 1.8 Valorile Indicelui de Susceptibilitate la Inundații (ISI) rezultat în urma aplicării Fuzzy-AHP

După cum se observă în Fig. 1.8, se remarcă o prezență predominantă a acestora în partea inferioară a bazinului hidrografic care se suprapune peste zona de câmpie. Deși valorile de pantă sunt apropiate de 0°, distanța mare față de cursurile de apă nu favorizează prezența unui grad de susceptibilitate ridicat sau foarte ridicat în cuprinsul zonelor amintite anterior. În schimb, în restul de bazin hidrografic ce însumează o pondere de 16,53% se înregistrează valori mari și foarte mari ale ISI (Fig. 1.9). Aceste areale sunt prezente în zonele cu pante reduse din lungul principalelor văi sau depresiuni.




Fig. 1.9 Ponderile procentuale ale claselor Indicelui de Susceptibilitate la Inundații (ISI)

1.5.3. Validarea rezultatelor

După cum s-a menționat la punctul 2.4.4. validarea rezultatelor s-a făcut atât prin metoda Curbei ROC. Conform Fig. 1.10 (a și b), în cazul Curbei ROC a fost reprezentată atât Rata de

Succes cât și Rata de Predicție. Pentru ambele variante ale Curbei ROC rezultatele au evidențiat înregistrarea unor performanțe foarte bune deoarece indicatorul AUC are valori de peste 0,9.




Fig. 1.10 Curba ROC pentru validarea rezultatelor ((a) Rata de Succes; (b) Rata de Predicție)

1.6. Discuții

Rezultatele FAHP indică faptul că panta este cel mai influent factor care controlează susceptibilitatea la inundații, cu o pondere de 0,367. Acest rezultat este în concordanță cu rolul fundamental al morfologiei terenului în procesele hidrologice, deoarece panta influențează direct viteza de scurgere, capacitatea de infiltrare și acumularea de apă. În zonele cu pantă mică, apa tinde să stagneze, crescând probabilitatea de inundații, în timp ce pantele abrupte facilitează drenajul rapid. Constatări similare au fost raportate pe scară largă în studii care aplică FAHP pentru cartografierea susceptibilității la inundații, unde panta este frecvent clasată ca factor dominant, în special în bazinele caracterizate de o variabilitate topografică semnificativă.

Utilizarea terenurilor reprezintă un alt factor semnificativ, cu o pondere de 0,179. Aceasta reflectă influența puternică a activităților umane asupra răspunsurilor hidrologice. Zonele caracterizate de suprafețe construite și practici agricole prezintă de obicei o capacitate de infiltrare redusă și o scurgere de suprafață crescută, sporind astfel riscul de inundații. În schimb,

zonele împădurite contribuie la retenția apei, interceptare și evapotranspirație, reducând susceptibilitatea la inundații. Importanța utilizării terenurilor a fost subliniată în mod constant în studiile bazate pe FAHP (Ekmekcioğlu et al., 2021; Yang et al., 2013), unde este adesea clasată printre principalii factori care contribuie, în special în regiunile care trec prin schimbări rapide ale utilizării terenurilor.

Metodologia FAHP în sine reprezintă un progres semnificativ față de AHP tradițional prin încorporarea numerelor triunghiulare fuzzy (TFN) pentru a gestiona incertitudinea în comparațiile perechi. În modelarea mediului, unde judecata experților joacă un rol central, incertitudinea este inevitabilă. Utilizarea logicii fuzzy permite o reprezentare mai flexibilă a preferințelor, reducând rigiditatea asociată cu valorile numerice precise. Acest lucru are ca rezultat o schemă de ponderare mai robustă și mai fiabilă. Avantaje similare au fost evidențiate în studiile anterioare care utilizează FAHP, demonstrând o consistență îmbunătățită și o eroare redusă în comparație cu abordările AHP clasice (Senan et al., 2023).

Distribuția spațială a Indicelui de Susceptibilitate la Inundații (ISI) oferă o perspectivă mai profundă asupra performanței modelului. Rezultatele arată că clasele de susceptibilitate scăzută (32,09%) și medie (33,86%) domină zona studiată, în timp ce zonele de susceptibilitate ridicată și foarte ridicată reprezintă 16,53% din bazin. Aceste zone cu risc ridicat sunt concentrate în principal în regiuni joase, în special de-a lungul văilor și depresiunilor principale ale râurilor, unde acumularea de apă este mai probabilă.

În schimb, zonele clasificate ca având susceptibilitate foarte scăzută (17,51%) sunt situate predominant în părțile superioare și mijlocii ale bazinului. Aceste regiuni sunt caracterizate de pante mai abrupte și o acoperire forestieră mai mare, ceea ce favorizează scurgerea rapidă a apelor și reduce retenția de apă. O astfel de diferențiere spațială evidențiază influența combinată a topografiei și a acoperirii terestre asupra susceptibilității la inundații și confirmă capacitatea modelului FAHP de a surprinde cu exactitate aceste interacțiuni.

Validarea rezultatelor folosind curbe ROC (rata de succes și rata de predicție) și indicatori statistici confirmă fiabilitatea modelului. Deși valorile specifice de precizie nu sunt detaliate aici, adoptarea mai multor tehnici de validare indică un proces riguros de evaluare. În literatura de specialitate mai largă, modelele de susceptibilitate la inundații bazate pe FAHP obțin, în general, performanțe predictive bune, în special atunci când sunt susținute de o selecție atentă a factorilor și de proceduri de ponderare consecvente.

Cu toate acestea, trebuie recunoscute câteva limitări. Abordarea FAHP se bazează pe judecata experților, care poate introduce subiectivitate în ciuda utilizării logicii fuzzy. În plus, calitatea

rezultatelor depinde de acuratețea și rezoluția datelor de intrare. Cercetările viitoare ar putea îmbunătăți modelul prin încorporarea unor factori suplimentari, a unor seturi de date cu rezoluție mai mare sau prin combinarea FAHP cu alte tehnici în cadre hibride.

În concluzie, abordarea bazată pe FAHP aplicată în acest studiu oferă o evaluare fiabilă și cuprinzătoare a susceptibilității la inundații. Rezultatele sunt în concordanță cu cele raportate în studii similare și evidențiază rolul dominant al factorilor topografici, hidrologici și de utilizare a terenurilor în controlul dinamicii inundațiilor. Integrarea Fuzzy Logic cu AHP sporește robustețea modelului, făcându-l un instrument valoros pentru evaluarea riscului de inundații și luarea deciziilor în contexte geografice similare.

1.7. Concluzii

Capitolul 1 demonstrează că integrarea Procesului Ierarhic Analitic cu metoda Fuzzy (AHP-Fuzzy) reprezintă o abordare robustă și eficientă pentru evaluarea susceptibilității la inundații în medii geografice complexe. Prin combinarea punctelor forte ale AHP-ului clasic cu logica fuzzy, metodologia propusă reduce cu succes subiectivitatea inerentă asociată cu ponderarea bazată pe experți, menținând în același timp un cadru decizional structurat. Rezultatele confirmă faptul că susceptibilitatea la inundații este controlată de o combinație de factori topografici, hidrologici și de utilizare a terenurilor, panta, distanța față de râuri și caracteristicile solului apărând ca predictorii cheie.

Aplicarea modelului în mai multe bazine hidrografice din România evidențiază adaptabilitatea și fiabilitatea acestuia în diferite condiții geomorfologice și climatice. Validarea folosind curbe ROC și alți indicatori statistici confirmă capacitatea predictivă puternică a modelului, demonstrând consecvența cu constatările raportate în literatura internațională. Acest lucru întărește caracterul adecvat al AHP-ului Fuzzy ca instrument de asistență decizională pentru managementul riscului la inundații.

Cu toate acestea, studiul recunoaște și câteva limitări. Bazarea pe judecata experților, chiar și atunci când este moderată de logica fuzzy, introduce un grad de subiectivitate care poate influența schema finală de ponderare. În plus, acuratețea rezultatelor este strâns legată de calitatea și rezoluția spațială a datelor de intrare, subliniind importanța seturilor de date geospațiale de înaltă calitate.

Per total, capitolul contribuie semnificativ la domeniu prin furnizarea unui cadru metodologic cuprinzător pentru cartografierea susceptibilității la inundații. Integrarea logicii fuzzy sporește robustețea modelului, în timp ce structura multicriterială asigură transparența și

interpretabilitatea. Rezultatele au implicații practice directe, sprijinind autoritățile în planificarea utilizării terenurilor, atenuarea riscurilor și prevenirea dezastrelor. Direcțiile de cercetare viitoare includ încorporarea de seturi de date cu rezoluție mai mare și dezvoltarea de modele hibride care combină Fuzzy-AHP cu tehnici de învățare automată pentru a îmbunătăți și mai mult performanța predictivă.

Capitolul 2. Determinarea potențialului de formare a viiturilor rapide prin intermediul metodelor bazate pe arbori de decizie

Capitolul 2 abordează problematica determinării potențialului de formare a viiturilor rapide cu ajutorul modelelor din categoria arborilor de decizie, fiind asociat cu cea de-a doua subdirecție de cercetare din prezenta lucrare. Studiul de caz din acest capitol în reprezintă zona mijlocie și superioară a bazinului hidrografic Prahova. Acest capitol s-a bazat pe rezultatele obținute în cadrul a trei articole științifice și două proiect de cercetare, acestea fiind menționate mai jos:

Costache R. (2019). *Flash-flood Potential Index mapping using weights of evidence, decision Trees models and their novel hybrid integration*. Stochastic Environmental Research and Risk Assessment, 33(7), 1375 – 1402. DOI: <https://doi.org/10.1007/s00477-019-01689-9>.

Costache R. (2019). *Flash-Flood Potential assessment in the upper and middle sector of Prahova river catchment (Romania). A comparative approach between four hybrid models*. Science of The Total Environment, 659, 1115 – 1134. DOI: <https://doi.org/10.1016/j.scitotenv.2018.12.397>.

Diaconu D.C., **Costache R.***, Islam A.R.M.T., Pandey M., Pal S.C., Mishra A.P., Pande C.B. (2024). *Developing flood mapping procedure through optimized machine learning techniques. Case study: Prahova river basin, Romania*, Journal of Hydrology: Regional Studies, 54, 101892, DOI: <https://doi.org/10.1016/j.ejrh.2024.101892>.

- **PN-III-P1-1.1-PD-2019-0424-P** - Analiza integrată a susceptibilității la viituri rapide și inundații la nivelul României utilizând algoritmi de învățare automată și statistici bivariate (acronim: **RO-FLOOD-SUSCEP**); **Contract nr.:** PD226 / 08.04.2021; **Proiect de Cercetare Postdoctorală** finanțat de UEFISCDI prin **Programul 1** - Dezvoltarea sistemului național de cercetare-dezvoltare din **PN III**. **Perioada:** 08.04.2021 – 31.12.2022.

Director de proiect la Universitatea Transilvania din Brașov.

- **PN-IV-P8-8.1-PRE-HE-ORG-2023-0135** - Tehnologii bazate pe emisii scăzute de carbon rezistente la hazarde multiple, și servicii digitale la scară multiplă destinate unui mediu construit durabil și centrat pe utilizator (acronim: **MULTICARE**); **Contract nr.:** 50PHE / 03.01.2024; **Proiect Premiere Orizont Europa - Instituții** finanțat de UEFISCDI prin **Programul 5.8 - Cooperare Europeană și Internațională** din **PN IV**. **Perioada:** 03.01.2024 – 31.12.2025.

Director de proiect la Universitatea Transilvania din Brașov.

2.1. Introducere

În vederea obținerii unor prognoze cât mai precise în ceea ce privește viiturile rapide este necesară o evaluare cât mai detaliată, în prealabil, a zonelor expuse la manifestarea scurgerii rapide de suprafață. O metodă foarte utilizată în acest sens este cea a indicelui Flash-Flood Potential Index (FFPI). Marele neajuns al metodei propusă inițial este acela că pentru calcularea FFPI, factorilor geografici le este acordată o pondere egală. Mai mult, în cadrul metodei inițiale de predicție a zonelor potențial afectate de scurgerea de suprafață, nu sunt luate în considerare suprafețele afectate în trecut de fenomenele de torențialitate. Ponderarea factorilor geografici, cât și considerarea zonelor deja afectate de fenomene este exemplificată în foarte multe studii din literatura internațională care se referă la evaluarea susceptibilității la apariția diverselor hazarde naturale precum inundațiile (Chapi et al., 2017; Shahiri Tabarestani and Afzalimehr, 2022) și alunecările de teren (Dou et al., 2015). Dintre metodele aplicate în cadrul acestor studii se remarcă: frequency ratio (Sewa et al., 2026; Tariq et al., 2022), weights of evidence (Saha et al., 2022), regresia logistică (Demissie et al., 2024; Yaseen et al., 2022), arbori de decizie (Sarwar et al., 2025), rețele neuronale artificiale (Ghobadi and Ahmadipari, 2024), naïve bayes (Saravanan and Abijith, 2022).

Ca urmare a faptului că România, este una din țările europene cele mai afectate de viituri rapide (Hanger et al., 2018; Romanescu et al., 2018), studiile referitoare la evaluarea susceptibilității la aceste fenomene de risc sunt extrem de utile în vederea întocmirii planurilor de management al riscului la inundații precum și în cadrul activității de prognoză și avertizare. Una din cele mai afectate zone la producerea viiturilor rapide este bazinului hidrografic al râului Prahova. Vulnerabilitatea ridicată a acestei zone este dată și de faptul că este una din cele mai dezvoltate regiuni ale României din punct de vedere economic. Inundațiile generate de viituri rapide care s-au produs în ultimii ani au provocat pagube materiale importante în special asupra infrastructurii din zonă. În cadrul studiului de față se are în vedere evaluarea potențialului la viituri rapide al suprafețelor aflate în perimetrul zonei mai sus menționate. În acest sens vor fi utilizate tehnici specifice domeniului machine learning, al statisticilor bivariate precum și integrare a acestora în mai multe modele hibride. Din sfera machine learning au fost selectate tehnicile bazate pe arbori de decizie precum: Rotation Forest, Alternating Decision Tree și Logistic Model Tree; în vreme ce din categoria statisticilor bivariate a fost aleasă metoda Weights of Evidence. Integrarea hibridă a celor 3 tehnici machine learning cu Weights of Evidence a fost realizată deoarece se consideră că tehnicile hibrid au rezultate mai exacte decât cele stand-alone sau individuale (Shirzadi et al., 2017). În vederea determinării potențialului de

declanșare a viiturilor rapide prin intermediul metodelor amintite, un număr de 12 factori de condiționare a viiturilor rapide, selectati pe baze statistice, alături de mai multe areale afectate în trecut de torrențialitate, au fost incluse în analiză. Validarea rezultatelor s-a realizat prin intermediul a 2 metode: distribuția relativă (densitatea) a pixelilor cu fenomene de torrențialitate și ROC Curve.

2.2. Studiu de caz

Zona superioară și mijlocie a bazinului hidrografic al râului Prahova este plasată în partea central-sudică a României între 45° 32' 21.85" N și 45° 00' 23.33" N latitudine, și 25° 27' 32.00" E și 26° 27' 10.19" E longitudine (Fig. 2.1).

Altitudinile pornesc de la o valoare de 128 m în sudul zonei de studii și ajung la 2505 m în partea Nord-Vestică a acesteia lângă cele mai importante localități turistice din România: Sinaia, Bușteni, Azuga și Predeal. Pe o suprafață de circa 2600 km² sunt amplasați circa 999,75 km de râuri incluse în cadastrul apelor din România. Dintre bazinele hidrografice care au generat probleme în trecut în ceea ce privește viiturile rapide, se remarcă Valea Cerbului și Valea Rea care sunt afluenți ai râului Prahova în sectorul superior. Un factor extrem de important pentru potențialul de producere a viiturilor rapide este panta reliefului. Media valorilor de pantă în zona de studiu este 12,43°, aceasta fiind o valoare mare tinându-se cont de suprafața bazinului hidrografic. Zonele cu panta ridicată se află în sectorul montan acolo unde și precipitațiile medii anuale sunt mai ridicate ajungând la circa 1000 mm/an. Rocile dure de tipul gresiilor și conglomeratelor alături de solurile impermeabile și suprafețele despădurite, contribuie și ele la producerea viiturilor rapide ce au loc în principal în sezonul de vară, atunci când cad în principal ploi convective.

Principalele obiective socio-economice potențial afectate de producerea viiturilor rapide sunt localitățile turistice aflate în partea de Nord-Vest, precum și Drumul National 1 (E60), care este principala artera rutieră a României. Ținând cont de dezvoltarea economică a zonei de studiu precum și de frecvența mare a viiturilor rapide, considerăm că realizarea unor studii detaliate referitoare la susceptibilitatea la viituri rapide este de o importanță majoră pentru arealul considerat.

În cadrul studiului de față, pentru identificarea suprafețelor cu susceptibilitate ridicată la producerea de viituri rapide, au fost folosite exclusiv date geospațiale. Acestea se referă la Modelul Digital de Teren (DEM), utilizarea terenurilor, solurile, litologia și ariile afectate în trecut de fenomene torrențiale. În continuare aceste date au fost incluse în cadrul următoarelor

etape ce alcătuiesc fluxul de lucru: i) estimarea abilității de predicție a factorilor de condiționare a viiturilor rapide și selectarea acestora pe baze statistice; ii) aplicarea metodelor individuale și a celor hibrid pentru determinarea *FFPI* pe cuprinsul zonei de studiu; iii) realizarea hărților aferente *FFPI*; iv) validarea rezultatelor și evaluarea performanței modelelor aplicate.




Fig. 2.1. Localizarea bazinului superior și mijlociu al râului Prahova în România

2.3. Date

Cartarea zonelor afectate de fenomene torențiale (Fig. 2.2) reprezintă un pas esențial în vederea evaluării corecte a relațiilor spațiale dintre factorii care condiționează producerea viiturilor rapide și potențialul de producere a acestora (Costache, 2019a). Identificarea acestor arii a fost posibilă prin utilizarea imaginilor aeriene furnizate de ANCPI, în timp ce validarea s-a realizat în teren, unde pentru o precizie ridicată a măsurătorilor s-a folosit un GPS Trimble GeoXH 2008 Series. Au fost considerate arii cu torențialitate, cele caracterizate de o prezență unificată pe spații largi a microformelor de tipul ravene, ogașe sau rigole (Costache and Zaharia, 2017). Cea mai puțin extinsă zonă cu torențialitate are o suprafață de 0,35 km², în vreme ce suprafața cea mai ridicată a unei astfel de zone este de 71,1 km². În total au fost identificați circa 260 km² afectați de fenomene torențiale. În vederea utilizării acestor areale pentru

calcularea FFPI, se recomandă ca 70% să fie incluse în eșantionul de antrenament al modelelor în vreme ce restul de 30% să fie păstrate pentru validarea rezultatelor.




Fig. 2.2. Localizarea bazinului superior și mijlociu al râului Prahova în România

Urmatoarea etapă a studiului a fost constituită de selectarea factorilor care influențează producerea viiturilor rapide în cadrul zonei de studiu. Astfel a fost considerat un număr de 12 variabile ce controlează procesul de scurgere a apei la suprafața solului. O influență ridicată o are utilizarea terenurilor și grupa hidrologică de sol (Costache, 2014). Pentru o mai bună caracterizare a zonei studiate din punct de vedere al potențialului de scurgere, factorul de utilizare a terenului extras din baza de date Corine Land Cover, 2012, și factorul grupului hidrologic de sol, obținut pe baza Hărții Digitale a Solurilor a României, 1:200000, au fost combinați pentru a obține indicii Curve Number (CN). CN este un parametru empiric utilizat pe scară largă în hidrologie pentru a estima scurgerea directă dintr-un eveniment ploios (Saharia et al., 2017). În general, valorile CN variază între 0 și 100, în funcție de tipul de utilizare a terenului și de grupul hidrologic de sol. Trebuie menționat că valorile CN apropiate de 100 indică un potențial foarte ridicat de apariție a scurgerilor (Ryu et al., 2016). În ceea ce privește zona studiată, s-a utilizat metoda Natural Breaks pentru a împărți valorile CN în următoarele

șase clase: 0 – 43, 43 – 52, 52 – 69 – 69 – 80, 80 – 89, 88 – 100 (Fig. 2.4e). Valorile CN cuprinse între 43 și 80 acoperă peste 70% din sectorul mijlociu și superior al bazinului hidrografic al râului Prahova.

Litologia este de asemenea importantă în ceea ce privește procesul de formare și manifestare a viiturilor rapide. Rocile dure, cu o permeabilitate scăzută contribuie la formarea scurgerii rapide de suprafață și mai departe la apariția viiturilor rapide. Cartarea formațiunilor litologice de pe cuprinsul zonei de studii s-a realizat pe baza Hărții Geologice a României, 1:200.000 în format digital. Cele mai mari suprafețe sunt ocupate de marne, breccii și conglomerate – 40% din întreaga zona de studiu (Fig. 2.4f). Cei doi factori anterior menționați au fost convertiți în mediul GIS, ținându-se cont de categoriile stabilite.

Modified Fournier Index (MFI) este un alt factor de condiționare a viiturilor rapide, utilizat pentru a evidenția variabilitatea spațială a intensității precipitațiilor în zona studiată. Calculul său a fost posibil folosind următoarea formulă (Kourgialas and Karatzas, 2011):

$$MFI = \sum_{i=1}^{12} \frac{P_i^2}{P} \quad (2.1),$$

unde P_i este suma medie lunară de precipitații pentru luna i (mm), și P – suma medie anuală de precipitații.

Pentru a obține datele raster corespunzătoare fiecăreia dintre cele 12 luni ale anului, au fost utilizate datele privind precipitațiile medii lunare (1980 – 2015). Aceste date au fost colectate de la un număr de 23 de stații meteo situate în sectorul superior și mijlociu al bazinului hidrografic al râului Prahova, precum și în zona înconjurătoare. Pentru interpolarea datelor de la stațiile meteo a fost utilizată metoda Spline, considerată a fi cea mai potrivită pentru acest tip de analiză cu un număr relativ mic de puncte (Kourgialas and Karatzas, 2011). Odată obținute, datele raster referitoare la cantitatea medie lunară de precipitații au fost utilizate ca date de intrare în ecuația 1. Valorile MFI calculate în mediul GIS la o dimensiune a celulei de 30 m au fost grupate în 5 clase folosind metoda Natural Breaks: 53,56 – 57,43, 57,44 – 62,83, 62,84 – 68,69, 68,7 – 75,14, 75,15 – 83,46 (Fig. 2.4d). Cele mai mari suprafețe, cuantificând aproximativ 28% din aria studiată, sunt acoperite de prima clasă (53,56 – 57,43) și a treia clasă (62,84 – 68,89) de valori MFI. Zonele caracterizate prin prezența unor valori MFI cuprinse între 68,7 și 75,14 includ cel mai mare procent de pixeli torențiali (36,65%).

Ceilalți factori considerați în studiul de față sunt exclusiv factori morfometrici ce au fost derivați din DEM (SRTM, 30 m). Primul dintre acestia, considerat și cu cea mai mare influență asupra formării viiturilor rapide este panta reliefului (Wu et al., 2017). Prin urmare pantele ridicate

favorizează scurgerea rapidă a apei pe versanți și formarea viiturilor rapide, în vreme ce pantele scăzute favorizează procesul de inundabilitate, prin stagnarea apei. În cadrul zonei de studiu, valorile de panta au fost împărțite în 5 clase în conformitate cu literatura internațională (Costache, 2025): $<3^\circ$, $3-7^\circ$, $7-15^\circ$, $15-25^\circ$, $>25^\circ$ (Fig. 2.4a). Aproape 41% din suprafața zonei de studiu este caracterizată de valori ale pantei cuprinse între 7° and 15° , acestea fiind urmate de pantele cuprinse între 15° and 25° cu circa 26% din total. Clasa cuprinsă între 15° and 25° detine circa 37% din totalul zonelor torențiale de pe cuprinsul zonei de studiu (Fig. 7). Curbura în profil reprezintă un factor extrem de important pentru creerea unei imagini de ansamblu asupra potențialului unei regiuni de declanșare a viiturilor rapide, ca urmare a faptului ca evidențiază zonele cu scurgere accelerată. Calcularea valorilor Curburii în Profil se bazează pe următoarea formulă aplicată pentru o fereastră mobilă (moving window) de pixeli aferentă unui raster (Alkhasawneh et al., 2013) (Fig. 2.3):

$$\text{Curbura în profil} = \frac{((Z_2 + Z_8)/2 - Z_5)}{2\omega} \quad (3.2),$$

where: Z – altitudinea unei cellule grid, ω – dimensiunea celulei.




Fig. 2.3 3 x 3 moving window

Pentru zona de studiu acest indice a fost derivat din DEM iar valorile sale au fost grupate în 3 clase după cum urmează: $-8.2 - 0$, $0.1 - 0.9$, $0.6 - 9.7$ (Fig. 6d).

Curbura în Plan este un alt factor morfometric luat în considerare pentru calculul FFPI pentru zona de studiu, acesta evidențiind zonele cu scurgere convergentă de cele cu scurgere divergentă. Următoarele trei clase au fost diferențiate pentru gruparea valorilor curburii în plan: $11.8 - 0$, $0.1 - 0.5$, $0.6 - 8.5$ (Fig. 2.5c). Ca și în cazul curburii în profil, ecuația de determinare a curburii în plan s-a baza tot pe o fereastră mobilă după cum urmează:

$$\text{Curbura în plan} = \frac{((Z_4 + Z_6)/2 - Z_5)}{2\omega} \quad (2.3).$$

Indicele de Convergență a rețelei hidrografice (CI) este un factor morfometric luat în considerare în multe din studiile anterioare referitoare la determinarea susceptibilității la viituri rapide (Costache et al., 2022). Valorile negative sunt caracteristice pentru zonele de vale în

vreme ce valorile pozitive evidențiază zonele de interfluviu. În conformitate cu Costache and Zaharia (2017), valorile CI au fost împărțite în 5 clase după cum urmează: $(-99) - (-3)$, $(-3) - (-2)$, $(-2) - (-1)$, $(-1) - 0$, $0 - 99$ (Fig. 2.4b). DEM-ul a fost utilizat în continuare în vederea derivării Topographic Position Index (TPI), un alt indicator morfometric utilizat pentru determinarea valorilor *FFPI* pe zona de studiu. Acesta arată diferența de altitudine dintre o anumită celulă și celulele învecinate. Conform Fig. 2.5a, valorile TPI au fost împărțite în 5 clase prin utilizarea metodei *Natural Breaks*. Astfel au rezultat clasele: $(-34.82) - (-2.08)$, $(-2.07) - (-0.84)$, $(-0.83) - 0.14$, $0.15 - 1.12$, $1.13 - 27.96$. Topographic Wetness Index (TWI), ce arată tendința de acumulare a apei într-un anumit punct al bazinului hidrografic, a fost determinat pe baza formulei (Costache, 2019a):

$$(2.4)$$

unde α este aria cumulată în pantă ascendentă care se drenează printr-un punct (pe unitatea de lungime a conturului) și $\tan \beta$ este unghiul de pantă în punctul respectiv.

Ca și în cazul *TPI* și de această dată s-a utilizat metoda *Natural Breaks* pentru clasificarea valorilor *TWI* rezultând clasele: $(-9.7) - 4.5$, $4.6 - 8.4$, $8.5 - 12$, $13 - 15$, $16 - 25$ (Fig. 2.6b).

Ultimul factor morfometric luat în considerare în studiul de fata este Orientarea Versanților (*Slope aspect*) (Fig. 2.4c). Aceasta influențează potențialul de manifestare a scurgerii de suprafață a apei prin impunerea unui anumit regim al umidității aerului și solului (Costache et al., 2022). Cele mai largi suprafețe sunt ocupate de versanții Estici și Sud-Vestici.

Forma bazinului hidrografic (Catchment Shape Index) (Fig. 2.5e) este un alt factor morfometric care controlează potențialul viiturilor rapide dintr-un bazin hidrografic. Principala sa influență este legată de valoarea timpului de concentrare al unui bazin hidrografic. În general, un bazin hidrografic de formă circulară va avea un timp de concentrare mai mic decât un bazin hidrografic cu o formă lungă și îngustă (Costache, 2019a). Sub-bazinele hidrografice din zona studiată au fost delimitate pe baza unui flux de lucru GIS care a implicat utilizarea Modelului Digital de Elevație. În prezentul studiu, Indicele Formei Bazinului Hidrografic a fost exprimat cu ajutorul formulei raportului de circularitate (R_c) (Zaharia et al., 2017a):

$$R_c = \frac{4\pi A}{P^2} \quad (2.5),$$

unde A este suprafața bazinului hidrografic (în km²) și P este perimetrul bazinului hidrografic (în km).




Fig. 2.4 Factorii de condiționare a viiturilor rapide (a. Panta reliefului; b. Indicele de Convergență a rețelei hidrografice; c. Orientarea versanților; d. Modified Fournier Index; e. Curve Number; f. Litologia)

Cu cât R_c este mai aproape de 1, cu atât forma bazinului hidrografic este mai circulară (Zaharia et al., 2017). În cazul zonei de studiu selectate, valorile indicelui formei bazinului hidrografic au fost împărțite în următoarele 8 clase, utilizând metoda Natural Breaks: 0,14 – 0,21; 0,22 – 0,26; 0,27 – 0,3; 0,31 – 0,33; 0,34 – 0,37; 0,38 – 0,41; 0,42 – 0,47; 0,48 – 0,53. Cele mai mari suprafețe sunt acoperite de bazine hidrografice caracterizate prin valori cuprinse între 0,27 și 0,3, în timp ce cel mai mare procent de pixeli torențiali (27%) se află în clasa cuprinsă între 0,34 și 0,37.




Fig. 2.5 Factorii de condiționare a viiturilor rapide (a. TPI; b. TWI; c. Curbura în plan; d. Curbura în profil; e. Forma bazinului hidrografic; f. Suprafața contributivă din amonte a rețelei hidrografice)

Suprafața contributivă din zona de amonte a rețelei hidrografice (Contributing area) este un factor morfometric care are o influență semnificativă asupra procesului de apariție a viiturilor rapide (Diakakis et al., 2016). Pentru a calcula această suprafață (km²) pe sectorul superior și mijlociu al bazinului hidrografic al râului Prahova, rasterul de acumulare a debitului, derivat din Modelul Digital de Elevație, a fost înmulțit cu valoarea suprafeței celulelor raster (900 m²) și apoi împărțit la 1.000.000. Harta finală a zonei contributive a fost obținută prin gruparea

valorilor acesteia în următoarele 6 clase: $< 0,2 \text{ km}^2$, $0,2 - 0,5 \text{ km}^2$, $0,5 - 2 \text{ km}^2$, $2 - 5 \text{ km}^2$, $5 - 8 \text{ km}^2$, $> 8 \text{ km}^2$ (Fig. 2.5f). Peste 98% din studiu are o zonă contributivă în amonte mai mică de $0,2 \text{ km}^2$.

Clasele și categoriile stabilite pentru fiecare factor de condiționare a viiturilor rapide au fost utilizate pentru a calcula coeficienții Weights of Evidence (WOE) conform metodologiei descrise la punctul 3.4.1. În schimb, pentru a fi incluși în modelul de selecție a caracteristicilor bazat pe corelație descris la punctul 3.4.2, valorile variabilelor continue au fost normalizate în intervalul 0 și 1. Această transformare a fost efectuată pentru toți factorii de condiționare, cu excepția orientării versanților și litologiei, care sunt singurele variabile categorice luate în considerare în prezenta analiză. Chiar dacă procesul de normalizare nu are niciun impact asupra performanței algoritmilor bazați pe arbori de decizie, valorile normalizate, direcțiile de aspect și categoriile litologice au fost, de asemenea, implicate în procesul de antrenare a modelelor independente de arbore de decizie aplicate în prezentul studiu.

2.4. Metode

2.4.1. Correlation-based feature selection (CFS) pentru selecția predictorilor

Conform lui Ozcift and Gulten (2011), un factor prezintă o importanță majoră pentru un model dacă este corelat într-o măsură ridicată cu prezența fenomenului analizat și necoral cu un alt factor. Astfel, o corelație ridicată între factorii de condiționare a viiturii rapide și zonele cu torențialitate evidențiază o mai bună capacitate predictivă a aceluia factor față de alți factori. CFS identifică rapid și afisează informațiile irelevante, redundante și zgomotoase. De obicei, un factor este redundant dacă este puternic corelat cu alți factori. Prin urmare, scorurile CFS vor fi atribuite factorilor de condiționare a inundațiilor, care sunt foarte corelați cu localizarea fenomenelor torențiale. Scorurile vor fi calculate prin următoarea relație (Ozcift and Gulten, 2011):

$$CFS = \frac{k r_{cf}}{\sqrt{k + k(k-1)r_{ff}}} \quad (2.6),$$

unde CFS este corelația dintre fiecare factor de condiționare a viiturii rapide cu prezența zonelor torențiale, k este numărul de factori de condiționare a viiturii rapide, r_{cf} este corelația medie dintre factorul de condiționare a viiturii rapide și zonele cu torențialitate, și r_{ff} este intercorelația medie dintre factorii de condiționare ai viiturilor rapide.

Determinarea scorurilor CFS se va realiza prin integrarea valorilor corespunzătoare fiecărei clase/categorii de factori de condiționare a viiturilor rapide și a zonelor cu torențialitate în software-ul Weka 3.8.6.

2.4.2. Weights of Evidence

Utilizată pentru prima dată în studiile geologice (Agterberg, 1992), metoda Weights of Evidence (WoE) a fost preluată și adaptată și pentru evaluarea susceptibilității la diferite hazarde naturale precum: alunecări de teren, inundații și viituri rapide (Costache and Zaharia, 2017). Această metodă bazată pe date reprezintă un model statistic bivariat Bayesian utilizat pe scară largă în domeniul geostiintelor și ingineriei.

În prezentul studiu metoda Weights of Evidence a fost utilizată atât pentru determinarea independentă a *Flash-Flood Potential Index* pe zona de studiu, cât și pentru derivarea datelor de intrare în modelele hibrid ce vor fi alcătuite pe deoparte de metoda WoE iar pe de altă parte de modelele: Rotation Forest (RF), Logisitic Model Tree (LMT) și Alternating Decision Tree (ADT).

Metoda WoE se bazează pe faptul ca factorii favorizanți pentru declanșarea viiturilor rapide sunt constanți în timp, valorile ponderilor fiecărei clase/categorii a acestora fiind calculate pe baza relațiilor spațiale dintre acestea și prezența/absența fenomenelor torențiale (Dahal et al., 2008). În fapt, determinarea ponderii fiecărei clase/categorii factorilor pe care o au în calculul *FFPI* se bazează pe teorema probabilității Bayes' care poate fi scrisă astfel (Regmi et al., 2014):

$$P\left\{\frac{A}{B}\right\} = \ln \frac{P\left(\frac{B}{A}\right) \times P(A)}{P(B)} \quad (2.7),$$

unde P este probabilitatea, B este prezența factorilor de condiționare a viiturilor rapide și A este prezența zonelor torențiale.

Determinarea în mediul GIS a coeficienților WoE solicită într-o primă fază, calcularea ponderii negative (W^-) și a celei pozitive (W^+). Ponderea negativă evidențiază o asocierie spațială între clasa/categoria unui factor de condiționare a viiturilor rapide și absența fenomenelor de torențialitate, în vreme ce ponderea pozitivă demonstrează o asocierie între clasa/categoria unui factor de condiționare a viiturilor rapide și prezența zonelor torrențiale (Van Westen et al., 2003).

Determinarea celor 2 tipuri de ponderi se realizează prin intermediul formulelor:

$$W^+ = \ln \frac{P\{B | S\}}{P\{B | \bar{S}\}} \quad (2.8) \quad \text{and} \quad W^- = \ln \frac{P\{\bar{B} | S\}}{P\{\bar{B} | \bar{S}\}} \quad (2.9),$$

unde: W^+ - ponderea pozitivă, W^- - ponderea negativă, P – probabilitatea, B – prezența predictorilor viiturilor rapide, $\bar{B}$ - absența predictorilor viiturilor rapide, S – prezența zonelor torențiale, $\bar{S}$ - absența zonelor torențiale.

Pentru o mai ușoară determinare în mediul GIS a valorilor celor 2 ponderi cele 2 ecuații au fost rescrise după cum urmează (Van Westen et al., 2003):

$$W^+ = \ln \frac{\frac{Npix_1}{Npix_1 + Npix_2}}{\frac{Npix_3}{Npix_3 + Npix_4}} \quad (2.10) \quad \text{și} \quad W^- = \ln \frac{\frac{Npix_2}{Npix_1 + Npix_2}}{\frac{Npix_4}{Npix_3 + Npix_4}} \quad (2.11)$$

unde $Npix_1$ este numărul de pixeli cu fenomene de torențialitate în clasa/categoria factorilor; $Npix_2$ este numărul de pixeli cu fenomene de torențialitate în afara clasei/categoriei factorilor; $Npix_3$ este numărul de pixeli fără fenomene de torențialitate în clasa/categoria factorilor; $Npix_4$ este numărul de pixeli fără fenomene de torențialitate în afara clasei/categoriei factorilor; W^+ ponderea pozitivă și W^- este ponderea negativă.

În cadrul procesului de determinare a $FFPI$ utilizând metoda WoE în mod individual, este necesară calcularea ponderii finale atribuite fiecărei clase/categorii de factori. Acest lucru a fost realizat prin intermediul următoarei relații (Costache and Zaharia, 2017):

$$Wf = W_{plus} + W_{min\ total} - W_{min} \quad (2.12),$$

unde W_{plus} este ponderea pozitivă a clasei unui factor, W_{min} este ponderea negativă a clasei unui factor, $W_{mintotal}$ este totalul ponderilor negative ale tuturor claselor din cadrul unui factor. Mai departe pentru determinarea finală a $FFPI_{WoE}$ a fost utilizată următoarea ecuație:

$$FFPI_{WoE} = \sum_{j=1}^n Wf_{ij} \quad (2.13),$$

unde Wf_{ij} este ponderea finală a clasei i în parametrul j și n este numărul de variabile.

În schimb, în cazul utilizării valorilor coeficienților *WoE* pentru instruirea modelelor *RF*, *LMT* și *ADT* și implicit generarea modelelor hibrid de calcul a *FFPI*, valorile *Wf* corespunzătoare fiecărei clase/categorii au fost normalizate prin intermediul formulei (Pradhan and Youssef, 2011):

$$y = \frac{(Wf - \min(d)) * (\max(n) - \min(n))}{\max(d) - \min(d)} + \min(n) \quad (2.14),$$

unde: y – este valoarea normalizată a Wf ; Wf – este valoarea curentă a variabilei; d – limitele intervalului de valori ale Wf în cadrul unui factor de condiționare a viiturilor rapide; n – limitele intervalului de normalizare. Intervalul de normalizare pentru prezentul studiu de caz a fost între 0,1 și 0,9.

2.4.3. Rotation forest (RF)

Rotation forest (*RF*) este o metodă de clasificare relativ nouă, fiind propusă pentru prima dată de Rodriguez et al. (2006). În ceea ce privește studiile de susceptibilitate la fenomene naturale de risc, aceasta metodă a fost utilizată cu precădere în ultimii 3 ani (Shen et al., 2023). Deoarece este un model de tip ansamblu, se consideră că oferă rezultate mai precise decât metodele bazate pe o singură metodă de clasificare (Ozcift and Gulten, 2011). Metoda *RF* este utilizată pentru generarea de ansambluri de clasificatori bazate pe extragerea caracteristicilor. Conform lui Rodriguez et al. (2006), datele de antrenament pentru un clasificator de bază sunt create prin împărțirea aleatorie a setului de caracteristici în K subseturi (K este un parametru al algoritmului), ulterior aplicând o Analiză a Componentelor Principale (PCA) fiecărui subset. Pașii principali ai procedurii *RF* sunt descriși în rândurile următoare.

Fie $g = [g_1, \dots, g_{12}]$ vectorul asociat factorilor de condiționare a viiturilor rapide descris de n clase/categorii, G setul de date care conține factorii de condiționare sub forma unei matrice $N \times n$ și $T = [t_1, t_2]$ un vector asociat zonelor torențiale, unde t_1 – reprezintă prezența acestora și t_2 – reprezintă absența zonelor torențiale. Presupunând că setul de date (F) este împărțit aleatoriu în K subseturi și L arbori de decizie ai algoritmului *RF*, notați cu $\{D_1, \dots, D_L\}$, vor fi necesari următorii pași pentru a construi setul de date de antrenament:

- i) Se împarte F aleatoriu într-un număr de K subseturi de caracteristici, unde fiecare subset conține $M = n/K$ caracteristici.
- ii) Dacă considerăm F_{ij} ca fiind subsetul j de caracteristici pentru antrenarea clasificatorului D_i , și G_{ij} ca set de date pentru G , atunci se va utiliza o procedură de reeșantionare bootstrap cu

75% din set de date pentru a crea un nou set de date de antrenament. Ulterior, se aplică o transformare liniară asupra matricei G_{ij} pentru a calcula coeficienții matricei C_{ij} . Matricea va conține coeficienții $a_{(1)ij}, \dots, a_{(M)ij}$, fiecare dintre ei cu dimensiunea $M \times 1$.

- iii) Se va deriva matricea dispersă de rotație R_i care conține vectorii obținuți cu coeficienții aferenți, după cum urmează:

$$R_i = \begin{bmatrix} a_{i,1}^{(1)}, a_{i,1}^{(2)}, \dots, a_{i,1}^{(M_1)} & 0 & \dots & 0 \\ 0 & a_{i,1}^{(1)}, a_{i,1}^{(2)}, \dots, a_{i,1}^{(M_2)} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & a_{i,K}^{(1)}, a_{i,K}^{(2)}, \dots, a_{i,K}^{(M_K)} \end{bmatrix} \quad (2.15)$$

Matricea obținută este rearanjată cu coeficienții corespunzători fiecărei clase, aceștia fiind derivați utilizând combinația medie din eșantionul de testare dat, descrisă de următoarea ecuație (Chen et al., 2017a):

$$m_j(g) = \frac{1}{L} + \sum_{i=1}^L d_{ij}(gR_i^a), j = 1, \dots, c \quad (2.16),$$

unde $d_{ij}(xR_i^a)$ este probabilitatea dată de clasificatorul D_i pentru ipoteza că x aparține clasei j .

În cadrul prezentului studiu RF model va fi aplicat atât individual pentru generarea Potențialului de Formare a Viiturilor Rapide (Flash-Flood Potential Index – FFPI) cât și prin integrarea hibridă cu WoE . În ambele situații aplicarea modelelor va fi posibilă prin utilizarea softului Weka 3.8.6.

2.4.4. Logistic Model Tree (LMT)

Logistic Model Tree reprezintă o combinație între Regresia Logistică și metoda arborilor de decizie (Ali et al., 2022). LMT prezintă următoarele avantaje (Eristi and Demir, 2012): este un proces de învățare rapid, nu necesită ajustarea diferiților parametri sensibili; este un model simplu cu o eficiență de învățare foarte ridicată. Conform lui Landwehr et al. (2005), LMT are o structură arborescentă formată dintr-un set de noduri interne sau neterminale N și un set de frunze sau noduri terminale T . Funcția de regresie logistică se aplică rezultatelor oferite de arborele de decizie la nivelul fiecărei frunze, în timp ce algoritmul CART este utilizat pentru tăierea arborilor și metoda de câștig de informații pentru divizare. Algoritmul LogitBoost este utilizat pentru a aplica funcția de regresie logistică pentru fiecare clasă C_i (zone torențiale și zone netorențiale) descrisă de următoarea relație (Tien Bui et al., 2016):

$$L_C(x) = \sum_{i=1}^D \beta_i x_i + \beta_0 \quad (2.17),$$

unde D este numărul de factori de condiționare pentru viituri rapide și β_i este coeficientul componenteii i în cadrul vectorului de intrare x .

La nivelul nodurilor frunzelor, în modelul LMT, probabilitatea posterioară este estimată utilizând modelul de regresie logistică liniară (Tien Bui et al., 2016):

$$p(C|x) = \frac{\exp(L_C(x))}{\sum_{C'}^D \exp(L_{C'}(x))} \quad (2.18),$$

unde D este numărul de clase.

Software-ul Weka 3.8.6 a fost utilizat pentru aplicarea modelului individual LMT și a modelului hibrid LMT-WoE.

2.4.5. Alternating Decision Tree (ADT)

Arborele Decizional Alternativ (Alternating Decision Tree - ADT), propus pentru prima dată de Freund and Mason (1999), oferă un mecanism care combină algoritmul de amplificare (boosting - AdaBoost) cu arborele decizional. Spre deosebire de alți algoritmi de arbori decizionali, cum ar fi CART și Random Forest, ADT produce structuri mai simple de arbori decizionali și reguli de clasificare mai ușor de interpretat (Hong et al., 2015a). Această metodă constă în alternarea straturilor de noduri de predicție și de decizie, fiind o extensie naturală a nodurilor votate și a arborelui decizional (Freud and Manson, 1999). Conform lui Hong et al. (2015), nodurile de predicție conțin un singur număr, în timp ce nodurile de decizie specifică o condiție predicativă. Prin urmare, structura ADT este formată din căi de decizie, unde o cale care ajunge la un nod de decizie continuă cu nodul descendent specific, și o altă cale care ajunge la un nod de predicție care va continua cu toate nodurile descendente.

Dacă considerăm c_1 ca precondiție, c_2 ca o condiție de bază și două numere reale a și b , valorile lui a și b pot fi calculate după cum urmează (Khosravi et al., 2018):

$$a = 0.5 * \ln \frac{W_+(c_1 \cap c_2)}{W_-(c_1 \cap c_2)}, b = 0.5 * \ln \frac{W_+(c_1 \cap \overline{c_2})}{W_-(c_1 \cap \overline{c_2})} \quad (2.19),$$

unde W denotă suma valorilor din orice nod de predicție, iar cele mai bune c_1 și c_2 sunt estimate prin minimizarea lui $Z_t(c_1, c_2)$, determinat după cum urmează:

$$z_t(c_1 c_2) = 2\sqrt{W_+(c_1 \cap c_2) * W_-(c_1 \cap c_2)} + \sqrt{W_+(c_1 \cap \overline{c_2}) * W_-(c_1 \cap \overline{c_2})} + W(\overline{c_2}) \quad (2.20)$$

În prezentul studiu, s-a utilizat ADT cu algoritmul de boosting AdaBoost pentru a obține Indicele de Potențial al Viiturii Rapide (*Flash-Flood Potential Index*) pe baza informațiilor legate de cei 12 factori de condiționare ai viiturilor rapide și de prezența și absența fenomenelor torențiale. Având în vedere structura ADT, valoarea *FFPI* pentru un anumit pixel va fi calculată prin însumarea tuturor valorilor din orice noduri de predicție care apar atunci când pixelul tranzitează toate ramurile aplicabile.

În cadrul întregii proceduri ADT, s-au aplicat un număr de 20 de iterații de boosting. Prin utilizarea zonelor de antrenament și validare, acuratețea clasificării a fost estimată pentru fiecare iterație.

Valorile FFPI au fost determinate prin utilizarea individuală a modelului ADT, precum și prin integrarea hibridă cu modelul WoE. În ambele situații s-a utilizat software-ul Weka 3.8.6.

2.4.6. Validarea rezultatelor

Determinarea **densității pixelilor cu fenomene de torențialitate în cadrul claselor FFPI** rezultate din aplicarea modelelor amintite mai sus, a constituit prima metodă de evaluare a performanțelor modelelor și de validare a rezultatelor. Această metodă, utilizată în studiile referitoare la susceptibilitatea la diferite hazarde naturale (Costache and Zaharia, 2017; Hong et al., 2018), indică o eficiență bună a modelelor aplicate și o acuratețe ridicată a rezultatelor obținute în cazul în care există o densitate mare a zonelor cu torențialitate în cadrul claselor IV^{th} și V^{th} ale FFPI.

De asemenea se va utiliza și **Curba ROC** descrisă în capitolul anterior.

2.5. Rezultate

2.5.1. Capacitatea de predicție a factorilor de condiționare a viiturilor rapide

Capacitatea predictivă a celor 12 factori de condiționare a viiturilor rapide a fost estimată prin metoda CFS descrisă anterior. Capacitatea de predicție a fost exprimată în valori medii de merit (AM) (Fig. 2.6).

Aplicarea metodelor CFS demonstrează că cea mai mare capacitate predictivă a fost atribuită unghiului de pantă, cu o valoare AM de 0,294. Acest rezultat este în acord cu majoritatea studiilor legate de manifestarea scurgerilor de suprafață, în care se menționează faptul că unghiul de pantă este cel mai important factor de condiționare. În ceea ce privește valorile AM, unghiul de pantă este urmat de Curve Number (0,258), litologie (0,193), curbura în profil (0,182), Modified Fournier Index (0,175), TWI (0,169), curbura în plan (0,151), forma bazinelor (0,144), indicele de convergență (0,125), suprafața contributivă din amonte (0,083), orientarea versanților (0,079) și TPI (0,035).

Deoarece AM calculat pentru fiecare factor de condiționare a viiturii rapide este mai mare decât 0, toate variabilele vor fi utilizate în analiză.




Fig. 2.6 Capacitatea de predicție a factorilor de condiționare a viiturilor rapide

2.5.2. Aplicarea modelului individual Weights of Evidence

Prima etapă realizată în cadrul procesului de estimare FFPI prin modelul WOE a constat în calcularea coeficienților WOE pentru fiecare clasă/categorie de factori. Aceste valori au fost determinate conform metodologiei descrise anterior. Cea mai mare valoare a lui *WOE* (2,38) aparține clasei Curve Number, cuprinsă între 88 și 100 (Tabelul 2.1). Având în vedere faptul că valoarea Curve Number este determinată de intersecția tipului de utilizare a terenului cu grupa hidrologică de sol, putem afirma că aceste valori ridicate ale lui *WOE* sunt explicate în principal, pe de o parte, prin prezența unui tip de utilizare a terenului caracterizat prin valori scăzute ale coeficienților de rugozitate Manning, favorabili unei manifestări intense a scurgerilor de suprafață, iar pe de altă parte, prin prezența unui grup hidrologic de sol caracterizat printr-un grad scăzut de permeabilitate (Costache, 2014). Analiza a arătat că valori mari ale lui *WOE* au fost înregistrate și pentru clasa MFI între 68,7 și 75,14 (1,65), unghiuri de pantă mai mari de 25° (1,51), clasa MFI între 75,15 și 83,46 (1,32) și clasa Catchment Shape Index între 0,31 și 0,33 (0,94). Se poate observa că unghiurile de pantă mai mari de 25° sunt legate de cea mai mare valoare a ponderilor pozitive (W^+) (1,87) (Fig. 9). Cele mai mici valori ale lui *WOE*, dintre cele 72 de clase/categorii de factori, au fost estimate pentru unghiurile de pantă mai mici de 3° (-2,15), grupa litologică 10 (-2,26), clasa MFI cuprinsă între 53,56 și 57,43 (-2,35), suprafețe plane (-2,37) și grupa litologică 3 (-2,67). Cea mai mică pondere negativă (W^-), de -0,77, a fost stabilită pentru clasa de suprafață contributivă din amonte mai mică de 0,2 km².

Odată calculate, valorile WOE au fost atribuite claselor/categoriilor de factori corespunzătoare în mediul GIS. Ulterior, factorii de condiționare ai viiturilor rapide în format raster au fost însumați pentru a calcula valorile FFPI WOE (Fig. 2.7).

Tabel 2.1 Valorile standardizate ale coeficienților WOE

Factor	Clasă	Pixelii claselor (%)	Pixelii torențiali (%)	Coeficientul WOE	Coeficientul WOE standardizat
Panta	< 3°	11.46	1.66	-2.15	0.10
	3 – 7°	13.32	7.46	-0.71	0.42
	7 – 15°	41.72	32.83	-0.43	0.48
	15 – 25°	26.42	37.35	0.58	0.70
	> 25°	7.09	20.70	1.51	0.90
TPI	(-20) – (-3.8)	2.71	4.67	0.66	0.88
	(-3.7) – (-1.1)	11.82	13.25	0.15	0.53
	(-1) – 1.3	44.96	34.26	-0.50	0.10
	1.4 – 4.5	30.14	30.41	0.01	0.45
	4.6 – 20	10.38	17.42	0.69	0.90
TWI	-9.7 – 4.5	21.30	22.33	-0.01	0.80
	4.6 – 8.4	24.98	24.89	0.08	0.90
	8.5 – 12	29.70	31.13	-0.08	0.71
	13 -15	21.09	19.93	-0.59	0.10
	16 – 25	2.93	1.72	0.07	0.89
Litologia	1	27.28	42.31	0.76	0.90
	2	3.08	0.75	-1.53	0.37
	3	0.65	0.05	-2.67	0.10
	4	1.43	1.59	0.12	0.75
	5	0.10	0.00	0.01	0.72
	6	0.05	0.04	-0.44	0.62
	7	0.89	0.39	-0.89	0.51
	8	28.62	41.59	0.65	0.87
	9	14.30	9.77	-0.48	0.61
	10	23.45	3.52	-2.26	0.20
	11	0.07	0.00	0.01	0.72
	12	0.08	0.00	0.01	0.72
Curbura în profil	-8.2 – 0	48.62	52.61	0.18	0.53
	0 – 0.9	50.97	46.77	-0.19	0.10
	0.9 – 9.7	0.40	0.62	0.49	0.90
Curbura în plan	-11.8 – 0	32.68	37.05	0.22	0.67
	0.1 – 0.5	56.65	47.66	-0.41	0.10
	0.6 – 8.5	10.66	15.29	0.47	0.90
Orientarea versanților	Zone plate	0.08	0.01	-2.37	0.10
	Nord	8.64	7.10	-0.24	0.74
	Nord-Est	11.62	12.30	0.07	0.83
	Est	14.69	18.54	0.32	0.90
	Sud-Est	14.34	17.24	0.04	0.82
	Sud	14.06	15.07	0.09	0.83
	Sud-Vest	14.66	14.49	-0.02	0.80
	Vest	12.84	9.15	-0.42	0.68
Indicele de convergență	Nord-Est	9.07	6.11	-0.47	0.67
	0 – 95	21.72	20.65	-0.07	0.10
	(-1) – 0	6.34	6.70	0.07	0.89
	(-2) – (-1)	8.51	8.99	0.07	0.90
	(-3) – (-2)	10.62	10.89	0.03	0.69
Curve Number	(-96) – (-3)	52.81	52.77	0.01	0.50
	0 – 43	7.78	1.97	-1.53	0.10
	43 – 52	25.32	14.19	-0.79	0.25

	52 – 69	22.57	15.72	-0.49	0.31
	69 – 80	22.14	15.05	-0.52	0.31
	80 – 88	13.80	16.61	0.25	0.46
	88 – 100	8.39	36.46	2.38	0.90
Forma bazinelor	0.14 - 0.21	6.34	4.12	-0.50	0.79
	0.22 - 0.26	14.04	8.24	-0.65	0.78
	0.27 - 0.3	22.70	18.81	-0.26	0.81
	0.31 - 0.33	12.73	24.53	0.94	0.90
	0.34 - 0.37	20.50	27.13	0.10	0.83
	0.38 - 0.41	12.26	13.61	0.14	0.84
	0.42 - 0.47	8.29	3.46	0.22	0.75
	0.48 - 0.53	3.14	0.09	-1.26	0.10
Suprafața contributivă din amonte (km ²)	< 0.2	98.26	99.15	0.78	0.90
	0.2 – 0.5	0.43	0.40	-0.08	0.65
	0.5 – 2	0.33	0.19	-0.62	0.50
	2 – 5	0.17	0.09	-0.70	0.47
	5– 8	0.10	0.07	-0.41	0.56
	> 8	0.71	0.10	-2.02	0.10
Modified Fournier Index (MFI)	53.56 - 57.43	27.03	3.88	-2.35	0.10
	57.44 - 62.83	23.99	6.46	-1.63	0.24
	62.84 - 68.69	28.32	32.78	0.24	0.62
	68.7 - 75.14	12.81	36.65	1.65	0.90
	75.15 - 83.46	7.84	20.22	1.32	0.83

Valorile FFPI WOE, cuprinse între (-25,35) și 9,84, au fost grupate în 5 clase (foarte mici; mici; medii; mari; foarte mari) prin metoda Natural Breaks disponibilă în ArcGIS 10.5.




Fig. 2.7 Distribuția spațială a valorilor FFPI WOE

Prima clasă, care denotă valori FFPI WOE foarte mici, ocupă aproximativ 12,6% din suprafața studiată și variază între (-25,35) și (-6,27). În aceste zone, situate în special în partea de sud a sectorului superior și mijlociu al bazinului hidrografic al râului Prahova, apariția viiturilor rapide este aproape imposibilă din cauza unghiului mic de pantă. Valorile mici ale FFPI WOE, cuprinse între (-6,26) și (-2,18), sunt răspândite pe 28,3% din suprafața studiată, în timp ce valorile medii acoperă aproximativ 35,7% din total. Valorile mari și foarte mari ale FFPI WOE, incluse în clasele a IV-a și a V-a, caracterizează 23,3% din suprafața studiată, fiind situate pe zone compacte, în special în partea de nord-vest. În cazul precipitațiilor abundente, prezența acestor zone compacte extinse, cu FFPI foarte mare, duce la evenimente de viituri rapide severe.


2.5.3. Aplicarea modelului LMT individual și LMT-WOE hibrid

Pentru a investiga multicolaritatea dintre factorii de condiționare ai viiturilor rapide, au fost calculați doi parametri reprezentați de factorii de inflație a varianței (VIF) și toleranțele (TOL) (Tabelul 2.2). Deoarece cea mai mică valoare a TOL este de 0,79 (zona contributivă), iar cea mai mare valoare a VIF este de 1,19 (indicele de convergență), se poate concluziona că nu există o colinearitate semnificativă între variabilele incluse în analiză.

Tabel 2.2 Analiza de multicolaritate pentru variabilele independente

Variabile	Indicii de multicolaritate	
	TOL	VIF
Orientarea versanților	0.93	1.03
Indicele de convergență	0.83	1.19
Curve Number	0.97	1.02
Litologie	0.94	1.01
Panta	0.85	1.11
Curbura în plan	0.87	1.14
Curbura în profil	0.84	1.18
TWI	0.81	1.13
TPI	0.85	1.02
Modified Fournier Index	0.95	1.03
Suprafața contributivă din amonte	0.79	1.17
Forma bazinelor	0.97	1.01

În plus, a fost utilizată o procedură de validare încrucișată pentru a determina numărul de iterații utilizate pentru evaluarea performanței clasificării. În acest sens, modelele LMT și LMT-WOE au fost comparate cu celelalte modele independente și hibride luate în considerare în prezenta cercetare (Fig. 2.8). Dintre toate modelele, cea mai mare precizie a fost obținută de modelul independent RF (93,4%) după 18 iterații. În ceea ce privește modelul independent LMT, cea mai mare precizie (92,1%) a rezultat după 18 iterații, în timp ce pentru modelul hibrid LMT-WOE, cea mai mare precizie a fost atinsă după 19 iterații (Tabelul 2.3).



În urma procesului de antrenament al modelului LMT autonom și al modelului hibrid LMT-WOE, a fost determinată importanța fiecărui factor de condiționare a viiturilor rapide (Fig. 2.11). Prin urmare, în cazul modelului LMT autonom, cea mai mare importanță aparține unghiului de pantă (15,78%), urmat de Curve Number (14,68%), litologie (11,84%), curbura în plan (10,57%), MFI (9,63%), TWI (7,45%), indicele de convergență (7,1%), curbura profilului (6,17%), aria contributivă din amonte (5,52%), TPI (5,05%), orientarea versanților (3,8%) și indicele formei bazinului hidrografic (2,41%). Conform modelului hibrid LMT-WOE, cea mai mare importanță a fost înregistrată și de unghiul de pantă (15,73%), urmat de Curve Number (14,48%), litologie (13,07%), curbura în plan (8,82%), MFI (8,17%), indicele de convergență (7,56%), aria contributivă din amonte (7,23%), TPI (6,78%), TWI (5,68%), curbura în profil (4,73%), indicele formei bazinului hidrografic (4,73%) și orientarea versanților (3%). Folosind variabilele importanță, FFPI LMT și FFPI LMT-WOE au fost calculate în ArcGIS 10.5.

Prin urmare, luând în considerare metoda de clasificare Natural Breaks, valorile FFPI LMT, cuprinse între 0,11 și 0,89, au fost grupate în 5 clase (Fig. 2.9a). Prima clasă de valori, cuprinsă între 0,11 și 0,23, este răspândită pe aproximativ 6,4% din zona studiată și evidențiază suprafețele cu un potențial foarte scăzut de apariție a viiturii rapide. Următoarea clasă, care variază între 0,23 și 0,34, acoperă 19,6% din sectorul superior și mijlociu al bazinului hidrografic al râului Prahova. Ponderea cea mai mare, în ceea ce privește suprafața, o dețin valorile medii ale FFPI LMT. Astfel, suprafețele incluse în clasa medie sunt răspândite pe aproximativ 30,3% din total, puțin mai mult decât valorile mari ale FFPI LMT, care acoperă 27,5% din suprafața

studiată. Valorile care caracterizează un potențial foarte mare de apariție a viiturii rapide se întâlnesc pe aproximativ 16,2% din întreaga suprafață studiată și variază între 0,69 și 0,89.

Prin includerea valorilor coeficienților WOE în procesul de antrenament al modelului LMT, rezultatele modelului hibrid LMT-WOE au fost modelate spațial (Fig. 2.9b).




Fig. 2.9 Distribuția spațială a valorilor FFPI (a. modelul LMT; b. modelul LMT-WOE)

Valori foarte mici ale FFPI LMT-WOE sunt caracteristice unei suprafețe de 260 km², având o pondere de 10,7% din sectorul superior și mijlociu al bazinului hidrografic al râului Prahova. Valorile mici ale potențialului de viituri rapide acoperă aproximativ 24,6% din suprafața de cercetare și corespund valorilor FFPI LMT-WOE cuprinse între 0,22 și 0,39. Următoarea clasă de valori variază între 0,39 și 0,59 și este răspândită pe aproximativ 34,4% din sectorul superior și mijlociu al bazinului hidrografic al râului Prahova. Împreună, valorile mari și foarte mari ale FFPI LMT-WOE ocupă aproximativ 30,3% din total.

2.5.4. Aplicarea modelului RF individual și a modelului RF-WOE hibrid

Aplicarea modelului RF stand-alone și a modelului hibrid RF-WOE pentru calculul FFPI în cadrul zonei de studiu necesită, într-o primă etapă, un proces de optimizare, această operațiune având o influență mare asupra acurateței rezultatelor oferite de cele două metode. Parametrii obținuți în urma procesului de optimizare sunt prezentați în Tabelul 2.3. În același tabel sunt prezentați parametrii optimi corespunzători celorlalte modele aplicate.

Tabel 2.3 Parametrii de optimizare a modelelor aplicate în prezentul studiu

Modele	Nr. iterații	Seeds	Accuratețe (%)
RF	18	4	93.4
RF-WOE	16	3	92.4
LMT	18	2	92.1
LMT-WOE	19	5	92.5
ADT	19	3	93.1
ADT-WOE	17	2	92.9

Așa cum s-a menționat anterior, precizia modelului RF independent (93,4%) a fost obținută după 18 iterații, în timp ce pentru modelul hibrid RF-WOE cea mai mare precizie de 92,4% a rezultat după 16 iterații.

După procesul de antrenament al modelelor RF și RF-WOE, a fost derivată ponderea fiecărui factor de condiționare a viiturilor rapide. Similar modelelor anterioare, unghiul de pantă a obținut cea mai mare importanță atât pentru modelul RF, cât și pentru cel RF-WOE (Fig. 2.12). Ponderile variabile au fost utilizate în continuare pentru a calcula valorile FFPI.

În ambele situații, metoda Natural Breaks a fost aplicată pentru a clasifica intervalul de valori al FFPI. Prin urmare, în ceea ce privește FFPI RF, prima clasă de valori, care indică un potențial de viituri rapide foarte mic, este răspândită pe aproximativ 8,9% din suprafața totală și variază între 0,13 și 0,22 (Fig. 2.10a). Următoarea clasă de valori, cuprinsă între 0,22 și 0,37, este prezentă pe aproximativ 20,1%, în timp ce valorile medii ale FFPI RF se întâlnesc pe aproximativ 28,8% din sectorul superior și mijlociu al bazinului hidrografic al râului Prahova. Peste 42% din

zona studiată este caracterizată de valori mari și foarte mari ale FFPI RF. Cele mai compacte zone cu astfel de suprafețe sunt situate în partea de nord-vest.




Fig. 2.10 Distribuția spațială a valorilor FFPI (a. modelul RF; b. modelul RF-WOE)

Prin utilizarea coeficienților WOE în procesul de antrenament al modelului RF, a fost reprezentată distribuția spațială a valorilor FFPI RF-WOE pe întreaga zonă studiată. De data aceasta, valorile foarte mici sunt distribuite pe aproximativ 9,4% din total, în timp ce potențialul

scăzut de viituri rapide acoperă aproximativ 20,5% din zona studiată. Valorile medii ale FFPI RF-WOE, cuprinse între 0,36 și 0,53, sunt distribuite pe aproximativ 29,6% din zona totală de cercetare (2.10b).

Conform rezultatelor obținute, valorile mari și foarte mari ale potențialului de viituri rapide pot fi întâlnite pe aproximativ 40,4% din suprafața studiată. Spre deosebire de FFPI RF, valorile mari și foarte mari ale FFPI RF-WOE au un grad de compactare mai mare, ceea ce ar crește posibilitatea apariției unor viituri rapide severe.

2.5.5. Aplicarea modelului ADT individual și a modelului ADT-WOE hibrid

Pentru modelul ADT independent, cea mai mare precizie de 93,1% a fost atinsă după 19 iterații, în timp ce modelul hibrid ADT-WOE a atins cea mai mare precizie (92,9%) după 17 iterații. Arborii de decizie optim eliminați utilizați în prezenta analiză sunt reprezentați în Fig. 2.11a și b.




Fig. 2.11 Arborii de decizie optim segmentați (a. modelul ADT; b. Modelul ADT-WOE)

Procesul de antrenament al modelelor ADT și ADT-WOE permite obținerea ponderilor pe care fiecare factor de condiționare a viiturii rapide le va avea în procedura de calcul FFPI. În acest sens, unghiul de pantă, Curve Number și litologia au fost clasate pe primele locuri (Fig. 2.13).




Fig. 2.12 Importanța factorilor de condiționare a viiturilor rapide

Valorile FFPI ADT variază între 0,14 și 0,86 (Fig. 2.13a). Pentru a fi cartografiate, aceste valori au fost grupate în 5 clase prin metoda Natural Breaks. Clasa de valori foarte mici acoperă aproximativ 9,7% din suprafața studiată, în timp ce a doua clasă este distribuită pe aproximativ 19,7%. Valorile medii ale FFPI ADT, cuprinse între 0,33 și 0,46, au cea mai mare pondere dintre cele cinci clase. Clasele a IV-a și a V-a sunt răspândite pe aproximativ 36,7% din suprafața totală și caracterizează suprafețele cu un potențial mare și foarte mare de apariție a viiturilor rapide. Valorile mari și foarte mari ale FFPI ADT apar uniform în toate regiunile sectorului superior și mijlociu al bazinului hidrografic al râului Prahova.

Aplicarea modelului hibrid ADT-WOE a condus la valori FFPI cuprinse între 0,07 și 0,89 (Fig. 2.13b). Un total de 34,8% din zona studiată este acoperită de valori FFPI ADT-WOE foarte scăzute și scăzute. Cele mai mari suprafețe (30,2%) sunt ocupate de valori FFPI ADT-WOE incluse în clasa medie. Aproximativ 35% din zona studiată este caracterizată de valori mari și foarte mari ale FFPI ADT-WOE, aceste suprafețe fiind localizate în special în jumătatea nordică a zonei.




Fig. 2.13 Distribuția spațială a valorilor FFPI (a. modelul ADT; b. modelul ADT-WOE)

2.5.6. Validarea rezultatelor

2.5.6.1. Densitatea zonelor torențiale în cadrul claselor FFPI

În ceea ce privește densitatea zonelor torențiale care aparțin eșantionului de antrenament, cea mai bună performanță a fost obținută de modelul hibrid ADT-WOE (Fig. 2.14a). Prin aplicarea acestui model, aproximativ 88,24% din zonele de antrenament sunt situate în clasele a IV-a și a V-a ale FFPIADT-WOE. Modelul hibrid ADT-WOE a fost urmat de: RF (84%), LMT-WOE (82,29%), RF-WoE (80,82%), LMT (80,26%), WOE (79,37%) și ADT (72,73%).

Așa cum s-a menționat în secțiunea de metodologie, zonele de validare au fost luate în considerare pentru validarea rezultatelor. În acest sens, se poate observa că ADT-WOE este cel mai bun model, cu un procent de 79,76% din totalul pixelilor torențiali (eșantion de validare) incluși în clasele a IV-a și a V-a ale FFPI ADT-WoE. Ordinea celorlalte modele în ceea ce privește acuratețea lor este următoarea: LMT-WOE (76,92%), RF (75,51%), LMT (75%), RF-WOE (71,43%), WOE (69,57%) și ADT (68,09%) (Fig. 2.14b).




Fig. 2.14 Densitatea pixelilor torențiali în cadrul claselor FFPI (a. setul de antrenament; b. setul de validare)

2.5.6.2. Curba ROC

Curba ROC reprezintă a doua metodă utilizată pentru a evalua performanțele modelelor aplicate și pentru a valida rezultatele obținute. În plus, au fost definite limitele Erorii Standard (S.E.) și Intervalului de Încredere de 95% (CI_{95%}) (Tabelul 2.4).

Pixelii zonei de antrenament au fost utilizați pentru a construi Rata de Succes utilizată pentru a evalua performanțele modelului (Fig. 2.15a). Rata de succes demonstrează capacitatea modelelor de a clasifica corect zonele predispuse la apariția viiturilor rapide în comparație cu zonele de antrenament.

Tabel 2.4 Parametrii ROC Curve pentru Rata de Succes și Rata de Predicție

Modele	Set de date de training				Set de date de validare			
	AUC	S.E.	CI _{95%}		AUC	S.E.	CI _{95%}	
			Limita inferioară	Limita superioară			Limita inferioară	Limita superioară
FFPI ADT	0.889	0.017	0.846	0.931	0.863	0.027	0.810	0.916
FFPI ADT-WOE	0.917	0.017	0.882	0.946	0.886	0.024	0.839	0.933
FFPI LMT	0.909	0.016	0.875	0.943	0.876	0.023	0.828	0.925
FFPI LMT-WOE	0.906	0.018	0.872	0.941	0.881	0.025	0.833	0.930
FFPI RF	0.910	0.018	0.877	0.943	0.825	0.028	0.770	0.881
FFPI RF-WOE	0.893	0.022	0.856	0.929	0.872	0.025	0.823	0.921
FFPI WOE	0.903	0.017	0.869	0.937	0.841	0.029	0.785	0.897

Cea mai bună performanță a fost atribuită modelului hibrid ADT-WOE (AUC = 0,917), urmat de modelul RF (AUC = 0,91), LMT (AUC = 0,909), modelul LMT-WOE (AUC = 0,906), modelul WOE (AUC = 0,903), modelul RF-WOE (AUC = 0,893) și modelul ADT (AUC = 0,889) (Fig. 2.15a).




Fig. 2.15. Curba ROC (a. Rata de Succes; b. Rata de Predicție)

Pentru a valida rezultatele celor șapte modele independente și hibride, a fost utilizată Rata de Predicție. Această reprezentare grafică, construită prin intermediul zonelor de validare, evidențiază concordanța dintre valorile observate și cele prezise ale FFPI. Și de această dată, modelul hibrid ADT-WoE a fost clasat pe primul loc ($AUC = 0,886$), urmat de modelul LMT-WOE ($AUC = 0,881$), modelul LMT ($AUC = 0,876$), modelul RF-WOE ($AUC = 0,872$), modelul ADT ($AUC = 0,863$), modelul WOE ($AUC = 0,841$) și modelul RF ($AUC = 0,825$) (Fig. 2.15b).

Trebuie menționat că modelul ADT are performanțe mai bune atunci când capabilitățile sale sunt combinate cu cele specifice metodei WOE decât în cazul în care este utilizat ca model independent. Prin urmare, se poate presupune că, cel puțin în situația actuală, modelul ADT are o performanță mai mare atunci când datele de intrare sunt reprezentate de coeficienții WOE atribuiți fiecărei clase/categorii de factori de condiționare ai viiturilor rapide.

Un alt aspect remarcabil este faptul că valorile AUC ale celor 7 modele sunt foarte apropiate, cu o diferență maximă de 0,028 în cazul Ratei de Succes și de 0,061 în ceea ce privește Rata de Predicție. Deși valorile AUC obținute pentru cele 7 modele sunt foarte apropiate, este foarte important să se analizeze dacă există o diferență semnificativă statistic între ele. Semnificația statistică a diferenței dintre valorile AUC aferente fiecăruia dintre cele șapte modele a fost testată folosind metodologia propusă de Hanley and McNeil (1982). Ca o scurtă caracterizare, pentru a estima semnificația statistică a diferenței dintre valorile AUC, această metodă ia în considerare următoarele elemente: valorile AUC, eroarea standard și numărul de cazuri pozitive (pixeli torențiali) și negative (pixeli non-torențiali) utilizate pentru a construi curba ROC. Principalele rezultate ale acestei metode sunt valoarea statistică z și nivelul de semnificație (valoarea p). Dacă p este mai mic de 0,05, diferența dintre două valori AUC comparate este semnificativă statistic.

Conform rezultatelor prezentate în Tabelul 2.5, în ceea ce privește rata de succes, comparația pe perechi a relevat o diferență semnificativă între aproape toate valorile AUC. Dintre toate cele 21 de comparații pe perechi, singura diferență care nu este semnificativă se înregistrează între modelele independente LMT ($AUC = 0,909$) și RF ($AUC = 0,91$). În ceea ce privește Rata de Predicție, rezultatele arată că toate diferențele dintre valorile AUC sunt semnificative statistic, valoarea p ridicată de 0,0013 fiind obținută în urma comparației dintre modelele LMT și RF-WOE (Tabel 2.5).

Tabel 2.5 Semnificația statistică a diferențelor dintre valorile AUC

Comparația perechilor of AUC	Rata de Succes			Rata de Predicție		
	<i>z-value</i>	<i>p-value</i>	Semnificația	<i>z-value</i>	<i>p-value</i>	Semnificația
ADT vs ADT-WOE	-39.89	<0.0001	YES	-18.26	<0.0001	YES
ADT vs LMT	-27.92	<0.0001	YES	-10.13	<0.0001	YES
ADT vs LMT-WOE	-23.56	<0.0001	YES	-14.16	<0.0001	YES
ADT vs RF	-29.39	<0.0001	YES	+27.23	<0.0001	YES
ADT vs RF-WOE	-5.37	<0.0001	YES	-6.96	<0.0001	YES
ADT vs WOE	-19.26	<0.0001	YES	+16.15	<0.0001	YES
ADT-WOE vs LMT	+12.02	<0.0001	YES	-7.83	<0.0001	YES
ADT-WOE vs LMT-WOE	+16.39	<0.0001	YES	-11.86	<0.0001	YES
ADT-WOE vs RF	+10.55	<0.0001	YES	+29.51	<0.0001	YES
ADT-WOE vs RF-WOE	+34.54	<0.0001	YES	-4.66	<0.0001	YES
ADT-WOE vs WOE	+20.69	<0.0001	YES	+18.44	<0.0001	YES
LMT vs LMT-WOE	+4.37	<0.0001	YES	-4.03	<0.0001	YES
LMT vs RF	-1.47	0.07	NO	+37.31	<0.0001	YES
LMT vs RF-WOE	+22.56	<0.0001	YES	+3.17	0.0013	YES
LMT vs WOE	+8.67	<0.0001	YES	+26.25	<0.0001	YES
LMT-WOE vs RF	-5.87	<0.0001	YES	+41.31	<0.0001	YES
LMT-WOE vs RF-WOE	+18.19	<0.0001	YES	+7.21	<0.0001	YES
LMT-WOE vs WOE	+4.31	<0.0001	YES	+30.27	<0.0001	YES
RF vs RF-WOE	+24.03	<0.0001	YES	-34.16	<0.0001	YES
RF vs WOE	+10.15	<0.0001	YES	-11.1	<0.0001	YES
RF-WOE vs WOE	-13.89	<0.0001	YES	+23.09	<0.0001	YES

2.6. Discuții

În ultima perioadă de timp, s-a înregistrat o creștere exponențială a frecvenței fenomenelor hidrologice cu risc ridicat, cum ar fi viiturile, având un efect direct asupra creșterii pagubelor materiale și a pierderilor de vieți omenești. Atenuarea efectelor negative necesită, în primul rând, identificarea zonelor susceptibile la apariția viiturilor rapide. Până în prezent, cea mai frecvent utilizată metodă pentru determinarea potențialului de apariție a viiturilor rapide este reprezentată de Flash-Flood Potential Index (FFPI). Scopul principal al prezentului studiu a fost calcularea valorilor FFPI pe sectorul superior și mijlociu al bazinului hidrografic al râului Prahova, prin utilizarea integrată a tehnicilor GIS cu cele specifice statisticii bivariate (Weights of Evidence) și domeniilor de învățare automată (Rotation Forest, Logistic Model Tree și Alternating Decision Tree). Trei modele hibride au fost formate prin combinarea modelului WOE cu fiecare dintre cele trei modele bazate pe arbori de decizie. Pentru antrenarea modelelor, a fost necesară identificarea zonelor cu fenomene torențiale din zona studiată, precum și selectarea unui număr de 12 factori de condiționare a viiturilor rapide, a căror capacitate predictivă a fost testată prin metoda selecției caracteristicilor bazate pe corelație (CFS). Conform modelului CFS, unghiul de pantă a înregistrat cea mai mare capacitate predictivă. Performanța modelelor aplicate și acuratețea rezultatelor au fost evaluate prin estimarea densității zonelor torențiale în cadrul claselor FFPI și utilizând modelul curbei ROC.

Modelul hibrid ADT-WOE a obținut cele mai bune performanțe atât pentru clasificarea rezultatelor ($AUC = 0,917$), cât și pentru validarea rezultatelor ($AUC = 0,886$). Cea mai mică performanță în ceea ce privește clasificarea rezultatelor a fost atribuită modelului ADT stand-alone ($AUC = 0,889$), în timp ce, în ceea ce privește acuratețea rezultatelor, modelul RF stand-alone a fost cel mai slab ($AUC = 0,825$). Cu toate acestea, toate modelele utilizate în acest studiu s-au dovedit a fi mai eficiente decât metoda WS subiectivă aplicată de Zaharia și colab. (2017) pentru a calcula FFPI-ul pe aceeași zonă de studiu.

Toate cele șapte modele au evidențiat partea de nord-vest a zonei de studiu ca fiind cea mai expusă la apariția viiturilor rapide. Împreună, valorile FFPI mari și foarte mari au avut ponderi totale cuprinse între 23,3% (modelul WOE) și 43,7% (modelul independent LMT) din zona de studiu.

Principala noutate a prezentului studiu constă în utilizarea a trei modele hibride și luarea în considerare a zonelor afectate în trecut de torențialitate pentru calculul FFPI.

Rezultatele acestui studiu pot fi utilizate cu succes de Institutul Național de Hidrologie și Gospodărire a Apelor din România pentru activitatea de prognoză și avertizare a viiturilor rapide, precum și de către autoritățile locale pentru a preveni construirea de noi clădiri în zonele cu potențial ridicat de viituri rapide. De asemenea, performanța ridicată care caracterizează toate modelele utilizate în calculul FFPI recomandă utilizarea acestor metode și a factorilor de condiționare ai viiturilor rapide și asupra altor zone pentru care ar trebui efectuată evaluarea susceptibilității la viituri rapide. Modul în care a fost clasificat fiecare factor de condiționare a viiturilor rapide și cel puțin ponderile celor mai importanți factori de condiționare a viiturilor rapide pot reprezenta un reper pentru studiile efectuate în alte bazine hidrografice, inclusiv în cele din afara României.

2.7. Concluzii

Capitolul 2 evidențiază eficacitatea abordărilor bazate pe arbori de decizie și hibride de învățare automată în îmbunătățirea evaluării potențialului de viituri rapide. Abordând limitele Indicelui tradițional de Potențial de Viituri rapide (FFPI) - în special presupunerea unei ponderări egale a factorilor de condiționare - studiul introduce un cadru mai avansat care integrează date istorice despre inundații și scheme de ponderare bazate pe date.

Implementarea unor modele precum Alternating Decision Trees (ADT), în combinație cu tehnici de amplificare și abordări hibride (de exemplu, ADT-WoE), îmbunătățește semnificativ acuratețea predicției. Rezultatele validării, inclusiv analiza curbei ROC, indică performanțe

ridicate ale modelului, modelele hibride depășind constant abordările independente. Aceste constatări confirmă faptul că încorporarea atât a învățării statistice, cât și a datelor istorice ale evenimentelor duce la o identificare mai fiabilă a zonelor predispuse la viituri rapide.

O contribuție importantă a acestui capitol este identificarea celor mai influenți factori de condiționare, cum ar fi panta, conectivitatea hidrologică și caracteristicile utilizării terenurilor, precum și delimitarea spațială a zonelor cu risc ridicat, în special în regiunile dezvoltate economic și vulnerabile, cum ar fi bazinul râului Prahova. Rezultatele demonstrează că o proporție semnificativă din zona studiată prezintă un potențial de viituri rapide de la mediu la foarte ridicat, subliniind urgența implementării unor strategii specifice de gestionare a riscurilor. În ciuda performanței puternice a modelelor, rămân anumite limitări, inclusiv potențiale incertitudini legate de calitatea datelor de intrare și de reprezentarea evenimentelor torențiale din trecut. Cu toate acestea, toate modelele aplicate s-au dovedit superioare metodelor subiective tradiționale, confirmând avantajele tehnicilor de învățare automată în evaluarea pericolelor.

În concluzie, acest capitol oferă un avans metodologic valoros în modelarea susceptibilității la viituri rapide. Utilizarea modelelor hibride de tip arbore de decizie oferă o precizie predictivă ridicată și aplicabilitate practică, sprijinind sistemele de avertizare timpurie, planificarea spațială și elaborarea politicilor. Cercetările viitoare ar trebui să se concentreze pe extinderea setului de date, testarea unor metode de ansamblu suplimentare și aplicarea modelelor în alte regiuni geografice.

Capitolul 3. Detectarea zonelor susceptibile la viituri rapide în bazine hidrografice mici cu ajutorul inteligenței artificiale

Capitolul 3 se focusează pe aplicarea metodelor de inteligență artificială în vederea identificării zonelor din bazinele hidrografice cu suprafețe mici care sunt favorabile formării viiturilor rapide, reprezentând totodată expunerea celei de-a treia subdirecții de cercetare din prezenta lucrare. Acest capitol s-a bazat pe rezultatele obținute în cadrul a două articole științifice și un proiect de cercetare, acestea fiind menționate mai jos:

Costache, R., Hong, H., & Pham, Q. B. (2020). *Comparative assessment of the flash-flood potential within small mountain catchments using bivariate statistics and their novel hybrid integration with machine learning models*. Science of the Total Environment, 711, 134514.

DOI: <https://doi.org/10.1016/j.scitotenv.2019.134514>.

Abedi R., **Costache R.**[#], Shafizadeh-Moghadam H., Pham Q.B. (2022) *Flash-flood susceptibility mapping based on XGBoost, Random Forest and Boosted Regression Trees*, Geocarto International. 37(19), 5479-5496. DOI: <https://doi.org/10.1080/10106049.2021.1920636>.

- **PN-III-P1-1.1-PD-2019-0424-P** - Analiza integrată a susceptibilității la viituri rapide și inundații la nivelul României utilizând algoritmi de învățare automată și statistici bivariate (acronim: **RO-FLOOD-SUSCEP**); **Contract nr.:** PD226 / 08.04.2021; **Proiect de Cercetare Postdoctorală** finanțat de UEFISCDI prin **Programul 1** - Dezvoltarea sistemului național de cercetare-dezvoltare din **PN III. Perioada:** 08.04.2021 – 31.12.2022.

3.1. Introducere

Același indice de potențial de formare a viiturilor rapide (FFPI) va fi utilizat și în prezentul capitol 4 pentru a exemplifica modalitatea în care modelele de inteligență artificială pot ajuta la detectarea zonelor susceptibile la viituri rapide în bazine hidrografice mici. Bazinele hidrografice mici, cu suprafața, în general, mai mică de 500 km² sunt cele mai predispuse la aceste fenomene naturale de risc. Pe plan național acest lucru este dovedit de mai multe evenimente istorice care s-au soldat cu pagube materiale importante și victime omenești. Cele mai recente evenimente severe s-au produs în județele Galați și Vaslui în luna Septembrie a anului 2024. Astfel, conform rapoartelor Inspectoratului General pe Situații de Urgență (IGSU) au fost afectate peste 6000 de case, fiind direct vizați peste 20000 de oameni. Au fost consemnate de

asemenea 7 victime omenești. Valoarea totală a pagubelor a fost estimată la peste 100 de milioane de euro, evidențiind amploarea dezastrului. Totodată, frecvența tot mai ridicată a acestor fenomene este evidențiată și de activitatea Institutului Național de Hidrologie și Gospodărire a Apelor din România care a emis în ultimii anii în medie peste 200 de coduri de avertizare pentru viituri rapide (galben, portocaliu și roșu). În acest context, detectarea precisă a zonelor predispuse la formarea viiturilor rapide din bazinele hidrografice mici este foarte importantă în vederea adoptării celor mai potrivite măsuri de combatere a pagubelor și evitării pierderilor de vieți omenești.

Studiul de față este focusat pe bazinul hidrografic al râului Bâsca Chiojdului și propune utilizarea Rețelelor Neuronale Artificiale (Perceptronul Multistrat sau Multilayer Perceptron-MLP) în combinație cu Indicele Statistic (o metodă aferentă statisticilor bivariate) pentru identificarea detaliată a zonelor susceptibile la formarea viiturilor rapide. În vederea comparării rezultatelor obținute și cu alte modele de machine learning vor mai fi utilizate următoarele patru metode: Regresia Logistică (Logistic Regression - LR), Classification and Regression Tree (CART), Random Forest (RAF) și Support Vector Machine (SVM). Performanța modelelor hibride va fi evaluată prin intermediul mai multor măsuri statistice reprezentate de Senzitivitate, Specificitate, Acuratețe și Indicele Kappa, în timp ce validarea valorilor FFPI se va realiza prin intermediul Curbei ROC.

3.2. Studiu de caz

Bazinul hidrografic al râului Bâsca Chiojdului se află plasat în zona central sud-estică a României. Zona studiată se suprapune atât peste regiunea carpatică (muntoasă) (44%), cât și peste regiunea subcarpatică (deluroasă) (56%) (Fig. 3.1). Suprafața redusă a bazinului hidrografic (340 km²) se coroborează cu o pantă medie de 12°, precum și cu o formă circulară a bazinului hidrografic, generând condiții favorabile pentru scurgerea de suprafață și apariția viiturilor rapide. Alți factori geografici care influențează scurgerea de suprafață sunt gradul de acoperire forestieră (50%), care a fost determinat pe baza setului de date Corine Land Cover 2018 (Kucsicsa et al., 2019), și grupa hidrologică de sol (predominant grupa B), care a fost extrasă din Harta Digitală a Solurilor a României, 1:200000 (Arghiuș and Arghiuș, 2011). Conform Costache and Zaharia (2017), timpul mediu de întârziere (Tlag) al bazinului hidrografic Bâsca Chiojdului este egal cu 4,36 ore, în timp ce timpul de concentrare (Tc) este de aproximativ 7,27 ore. Valorile mici ale celor doi parametri, Tlag și Tc, indică, de asemenea, faptul că bazinul hidrografic Bâsca Chiojdului este susceptibil la apariția viiturilor rapide.




Fig. 3.1 Localizarea bazinului hidrografic al râului Bâsca Chiojdului în România

În perimetrul bazinului hidrografic Bâsca Chiojdului se găsesc numeroase obiective socio-economice expuse la apariția viiturilor rapide. Aceste obiective sunt amplasate în următoarele 6 localități care cuantifică un număr total de 25417 locuitori: Calvini, Poseștii-Pământeni, Bătrâni, Starchiojd, Chiojdu și Cătina. În perimetrul acestor localități se află, de asemenea, 331 km de drumuri, dintre care cele mai importante sunt: Drumul Național 10 (DN 10) cu o lungime totală de 1,3 km, Drumul Județean 102B (DJ 102B) cu o lungime totală de 21,3 km, Drumul Județean 103P (DJ 103P) cu o lungime totală de 907 m, Drumul Județean 102L (DJ 102L) cu o lungime totală de 20,7 km și Drumul Județean 100M (DJ 100M) cu o lungime totală de 720 m. De-a lungul timpului, aceste elemente socio-economice au fost afectate de numeroase fenomene severe de viiturilor rapide. Cele mai devastatoare viiturilor rapide au avut loc în 1975, când debitul Bâsca Chiojdului a atins valoarea maximă istorică de $300 \text{ m}^3/\text{s}$, în 1990 când debitul a fost egal cu $170 \text{ m}^3/\text{s}$ și în 2005 când valorile debitului au fost de $236 \text{ m}^3/\text{s}$. Viituri rapide importante s-au manifestat și în ultimii ani (2016, 2018 și 2019), când, potrivit Inspectoratului General pentru Situații de Urgență din România, aproape 350 de persoane au fost afectate, iar peste 120 de case și 5,3 km de drumuri au fost distruse de aceste riscuri naturale. De

asemenea, trebuie menționat că, potrivit Administrației Naționale a Apelor Române, aproape 27 km aparținând râului Bâsca Chiojdului, situat în aval de localitatea Chiojdu, reprezintă un sector cu potențial ridicat de inundații, declanșate de viituri rapide propagate din zonele superioare.

3.3. Date

Detectarea și cartarea suprafețelor afectate de torențialitate în bazinul hidrografic Bâsca Chiojdului a constituit prima etapă a prezentului studiu. Utilitatea integrării acestor informații în cercetarea de față se explică prin faptul că viiturile rapide sunt mai susceptibile de a se produce în zonele cu caracteristici similare cu cele în care au avut loc deja. În plus, este necesară înțelegerea relației spațiale dintre prezența proceselor torențiale și predictorii viiturilor rapide. Prin urmare, zonele afectate de torențialitate au fost digitalizate pe baza imaginilor aeriene și a măsurătorilor de teren. Au fost considerate suprafețele cu o prezență unitară a microformelor torențiale, cum ar fi ravenele și rigolele (Costache și Zaharia, 2017). După această etapă, un număr de 36 de poligoane, cu o suprafață totală de aproximativ 34 km², au fost identificate ca fiind afectate de torențialitate. Aceste suprafețe reprezintă 10% din aria studiată. 70% din totalul zonelor digitizate au fost utilizate ca set de date de antrenament, în timp ce 30% au fost utilizate pentru validarea rezultatelor. Pentru a împărți aceste zone în seturi de date de antrenament și validare, s-a utilizat instrumentul Generate Subset Polygons din ArcGIS Pro 2.2. Pentru a fi utilizat în prezentul studiu, suprafețele afectate de fenomenele torențiale au fost transformate din format shapefile poligon în raster cu o dimensiune a celulei de 30 de metri. Această rezoluție spațială a fost aleasă deoarece este egală cu dimensiunea celulei Modelului Digital de Elevație (DEM) extras din baza de date Shuttle Radar Topography Mission (SRTM) (Mamede da Silva et al., 2018). DEM-ul reprezintă sursa de date pentru un număr de 7 factori morfometrici luați în considerare în prezenta analiză, care au fost prezentați la 2.1.2. Prin urmare, un număr total de 37723 de pixeli au fost identificați ca fiind afectați de fenomenele torențiale. În plus, un număr de 26406 pixeli au fost incluși în datele de antrenament, iar ceilalți 11317 au fost incluși în setul de date de validare. Deoarece maparea potențialului de formare a viiturilor rapide se bazează pe o clasificare binară a pixelilor, a fost creat un alt set de date, reprezentând zonele neafectate de fenomene torențiale. Acest set de date conține același număr de pixeli (37723) ca și setul de date pentru zonele torențiale și a fost creat printr-o selecție aleatorie de pixeli localizați în general pe suprafețe cu un unghi de pantă mic, apropiat de 0°, unde scurgerea superficială este aproape imposibilă. Trebuie menționat că

setul de date netorential a fost împărțit și în eșantioane de antrenament (70%) și eșantioane de validare (30%). Deoarece zonele de antrenament și validare vor fi utilizate ca set de date binar, valoarea 1 a fost atribuită regiunilor cu procese torențiale, în timp ce valoarea 0 a fost atribuită zonelor caracterizate prin absența fenomenelor torențiale.

În cazul prezentului studiu de caz au fost selectați pentru modelarea FFPI un număr de 10 factori geografici care influențează formarea viiturilor rapide. Dintr-un număr total de zece predictor, următoarele șapte variabile sunt factori morfometrici derivați din Modelul Digital de Elevație: panta, L-S factor, indicele de convergență al rețelei hidrografice, Stream Power Index (SPI), indicele de umiditate topografică (TWI), curbura în profil și Topographic Position Index (TPI). Ceilalți trei predictor, extrași din baza de date vectorială, sunt următorii: utilizarea terenului, grupa hidrologică de sol și litologia.

Pentru a obține distribuția spațială a valorilor pantei pe zona studiată, s-a utilizat instrumentul Slope din extensia Spatial Analyst a software-ului ArcGIS 10.5. DEM-ul a fost utilizat ca date de intrare în instrumentul menționat anterior. În cazul prezentului studiu, harta pantei a fost realizată prin împărțirea valorilor acesteia în următoarele cinci clase, conform literaturii de specialitate (Costache și Zaharia, 2017): $<3^\circ$, $3^\circ - 7^\circ$, $7,1^\circ - 15^\circ$, $15,1^\circ - 25^\circ$, $>25^\circ$ (Fig. 1a). L-S Factor este un indice morfometric utilizat pe scară largă pentru a estima efectul combinat al lungimii pantei și al abrupției pantei asupra manifestării scurgerilor de suprafață (Costache, 2019b; Zaharia et al., 2017b, 2015). Derivarea factorului L-S se bazează pe următoarea formulă (Moore and Wilson, 1992):

$$LS = \left(\frac{A_s}{22.13}\right)^m \left(\frac{\sin(\theta)}{0.0896}\right)^n \quad (3.1)$$

unde A_s este suprafața unitară contributivă (m^2), θ este valoarea pantei în radiani, m (0,4 – 0,56) și n (1,2 – 1,3) sunt exponenți. În ceea ce privește bazinul hidrografic Bâsca Chiojdului, factorul L-S a fost calculat utilizând DEM ca intrare în modulul Analiză de bază a terenului din SAGA GIS 2.1.4. Valorile exponenților m și n au fost optimizate automat de software-ul GIS în funcție de caracteristicile DEM-ului utilizat ca date de intrare. Valorile factorului L-S au fost clasificate în următoarele clase pe baza metodei Natural Breaks: 0 – 3,75; 3,76 – 7,17; 7,18 – 10,75; 10,76 – 15,33; 15,34 – 41,49 (Fig. 3.2e). Un alt factor ale cărui valori au fost calculate folosind Modelul Digital de Elevație (DEM) este Topographic Wetness Index (TWI). Ca și în cazul L-S Factor, metoda Natural Breaks a fost utilizată și pentru a împărți valorile TWI după cum urmează: 3,15 – 6,1; 6,11 – 7,78; 7,79 – 10,21; 10,22 – 14,5; 14,51 – 24,59 (Fig. 3.2i). Mai

departe Clasificarea valorilor TPI s-a realizat prin metoda Natural Breaks după cum urmează: $(-20) - (-3,8)$; $(-3,7) - (-1,1)$; $(-1,1) - 1,3$; $1,4 - 4,5$; $4,6 - 20$ (Fig. 3.2h).




Fig. 3.2 Factorii de condiționare ai viiturilor rapide (a. panta, b. utilizarea terenurilor, c. indicele de convergență a rețelei hidrografice, d. litologia, e. L-S Factor, f. grupa hidrologică de sol, g. Stream Power Index, h. Topographic Position Index, i. Topographic Wetness Index, j. curbura în profil)

Metoda Natural Breaks a fost utilizată pentru a clasifica valorile predictorilor de viituri rapide L-S Factor, TWI și TPI, deoarece este considerată o metodă de clusterizare care creează una dintre cele mai bune aranjamente de valori în diferite clase și determină minimizarea varianței pentru obiectele din subseturile alese și maximizarea varianței între subseturi (Rosati et al., 2010). Harta curburii profilului a fost creată prin împărțirea valorilor sale în trei clase, conform literaturii de specialitate (Minea, 2013b): (-3) – 0, 0,1 – 0,9, 1 – 2 (Fig. 3.2j). Totodată pentru Indicele de convergență s-a utilizat de asemenea literatura de specialitate în vederea stabilirii claselor: (Costache et al., 2019): (-99) – (-3), (-2.9) – (-2), (-1.9) – (-1), (-0.9) – 0, 0 – 99 (Fig. 3.2c). Stream Power Index (SPI), derivat din DEM, evidențiază capacitatea unui râu de a transporta sedimentele de-a lungul văii unui râu (Moore et al., 1991). Calculul său se bazează pe următoarea formulă:

$$SPI = \alpha \times \tan\beta \quad (3.2)$$

unde α reprezintă regiunea totală în pantă ascendentă care drenează printr-un punct (pe unitatea de lungime a conturului) și $\tan \beta$ reprezintă valoarea unghiului de pantă măsurată în acest punct. Valorile SPI au fost împărțite în următoarele clase: < 50; 50 – 500; 501 – 2000; 2001 – 5000; > 5000 (Fig. 3.2g).

În zona de cercetare au fost identificate următoarele 8 categorii de utilizare a terenurilor: zone construite, zone agricole, podgorii, pomi fructiferi, pășuni, păduri, arbuști de tranziție și corpuri de apă (Fig. 3.2b). În ceea ce privește bazinul râului Bâsca Chiojdului, sunt prezente toate cele 4 grupe hidrologice de sol (Fig. 3.2f). Un alt factor care exercită o influență importantă asupra procesului de infiltrare a apei este litologia. În zona de cercetare au fost cartate un număr de 10 grupe litologice (Fig. 3.2d).

Pentru a fi utilizați în fluxurile de lucru actuale, următorii factori de condiționare ai viiturilor rapide au fost transformați dintr-un format vectorial poligonal într-un format raster cu dimensiunea celulei de 30 m: utilizarea terenului/acoperirea terenului, grupul hidrologic de sol și litologia.

3.4. Metode

Pentru a estima susceptibilitatea la viituri rapide pentru bazinul hidrografic Bâsca Chiojdului, datele colectate, prezentate mai sus, au fost incluse în mai multe etape de procesare metodologică. Schema întregului flux de lucru metodologic este reprezentată grafic în Fig. 3.3.




Fig. 3.3 Schema fluxului de lucru implementat pentru calculul potențialului de viituri rapide

3.4.1. Evaluarea multicoliniarității

În acest studiu, s-a utilizat analiza multi-colinearității pentru a evalua inter-asocierile sau corelația dintre predictorii viiturilor rapide. Multi-colinearitatea apare atunci când predictorii au o corelație ridicată între ei. Aceasta poate cauza descrierea greșită a factorilor relevanți în modelele statistice și, prin urmare, poate afecta rezultatele modelelor (Dou et al., 2019). Prin urmare, factorul de inflație a varianței (VIF) și toleranța (TOL) au fost utilizați pentru a detecta multi-colinearitatea dintre predictorii în acest studiu. Fie $X = \{X_1, X_2, \dots, X_N\}$ care definesc predictorii independenți, iar R_j^2 indică coeficientul de determinare atunci când al j -lea predictor independent X_j este regresat asupra tuturor celorlalți predictorii din model. VIF-ul se calculează după cum urmează:

$$VIF = \frac{1}{1 - R_j^2} \quad (3.3)$$

Dacă valoarea $VIF > 10$ sau valoarea $TOL < 0,1$, predictorii corespunzători sunt coliniari și trebuie eliminați din modelele de predicție (Dou et al., 2019).

3.4.2. Information Gain (IG) pentru estimarea capacității de predicție

Datorită faptului că anumiți factori geografici, dintre cei luați în considerare pentru prezenta analiză, au o influență redusă asupra scurgerii de suprafață, s-a realizat o selecție a predictorilor

viiturilor rapide, bazată pe un model statistic. Metoda Information Gain (IG) este una dintre cele mai populare metode în acest tip de cercetare (Dai and Ji, 2014; Gao et al., 2017; Javidi and Mansoury, 2017) și, prin urmare, a fost utilizată și în prezentul studiu. Metoda IG, propusă de Hunt et al. (1966), este foarte utilă pentru a evalua un atribut al calității. Valoarea IG pentru fiecare predictor al viiturii rapide a fost estimată folosind următoarea formulă (3.4) (Chen et al., 2018a):

$$IG(Y|X_i) = H(Y) - H(Y|X_i) \quad (3.4)$$

unde $H(Y)$ este valoarea entropiei lui Y și $H(Y|X_i)$ este entropia lui Y după asocierea valorilor factorului de condiționare a viiturii rapide X_i (Chen et al., 2018).

Într-o primă etapă, calculul valorilor IG a presupus pregătirea datelor privind prezența și absența fenomenelor torențiale în software-ul ArcGIS 10.5. Datele au fost procesate în același tabel de atribute, împreună cu datele privind factorii de condiționare. Ulterior, tabelul de atribute rezultat a fost procesat în software-ul Microsoft Excel 2016. Aceste date au fost importate ulterior în software-ul WEKA v. 3.8.6 dezvoltat de Universitatea din Waikato, Hamilton, Noua Zeelandă (Hall et al., 2009). Folosind acest software, dedicat în principal aplicațiilor de învățare automată, au fost calculate valorile IG pentru fiecare factor de condiționare a viiturilor rapide.

3.4.3. Statistical Index (SI)

Această metodă a fost utilizată pentru prima dată într-o cercetare privind riscurile naturale de către van Westen (1997). În cadrul acestei metode, ponderea unei clase sau categorii de factori în rezultatul final (FFPI SI) este considerată a fi logaritmul natural al densității fenomenelor torențiale din cadrul acelei clase sau categorii de factori împărțit la densitatea fenomenelor torențiale pe întreaga zonă de studiu (Rautela and Lakhera, 2000). Ponderile indicelui statistic pentru fiecare clasă/categorie de factori au fost calculate folosind următoarea formulă, de către Van Westen et al. (1997):

$$W_{ij} = \ln \left(\frac{f_{ij}}{f} \right) = \ln \left(\frac{\frac{Npix(S_i)}{Npix(N_i)}}{\frac{\sum Npix(S_i)}{\sum Npix(N_i)}} \right) \quad (3.5)$$

unde: W_{ij} – este ponderea acordată unei anumite clase/categorii i a parametrului j ; f_{ij} - este densitatea pixelilor torențiali din clasa i a parametrului j , f - este densitatea pixelilor torențiali din întreaga hartă, $Npix(S_i)$ este numărul de pixeli torențiali din clasa de parametri i , iar $Npix(N_i)$ este numărul total de pixeli din aceeași clasă de parametri.

Pentru a aplica Statistical Index model, a fost dezvoltat un flux de lucru care a implicat utilizarea software-ului ArcGIS 10.5, precum și a software-ului Microsoft Excel 2016. Prin urmare, într-o primă etapă, rasterele corespunzătoare factorilor de condiționare ai viiturilor rapide și suprafețelor cu procese torențiale au fost importate în mediul GIS. Mai departe, pentru a cuantifica numărul de pixeli torențiali din cadrul fiecărei clase/categorii de factori, fiecare raster corespunzător unui singur factor de condiționare a viiturilor rapide a fost combinat cu rasterul corespunzător regiunilor cu procese torențiale. După această etapă, pentru a determina ponderile finale ale unei clase/categorii de factori, datele au fost procesate în Microsoft Excel 2016. Ponderile deja obținute au fost atribuite fiecărei clase/categorii de factori în software-ul ArcGIS 10.5. Odată ce valorile ponderilor au fost atribuite fiecărei clase/categorii, FFPI SI a fost calculat prin operația de însumare implementată în Algebra Cartografică. Ponderile pozitive evidențiază o clasă/categorie favorabilă fenomenului de viituri rapide, în timp ce o valoare negativă a ponderii evidențiază o clasă/categorie care reduce potențialul de apariție a viiturilor rapide.

3.4.4. Regresia Logistică (Logistic Regression)

Scopul principal al metodei de regresie logistică este de a determina modelul cel mai potrivit care descrie relația dintre variabila binară dependentă (Y) și un set de variabile independente (explicative) (Kavzoglu et al., 2014; Lee and Pradhan, 2007; Pradhan, 2010; Pradhan and Lee, 2010). În modelul de regresie logistică, o variabilă dependentă este formată doar din două clase/categorii (prezență și absență). Prin urmare, modelul de regresie logistică este util în principal pentru a prezice prezența sau absența unui anumit fenomen, predicție bazată pe valorile variabilelor independente și, de asemenea, pe relația dintre variabilele dependente și independente. Variabilele luate în considerare în modelul de regresie logistică pot fi continue, discrete sau o combinație a ambelor.

Modelul liniar generalizat al metodei de regresie logistică poate fi calculat folosind următoarea ecuație (Bui et al., 2011; Kavzoglu et al., 2014; Pradhan, 2011):

$$p = \frac{1}{1 + e^{-Z}} \quad (3.6)$$

unde p este probabilitatea unui eveniment, Z este o valoare de la $-\infty$ la $+\infty$, definită de următoarea ecuație:

$$Z = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (3.7)$$

unde b_0 este intersecția cu axa modelului, β_i ($i=0, 1, 2, \dots, n$) sunt coeficienții de pantă ai modelului de regresie logistică, iar x_i ($i=0, 1, 2, \dots, n$) sunt variabilele independente.

Atunci când variabilele predictoare sunt puternic corelate într-un model logistic, se poate presupune că există o multicoliniaritate între variabilele independente (Midi et al., 2010). Multicoliniaritatea poate duce la estimări inexacte și poate afecta, de asemenea, testele de ipoteze și intervalele de încredere (Midi et al., 2010). În lucrarea de față, diagnosticul de multicoliniaritate între variabilele independente va fi evaluat conform procedurii descrise la 3.4.1.

3.4.5. Classification and regression tree (CART)

Tehnica de învățare automată a fost utilizată în special în studii privind susceptibilitatea la alunecări de teren (Felicísimo et al., 2013; Hong et al., 2015b; Pradhan, 2013; Yeon et al., 2010; Youssef et al., 2016). CART este o metodă bazată pe reguli care prezintă informațiile într-un mod intuitiv și ușor de vizualizat. Trei tipuri de variabile independente au putut fi incluse în analiză (numerice, binare și categoriale), acest fapt fiind un alt avantaj al acestei tehnici. Pentru a construi arborii, fiecare predictor este selectat astfel încât să se reducă erorile de date. Măsura față de care un predictor este preferat în raport cu altul este valoarea entropiei.

O valoare lipsă a unui anumit predictor nu va fi utilizată pentru a determina ramificația optimă a unui arbore. Dacă se utilizează CART pentru a prezice date noi, valorile lipsă sunt gestionate de substitute (surrogate) (Breiman et al., 1984). Valorile prezise ale unui nod terminal reprezintă media valorilor de răspuns din acel nod (Breiman et al., 1984). În algoritmul CART, există o regulă de eșantionare optimă numită remorcare modificată, care se bazează pe o comparație directă a atributului țintă în două noduri copil. Acest proces se realizează conform ecuației (3.8):

$$I(Split) = [0.25(q(1 - q))^u \sum_k |PL(k) - PR(k)|]^2 \quad (3.8)$$

unde: k este indicele claselor țintă, $PL(k)$ și $PR(k)$ reprezintă distribuțiile de probabilitate ale țintei în nodurile copil stânga și respectiv dreapta, iar termenul de putere u încorporează o penalizare controlabilă de utilizator asupra diviziunilor care creează noduri copil cu dimensiuni inegale (Wu et al., 2008).

Rezultatul algoritmului CART este un arbore decizional complex care trebuie eliminat pentru a păstra doar cele mai importante informații.

3.4.6. Multilayer Perceptron (MLP)

MLP este una dintre cele mai utilizate rețele neuronale artificiale. Este o tehnică eficientă care poate surprinde relația neliniară complexă dintre predictorii și un fenomen specific (Jahani and Mohammadi, 2019). Acest model a fost utilizat în multe domenii, cum ar fi predicția spațială a

inundațiilor (Costache and Bui, 2019) și evaluarea susceptibilității la alunecări de teren (Pham et al., 2017). Prin intermediul algoritmului de propagare inversă, ponderile structurii rețelei feed-forward sunt actualizate și optimizate (Costache and Bui, 2019). Prin urmare, se poate distinge o etapă de antrenament înainte și o etapă de antrenament înapoi (Costache and Bui, 2019). În etapa înainte, intrările sunt propagate înainte prin stratul ascuns pentru a calcula clasele de ieșire care sunt comparate cu valorile observate pentru a estima diferența dintre ele. În etapa înapoi, ponderile conexiunilor au fost ajustate pentru a îmbunătăți ieșirea cu eroarea medie pătratică (RMSE, ec. 3.9). Pentru a obține o valoare acceptabilă a RMSE, procesul deja descris va fi repetat iterativ.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (c_i - \hat{c}_i)^2} \quad (3.9)$$

unde n este numărul de pixeli torențiali, c_i și $\hat{c}_i$ sunt valorile potențialului de viituri rapidă observate și, respectiv, valorile potențialului de viituri rapide calculate.

3.4.7. Random Forest (RAF)

Random Forest (RAF), dezvoltat de (Breiman, 2001), sunt metode de învățare ansamblu foarte flexibile și puternice, bazate pe arbori decizionali, care pot fi utilizate atât pentru clasificare, cât și pentru predicție. Recent, RAF a fost aplicat în diferite domenii pentru a rezolva probleme de clasificare (Ibarra-Berastegi et al., 2011; Arabameri et al., 2019; Dou et al., 2019; Pham et al., 2019; Woznicki et al., 2019). RAF poate fi definit ca un grup de arbori aleatorii (arbori decizionali). RAF se bazează pe ideea fundamentală de a crește mai mulți arbori decizionali pe subseturi aleatorii în următorii pași: i) se iau datele de antrenament și se reeșantionează datele de mai multe ori; ii) se selectează un set de caracteristici aleatorii pentru fiecare reeșantionare; iii) se determină un arbore decizional pentru reeșantionarea dată și un set aleatoriu de caracteristici; iv) se agregă setul de arbori decizionali determinați pentru a obține un singur arbore decizional. Fiecare arbore decizional contribuind cu un vot, clasa care a primit cele mai multe voturi este clasa de predicție finală (Woznicki et al., 2019). În acest studiu, RF a fost implementat pentru a clasifica două clase, inclusiv valoarea „0”, care a fost atribuită zonelor caracterizate prin absența fenomenelor torențiale, și valoarea „1”, care a fost atribuită regiunilor cu procese torențiale.

3.4.8. Support Vector Machine (SVM)

SVM este o metodă de învățare automată bazată pe principiul minimizării riscului structural din teoria învățării statistice. Într-o clasificare binară, obiectivul principal al algoritmului SVM este

de a găsi un hiperplan care să poată diviza datele de antrenament într-un mod optim. Hiperplanul este construit prin transformarea spațiului de intrare original într-un spațiu de caracteristici de dimensiuni superioare (Naghibi et al., 2017). Odată ce hiperplanul optim este delimitat, pot fi identificați vectorii suport situați cel mai aproape de hiperplan (Pham et al., 2019). După identificarea vectorilor suport și definirea hiperplanului optim, se va utiliza o funcție kernel specifică pentru a transforma datele de intrare în două clase distincte (Choubin et al., 2019). Conform lui Naghibi et al. (2017), dacă punctele claselor sunt situate deasupra hiperplanului, acestea vor fi clasificate ca pozitive (pixeli torențiali = 1), în timp ce dacă sunt situate sub hiperplan, punctele vor fi clasificate ca negative (pixeli non-torențiali = -1). În ceea ce privește funcția kernel, în cercetarea de față se va utiliza funcția Radial Basis, deoarece aceasta depășește alte funcții kernel, cum ar fi: liniară, polinomială și sigmoidă (Choubin et al., 2019; Tien Bui et al., 2012).

3.5. Configurarea modelelor hibrid pentru calcularea FFPI

Pentru a configura cele cinci modele hibride utilizate pentru calculul FFPI, coeficienții SI determinați urmând procedura descrisă la 3.4.3. au fost utilizați ca date de intrare în modelele de învățare automată. Conform literaturii de specialitate (Cherukuri et al., 2019), datele utilizate ca date de intrare în algoritmi de învățare automată ar trebui rescalate în același interval de valori. Prin urmare, coeficienții SI au fost normalizați între 0,1 și 0,9. De asemenea, este important de menționat că eșantionul de antrenament, care reprezintă 70% din totalul suprafețelor torențiale, a fost împărțit într-un alt eșantion de antrenament (70%) utilizat pentru rularea modelelor și un eșantion de testare utilizat pentru testarea performanțelor modelelor (30%). Astfel, noul eșantion de antrenament va conține 18482 pixeli torențiali și 18482 pixeli non-torențiali, în timp ce eșantionul de testare va conține 7922 pixeli torențiali și 7922 pixeli non-torențiali.

3.5.1. LR-SI

În analiza de față, zonele cu prezență/absența fenomenelor torențiale, din bazinul râului Bâsca Chiojdului, reprezintă variabila binară. Pentru a fi incluse în analiză, zonelor afectate de fenomene torențiale li s-a atribuit valoarea 1, iar zonelor fără fenomene torențiale li s-a atribuit valoarea 0. În continuare, următorul pas al analizei a constat în combinarea fiecărui raster reprezentând factorii de condiționare ai viiturilor rapide, având un coeficient SI atribuit, cu rasterul reprezentând prezența sau absența fenomenelor torențiale. Datele rezultate în format tabelar au fost utilizate ulterior în software-ul SPSS, unde s-a efectuat analiza de regresie

logistică. Un parametru foarte important utilizat în modelarea Regresiei Logistice (LR) este valoarea limită de clasificare, care de obicei este setată implicit la 0,5. Deși, în analiza de față, pentru a stabili cea mai bună valoare-prag, modelarea LR a fost repetată utilizând un număr de unsprezece valori-prag (0.01, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9 și 0.99) conform literaturii de specialitate (Soureshjani and Kimiagari, 2013). În final, va fi aleasă valoarea-prag care permite obținerea celor mai bune performanțe, demonstrată de cea mai mare valoare a sumei dintre Specificitate și Senzitivitate a modelului. În plus, pentru a evalua semnificația datelor de intrare, calitatea modelului aplicat, precum și pentru a analiza supradispersia, au fost calculați și următorii parametri: eroarea standard (S.E.), Wald χ^2 cu valoare p, deviația reziduală (RD), gradul de libertate (DF) și Criteriile Informaționale Akaike (AIC). Mai exact, prezența supradispersiei, care poate afecta rezultatele regresiei logistice, este indicată de o diferență mare între valorile RD și DF (Aitkin, 1996). Ponderea finală a fiecărei variabile independente va fi egală cu valoarea coeficienților de regresie logistică (β_i). Conform ecuației (9), valorile Z ale fiecărei celule raster vor fi derivate în mediul GIS prin însumarea valorii constante a intersecției cu modelul (β_0) și a rasterelor predictorilor de viituri rapide (x_i), fiecare dintre ele fiind înmulțită cu coeficientul (β_i). Trebuie ținut cont de faptul că rasterelor predictorilor de viituri rapide li se vor atribui valori SI. În plus, pentru a deriva valorile FFPI în algebra cartografică, în ecuația (8) se va utiliza rasterul având valorile celulelor egale cu Z.

3.5.2. CART-SI

Construirea arborelui decizional prin algoritmul CART a fost posibilă utilizând datele de intrare reprezentate de coeficienții SI și absența/prezența zonelor torențiale în software-ul Salford Predictive Modeler v 8.2 (Fitriani and Siahaan, 2016). Anumiți parametri specifici, utilizați pentru antrenarea modelului CART, au fost optimizați după un proces de testare prin care au fost determinate cele mai bune valori ale AUC. Optimizarea parametrilor a fost realizată cu ajutorul unui eșantion de testare care numără 15844 pixeli. Astfel, numărul minim de cazuri de noduri părinte a fost stabilit la 28, numărul minim de cazuri de noduri terminale a fost stabilit la 13, dimensiunea eșantionului este egală cu numărul de pixeli torențiali și netorențiali din datele de antrenament (aproximativ 37000), iar adâncimea arborelui a fost stabilită automat de software după aplicarea parametrilor menționați anterior.

3.5.3. MLP-SI

Coeficienții SI au fost utilizați și ca date de intrare în modelul Multilayer Perceptron (MLP), care a fost rulat în software-ul SPSS 21. În cazul de față, arhitectura ansamblului MLP-SI constă din

următoarele elemente: i) un strat de intrare care include opt neuroni reprezentați de predictorii de viituri rapide; ii) un strat ascuns cu un număr specific de neuroni; iii) un strat de ieșire cu 2 neuroni reprezentați prin prezența și absența fenomenelor torențiale. Un pas foarte important în configurarea și antrenarea ansamblului MLP-SI este stabilirea numărului optim de neuroni ascunși în cadrul stratului ascuns. Conform Sheela and Deepa (2013), majoritatea cercetătorilor au utilizat un proces de încercare-eroare pentru a selecta numărul optim de neuroni ascunși. Prin urmare, în cazul de față a fost selectat numărul de neuroni ascunși care a determinat obținerea celei mai mici erori medii pătratice (RMSE).

Cea mai mică eroare indică cea mai mare stabilitate a modelului, în timp ce o eroare mai mare evidențiază o stabilitate mai slabă (Sheela and Deepa, 2013).

3.5.4. RAF-SI

Ca și în cazul celor trei ansambluri analizate mai sus, valorile SI calculate au fost utilizate ca date de intrare în modelul RAF. Ansamblul RAF-SI a fost rulat cu ajutorul instrumentului *Forest-based Classification and Regression* din software-ul ArcGIS Pro 2.2. Un rezultat foarte important al procesului de modelare RAF este eroarea out-of-bag (OOB), care este direct legată de stabilitatea și acuratețea modelului. Eroarea OOB este calculată utilizând cazurile care nu au fost selectate de algoritmul RAF în timpul selecției aleatorii a setului de date de antrenament (Trigila et al., 2015). Pentru a atinge eroarea OOB minimă, modelul RAF a fost rulat automat în software-ul ArcGIS Pro 2.2 de 300 de ori cu un număr de arbori de la 1 la 300. În cele din urmă, pentru calculul FFPI a fost selectat modelul RAF caracterizat prin eroarea Out-of-bag (OOB) minimă cu un număr minim de arbori. Rezultatele modelului conțin, de asemenea, importanța fiecărui predictor al viiturii rapide în ceea ce privește calculul FFPI. Trebuie menționat că rasterul final al FFPI a fost derivat automat în software-ul ArcGIS Pro 2.2, fără a aplica o sumă ponderată suplimentară în Algebra Hărților.

3.5.5. SVM-SI

Ansamblul SVM-SI a fost implementat utilizând coeficienții SI ca date de intrare în modelul SVM, împreună cu pixelii care reprezintă zonele torențiale și netorențiale. Configurarea și antrenarea SVM-SI s-au realizat cu ajutorul software-ului Weka 3.8.6, unde au fost procesate datele obținute din fluxurile de lucru GIS. O etapă esențială în aplicarea modelului SVM cu Funcție Radială de Bază (RBF) este reprezentată de selectarea parametrului de penalizare C și a termenului γ . Valorile acestor indicatori au o influență crucială asupra preciziei modelului, deoarece previn supra-ajustarea acestuia (penalizare C) și gradul de neliniaritate (termen γ).

Pentru a optimiza valorile celor doi parametri, a fost aplicată o procedură de validare încrucișată. Astfel, au fost testate mai multe perechi (C, γ) până când s-a obținut cea mai bună precizie a modelului. În final, pentru parametrul C s-a atribuit o valoare de 2,1 în timp ce valoarea optimă a termenului γ a fost stabilită la 0,12.

3.6. Evaluarea performanțelor modelelor și validarea rezultatelor

Evaluarea performanței modelelor reprezintă o etapă esențială în cadrul fluxului de lucru dezvoltat pentru identificarea zonelor susceptibile la viituri rapide (Chen et al., 2017b).

Pentru a testa performanțele modelelor aplicate, se va utiliza Curba ROC precum și următorii metrici statistice: specificitate, senzitivitate, acuratețe, indice kappa. Acești indici statistici pot fi determinați folosind următoarele relații:

$$k = \frac{p_o - p_e}{1 - p_e} \quad (3.10)$$

$$\text{Senzitivitatea} = \frac{TP}{TP + FN} \quad (3.11)$$

$$\text{Specificitatea} = \frac{TN}{FP + TN} \quad (3.12)$$

$$\text{Acuratețea} = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.13)$$

unde FP (fals pozitiv) și FN (fals negativ) sunt numărul de pixeli clasificați eronat; k este coeficientul kappa, p_o reprezintă pixelii torențiali observați, iar p_e reprezintă pixelii torențiali estimați.

3.7. Rezultate

3.7.1. Evaluarea multicoliniarității și selectarea factorilor

Rezultatele obținute în urma modelării în software-ul SPSS 21 arată că valorile TOL pentru variabilele independente luate în considerare pentru acest studiu se încadrează în intervalul 0,459 (TWI) și 0,923 (Utilizarea terenului/acoperirea terenului). În ceea ce privește valorile VIF, se poate observa un interval între 1,01 (TPI) și 3,332 (Indicele de convergență) (Tabelul 3.1). În urma analizei valorilor VIF și TOL, nu există condiții serioase de multicoliniaritate între variabile. În plus, a fost testată capacitatea predictivă a factorilor de condiționare a viiturilor rapide.

Valorile Informației Câștigate (IG) calculate oferă informații utile cu privire la influența pe care factorii de condiționare ai viiturilor rapide o au asupra fenomenelor de viituri rapide. Cea mai mare valoare (IG = 0,0775) a fost atribuită factorului de relief al pantei (Tabelul 3.1). Astfel, conform analizei IG, relieful pantei are cea mai mare importanță asupra procesului de producere a viiturilor rapide. Pe a doua poziție se află utilizarea terenului/acoperirea terenului (IG = 0,0564), urmat de L-S Factor (IG = 0,0491), indicele de umiditate topografică (TWI) (IG =

0,0441), indicele de poziție topografică (TPI) ($IG = 0,0391$), grupul hidrologic de sol ($IG = 0,0379$), litologia ($IG = 0,0334$) și indicele de convergență ($IG = 0,0290$). Pe ultimele două poziții, cu $IG = 0$, se află curbura și aspectul profilului. Trebuie menționat că, deși factorii morfometrici au ca sursă de date Modelul Digital de Elevație, valorile lor IG sunt diferite. Principala explicație este că valorile IG sunt estimate pe baza relațiilor spațiale dintre valorile fiecărui factor de condiționare a viiturii rapide și prezența/absența zonelor torențiale. Deoarece ultimii doi factori, cu $IG = 0$, nu au capacitate predictivă în ceea ce privește procesul de apariție a viiturilor rapide, aceștia vor fi eliminați din analiză.

Tabelul 3.1. Capacitatea predictivă și analiza multicolinearității pentru variabilele independente

Factor	TOL	VIF	IG
Pantă	0.463	2.083	0.0775
TPI	0.595	1.010	0.0391
TWI	0.459	3.272	0.0441
Utilizarea terenurilor	0.923	1.045	0.0564
Litologia	0.894	1.118	0.0334
Indicele de convergență	0.515	3.332	0.0290
L-S Factor	0.489	2.875	0.0491
Grupa hidrologică de sol	0.849	1.177	0.0379
Stream Power Index	0.721	2.561	0
Profile curvature	0.612	1.813	0

3.7.2. Calcularea Statistical Index

Valorile ponderilor corespunzătoare coeficienților indicelui statistic au fost atribuite fiecărei clase/categorii de factori de condiționare a viiturilor rapide luate în considerare pentru analiză. Pentru factorul de relief al pantei, valorile ponderilor variază de la -1,17 (clasa de pantă între 0° - 3°) și 0,5 (clasa de pantă $> 25^\circ$). În ceea ce privește factorul TPI, cea mai mare valoare a ponderilor indicelui statistic a fost 0,32, fiind atribuită clasei de interval între 4,6 și 20. Intervalul de clasă medie al TWI (7,79 – 10,21) conține cea mai mare valoare a ponderii SI (0,12). Categoria de utilizare/acoperire a terenului, reprezentată de zone construite, are cea mai mare valoare a ponderii SI (3,09) din întregul set de date utilizat în prezentul studiu (Tabelul 3.2). În ceea ce privește utilizarea terenului, se poate observa că odată cu scăderea coeficienților de rugozitate Manning, valorile ponderilor SI cresc pentru fiecare categorie. Această relație dintre coeficienții de rugozitate Manning și valoarea ponderării SI ar putea fi explicată prin faptul că apariția viiturilor rapide este mai probabilă pe suprafețele cu coeficient de rugozitate mai mic, cum ar fi zonele construite. Din punct de vedere litologic, cea mai mare pondere SI a fost atribuită Gresiei de Răchitașu, cea mai dură rocă din zona studiată. Valorile factorului L-S sunt direct proporționale cu valorile ponderilor SI, în timp ce în ceea ce privește indicele de

convergență, situația este inversă. Astfel, cele mai mari valori ale ponderilor SI sunt atribuite valorilor negative ale indicelui de convergență situate în zonele cu văi râurilor. În ceea ce privește grupele hidrologice de sol, cea mai mică valoare a ponderii SI (-0,64) a fost atribuită clasei C, în timp ce cea mai mare valoare este specifică clasei D.

Tabelul 3.2. Valori SI normalizate și ponderi ale factorilor de condiționare a viiturilor rapide

Factor	Clasă	Pp (%)	Pt(%)	SI	SI _N	LR-SI (β_i)	CART-SI	MLP-SI	RAF-SI	SVM-SI
Pantă	0 - 3°	5.84	1.80	-1.17	0.10	3.06	0.18	0.23	0.2	0.25
	3.1 - 7°	14.38	14.22	-0.01	0.66					
	7.1 - 15°	47.99	58.09	0.19	0.75					
	15.1 - 25°	28.52	23.91	-0.17	0.58					
	> 25°	3.27	1.99	0.5	0.90					
TPI	(-20) - (-3.8)	18.19	19.31	0.05	0.28	0.37	0.07	0.11	0.08	0.06
	(-3.7) - (-1.1)	23.65	22.92	-0.03	0.10					
	(-1) - 1.3	26.39	19.40	0.3	0.85					
	1.4 - 4.5	21.07	23.56	0.11	0.42					
	4.6 - 20	10.70	14.81	0.32	0.90					
TWI	3.15 - 6.1	12.78	13.09	0.02	0.73	1.63	0.09	0.1	0.11	0.12
	6.11 - 7.78	28.43	30.58	0.07	0.82					
	7.79 - 10.21	24.81	28.01	0.12	0.90					
	10.22 - 14.5	22.08	20.07	-0.09	0.55					
	14.51 - 24.59	11.90	8.25	-0.36	0.10					
Utilizarea terenurilor	Pădure	49.46	27.48	-0.5	0.36	2.69	0.21	0.17	0.23	0.18
	Livezi, arbuști	21.35	24.98	0.15	0.46					
	Zone agricole, Vii	6.95	0.73	-2.2	0.10					
	Pășuni	15.81	46.53	1.07	0.59					
	Zone construite	6.42	0.29	3.09	0.90					
Litologia	Nisipuri, Pietrișuri, Loess	5.65	2.32	-0.88	0.10	1.01	0.16	0.12	0.13	0.15
	Marne, argilă	29.80	18.13	-0.49	0.23					
	Gips, Calcar	38.57	49.14	0.24	0.46					
	Gresie, Tufuri, Șisturi	22.17	29.65	0.29	0.48					
	Gresia de Răchitașu	3.80	0.71	1.6	0.90					
L-S Factor	0 - 3.75	21.85	14.91	-0.3	0.10	1.73	0.11	0.13	0.09	0.08
	3.76 - 7.17	29.74	37.42	0.22	0.73					
	7.18 - 10.76	26.30	30.12	0.13	0.62					
	10.77 - 15.33	16.63	13.76	-0.18	0.25					
	15.34 - 41.59	5.47	3.79	0.36	0.90					
Indicele de convergență	0.1 - 99	16.84	13.62	-0.21	0.10	-0.46	0.03	0.05	0.04	0.06
	(-0.9) - 0	46.20	44.34	-0.04	0.49					
	(-1.9) - (-1)	9.62	10.50	0.08	0.76					
	(-2.9) - (-2)	7.14	8.27	0.14	0.90					
	(-99) - (-3)	20.21	23.28	0.14	0.90					
Grupa hidrologică de sol	A	0.08	0.00	0.19	0.50	2.48	0.15	0.09	0.12	0.1
	B	25.32	30.71	0.11	0.46					
	C	52.40	58.59	-0.64	0.10					
	D	22.20	10.70	1.03	0.90					

*Pp(%) – procentul ocupat de pixelii fiecărei clase; Pt(%) – procentul de pixeli torențiali.

3.7.3. Performanțele procesului de modelare

După calcularea coeficienților Indexului Statistic, valorile normalizate corespunzătoare fiecărei clase/categorii de factori au fost utilizate pentru a antrena cele cinci modele hibride propuse

pentru calcularea potențialului de viitură rapidă în bazinul hidrografic Bâsca Chiojdului. Performanțele celor cinci modele hibride au fost evaluate prin intermediul mai multor măsuri statistice atât pentru eșantionul de antrenament, cât și pentru cel de testare. În ceea ce privește senzitivitatea, modelul hibrid MLP-SI a obținut cea mai mare valoare atât pentru eșantionul de antrenament (91,7%), cât și pentru cel de validare (89,9%), în timp ce modelul hibrid SVM-SI a obținut cele mai mici performanțe pentru zonele de antrenament (88,1%) și LR-SI pentru zonele de validare (87,2%) (Tabelul 3.3). Dacă discutăm despre specificitate, putem observa că MLP-SI a obținut cele mai mari performanțe, 93,1% pentru zonele de antrenament și 93,2% pentru eșantionul de validare, în timp ce RAF-SI are cea mai mică performanță în ceea ce privește zonele de antrenament (89,4%), iar LR-SI are cea mai mică performanță în ceea ce privește zonele de validare (89,3%). Indicatorul de precizie a relevat că MLP-SI are cele mai mari valori pentru zonele de antrenament (92,4%) și de validare (91,5%), în timp ce cele mai mici performanțe au fost obținute de SVM-SI pentru eșantionul de antrenament (89%) și LR-SI pentru eșantionul de validare (88,2%).

Tabelul 3.3 Valorile metricilor statisticilor

Metrici	Eșantionul de antrenament					Eșantionul de testare				
	LR-SI	CART-SI	MLP-SI	RAF-SI	SVM-SI	LR-SI	CART-SI	MLP-SI	RAF-SI	SVM-SI
TP	16906	17061	17234	16514	16696	7095	7240	7400	7316	7165
TN	16408	16680	16913	16613	16220	6882	7050	7095	6960	6966
FP	1576	1421	1248	1968	1786	824	682	521	606	757
FN	2074	1802	1569	1870	2262	1040	872	827	962	956
PPV (%)	91.5	92.3	93.2	89.4	90.3	89.6	91.4	93.4	92.4	90.4
NPV (%)	88.8	90.3	91.5	89.9	87.8	86.9	89.0	89.6	87.9	87.9
Senzitivitatea (%)	89.1	90.4	91.7	89.8	88.1	87.2	89.3	89.9	88.4	88.2
Specificitatea (%)	91.2	92.2	93.1	89.4	90.1	89.3	91.2	93.2	92.0	90.2
Accuratețea (%)	90.1	91.3	92.4	89.6	89.0	88.2	90.2	91.5	90.1	89.2
Kappa	0.803	0.826	0.848	0.792	0.781	0.764	0.804	0.830	0.802	0.784
AUC	0.915	0.929	0.942	0.903	0.894	0.889	0.913	0.928	0.904	0.897

În ceea ce privește indicele Kappa, se poate observa că cele mai mari valori pentru eșantioanele de antrenament (0,848) și de validare (0,83) au fost atribuite MLP-SI, în timp ce cele mai mici valori au fost atribuite SVM-SI pentru zonele de antrenament (0,781) și LR-SI pentru zonele de validare (0,764). Aceeași situație este prezentă și în cazul valorilor AUC, MLP-SI fiind modelul cel mai performant, iar SVM-SI și LR-SI având cele mai mici performanțe. Per total, putem afirma că toate modelele au obținut performanțe foarte bune în ceea ce privește măsurătorile statistice.

3.7.4. Cartografierea Flash-Flood Potential Index (FFPI)

Odată stabilit că toate modelele au obținut rezultate foarte bune, precum și faptul că rezultatele diferă semnificativ statistic, s-a determinat Indicele de Potențial de Viitură Rapidă (Flash-Flood Potential Index) cu ajutorul modelelor menționate.

3.7.4.1. Modelul Statistical Index (SI) individual

După atribuirea valorilor ponderilor SI pentru fiecare clasă/categorie de factor de condiționare a viiturilor rapide, rasterele rezultate au fost însumate în software-ul ArcGIS 10.5, astfel încât să se obținut coeficientul FFPI SI. Valorile FFPI SI cuprinse între -1,72 și 7,63 au fost normalizate între 0,1 și 0,9 pentru a avea același interval ca și rezultatele furnizate de celelalte modele. În plus, aceste valori au fost clasificate în cinci intervale folosind următoarele 4 metode de clasificare disponibile în software-ul ArcGIS: *Natural Breaks*, *Quantile*, *Equal Intervals* și *Geometrical Intervals*. Pentru a stabili cea mai bună metodă de clasificare, a fost determinată frecvența tuturor pixelilor torențiali pentru fiecare dintre cele cinci clase. În acest sens, se va lua în considerare procentul de pixeli torențiali localizați în clasa Foarte Mare. Cu cât este mai mare procentul de pixeli torențiali în clasa Foarte Mare, cu atât metoda de clasificare este mai bună. În cazul modelului SI, cel mai mare procent de pixeli torențiali din a cincea clasă a FFPI a fost stabilit pentru clasificarea efectuată prin metoda *Natural Breaks* (62,32%), urmată de *Geometrical Intervals* (58,43%), *Quantile* (53,75%) și *Equal Intervals* (50,23%) (Fig. 3.4a). Prin urmare, pentru clasificarea valorilor FFPI SI în harta finală, a fost selectată metoda *Natural Breaks* (Fig. 3.5a). Valori foarte scăzute ale FFPI SI acoperă aproximativ 14,1% din bazinul râului Bâsca Chiojdului. Aceste zone au o distribuție relativ omogenă în întreaga zonă de studiu, cu excepția părții centrale, unde acestea lipsesc. Valori scăzute ale FFPI SI acoperă aproximativ 27% din zona de studiu. Valorile medii ale FFPI SI sunt răspândite relativ uniform în întregul bazin al râului Bâsca Chiojdului și sunt răspândite pe aproximativ 27,3% din bazinul râului Bâsca Chiojdului. Aproximativ 20% din zona studiată este acoperită de valori ridicate ale FFPI SI, în timp ce valorile foarte ridicate se extind la 10,7%. Valorile ridicate și foarte ridicate ale potențialului de viituri rapide sunt specifice în special părții centrale a bazinului râului Bâsca Chiojdului.




Fig. 3.4. Distribuția frecvenței tuturor pixelilor torențiali în cadrul claselor FFPI folosind metodele de clasificare *Natural Breaks* (NB), *Equal Intervals* (EI), *Quantile* (Q) and *Geometrical Intervals* (a. FFPI SI; b. FFPI LR-SI; c. FFPI CART-SI; d. FFPI MLP-SI; e. FFPI RAF-SI; f. FFPI SVM-SI).

3.7.4.2. Modelul hibrid LR-SI

Așa cum s-a menționat la 3.5.1, cea mai bună valoare limită utilizată în modelul LR-SI final a fost stabilită după aplicarea repetată a modelării LR cu unsprezece valori diferite între 0,01 și 0,99. Conform rezultatelor prezentate în Tabelul 3.4, cea mai mare sumă a Senzitivității (89,1) și Specificității (91,2) a fost obținută utilizând o valoare limită (cut-off) egală cu 0,7.

Tabel 3.4. Valorile Specificității și Senzitivității utilizând diferite valori limită (cut-off thresholds)

Cut-off threshold	Specificitatea	Senzitivitatea	Suma
0.01	39.6	99.8	139.4
0.1	62.5	97.8	160.3
0.2	69.3	95.9	165.2
0.3	80.2	94.3	174.5
0.4	83.1	93.6	176.7
0.5	84.6	92.7	177.3
0.6	88.2	91.5	179.7
0.7	91.2	89.1	180.3
0.8	94.6	84.1	178.7
0.9	95.9	73.6	169.5
0.99	99.3	58.3	157.6

Prin urmare, această valoare limită a fost utilizată pentru a realiza modelul LR-SI. În urma antrenării modelului hibrid LR-SI, intersecția cu modelul ($\beta_0 = 1,82$) și coeficienții de regresie (β_i) au fost determinați pentru fiecare factor de condiționare a viiturii rapide (Tabelul 3.2). Dacă analizăm valorile coeficienților de regresie (β_i), putem observa că cea mai mare valoare a fost atribuită pantei (3,06), urmată de utilizarea terenurilor (2,69), grupa hidrologică de sol (2,48), L-S Factor (1,73), twi (1,63), litologie (1,01), tpi (0,3) și indicele de convergență (-0,46). Se poate observa că șapte predictorii au obținut valori pozitive, în timp ce unul a obținut un coeficient de regresie negativ. Valorile pozitive evidențiază faptul că un anumit factor de condiționare a viiturilor rapide are o influență pozitivă asupra procesului de apariție a viiturilor rapide, în timp ce valorile negative indică condiții restrictive pentru apariția viiturilor rapide.

În final, FFPI LR-SI a fost calculat prin implementarea ecuației (4.7) în ArcGIS 10.5, conform fluxului de lucru descris la 4.4.1.

După calcularea FFPI LR-SI, valorile acestuia au fost normalizate între 0,1 și 0,9. Ca și în cazul FFPI-SI, aceleași patru metode au fost utilizate pentru a clasifica valorile FFPI LR-SI în cinci intervale. În ceea ce privește procentul de pixeli torențiali localizați în clasa foarte înaltă, metodele *Quantile* au atins cea mai mare valoare (71,44%), urmate de *Geometrical Intervals* (68,43%), *Natural Breaks* (66,33%), *Equal Intervals* (53,11%) (Fig. 3.4b). Prin urmare, pentru realizarea hărții finale FFPI LR-SI (Fig. 3.5b) a fost utilizată metoda *Quantile*. Valorile foarte mici reprezintă aproximativ 5,8% din bazinul hidrografic al râului Bâsca Chiojdului și sunt situate în special pe liniile interfluviale unde scurgerile de suprafață sunt mai puțin probabile (Fig. 3.5b). 23,6% din zona studiată este caracterizată de valori mici ale indicelui de potențial de viituri rapide, aceste zone fiind distribuite relativ omogen în jumătatea sudică a bazinului hidrografic al râului Bâsca Chiojdului. Cele mai mari zone sunt caracterizate de un potențial mediu de apariție a viiturilor rapide. Valorile medii ale FFPI LR-SI acoperă aproximativ 44,3% din zona studiată. Datorită faptului că valorile mari și foarte mari ale FFPI LR-SI acoperă aproximativ 26,7% din zona studiată, bazinul hidrografic al râului Bâsca Chiojdului este considerat a fi foarte expus fenomenelor de viituri rapide.




Fig. 3.5 Distribuția spațială a valorilor FFPI (a.FFPI SI; b. FFPI LR-SI; c. FFPI CART-SI; d. FFPI MLP-SI; e. FFPI SVM-SI)

3.7.4.3. Modelul hibrid CART-SI

Rezultatul procesului de antrenament aplicat pentru hibridul CART-SI a constatat într-un arbore decizional foarte complex, care a fost tăiat pentru a selecta acea parte care conținea cele mai importante informații. Prin urmare, a fost selectat arborele ale cărui noduri terminale au înregistrat cele mai mari valori ale parametrilor de succes, prezentați în Tabelul 3.3.

Arborele de regresie optim tăiat pentru zona de studiu are un număr de 11 noduri terminale (Fig. 3.6).




Fig. 3.6 Schema arborelui de regresie optim tăiat pentru zona de studiu

După cum se poate observa, toți factorii condiționanți ai viiturilor rapide au fost luați în considerare în procesul de construire a arborelui decizional. Conform schemei arborelui de regresie optim tăiat pentru zona de studiu, cel mai important factor care influențează apariția viiturilor rapide este utilizarea terenului (0,21), urmat de pantă (0,18), litologie (0,16), grupe hidrologice de sol (0,15), factorul L-S (0,11), twi (0,09), tpi (0,07) și indicele de convergență (0,03). Pentru a determina valorile FFPI CART-SI în zona studiată, s-au utilizat ponderile relative ale factorilor de condiționare ai viiturilor rapide în mediul GIS.

În ceea ce privește valorile normalizate ale FFPI CART-SI, cea mai bună clasificare a fost atribuită metodei *Natural Breaks*, cu 73,21% din pixelii torențiali în clasa foarte înaltă, urmată de

Geometric Intervals (69,31%), *Quantile* (68,43%) și *Equal Intervals* (54,4%) (Fig. 3.4c). În acest caz, valorile FFPI CART-SI au fost cartografiate cu ajutorul metodei *Natural Breaks*. Valori foarte mici ale Indicelui de Potențial al Viiturilor Rapide au fost estimate pentru aproximativ 5,5% din bazinul hidrografic al râului Bâsca Chiojdului (Fig. 3.5c). Acestea sunt situate în special în zonele interfluviale unde apariția scurgerilor este mai puțin probabilă. Aproximativ 30,9% din zona de studiu este acoperită de a doua clasă de FFPI CART-SI, ceea ce indică un potențial mic de apariție a viiturilor rapide. Pe lângă FFPI LR-SI, valorile medii ale FFPI CART-SI acoperă cea mai mare parte a bazinului hidrografic al râului Bâsca Chiojdului, fiind prezente pe 32,7% din suprafața studiată. În general, aceste valori sunt distribuite omogen pe întreaga zonă de cercetare. Zonele acoperite cu valori mari și foarte mari ale FFPI CART-SI sunt distribuite pe aproximativ 31% din bazinul hidrografic al râului Bâsca Chiojdului.

3.7.4.4. Modelul hibrid MLP-SI

Așa cum s-a menționat la subsecțiunea 3.5.3, numărul de neuroni ascunși a fost stabilit în urma unui proces de tip încercare-eroare menit să determine arhitectura MLP cu cea mai mică valoare RMSE. În cazul de față, valoarea RMSE a fost estimată pentru un număr de 50 de arhitecturi MLP având de la 1 la 50 de neuroni ascunși (hidden neurons) (Fig. 3.7). Conform rezultatelor obținute, valoarea RMSE a scăzut continuu de la 0,473, obținută cu un singur neuron ascuns, la 0,014, care a fost atinsă prin aplicarea unei arhitecturi cu 19 neuroni ascunși. De la 19 la 50 de neuroni ascunși, valoarea RMSE s-a stabilizat la 0,014. Trebuie menționat faptul că numărul excesiv de neuroni ascunși poate cauza supra-ajustarea.




Fig. 3.7 Valorile RMSE pentru arhitecturi MLP de la 1 la 50 de neuroni ascunși (hidden neurons)

Prin urmare, pentru a calcula FFPI, a fost aleasă arhitectura MLP cu un număr de 19 neuroni ascunși (Fig. 3.8). În plus, ponderea fiecărui predictor de viituri rapide, obținută după antrenamentul MLP-SI, a fost utilizată într-o operație de sumă ponderată pentru a obține valorile Indicelui de Potențial de Viituri Rapide.




Fig. 3.8 Arhitectura MLP-SI utilizată în prezentul studiu

Pentru a cartografia valorile FFPI MLP-SI, a fost aplicată aceeași procedură ca în cazurile anterioare. Astfel, cea mai performantă a fost metoda de clasificare a *Geometric Intervals*, cu 74,23% de pixeli torențiali în a cincea clasă a FFPI MLP-SI, urmată de *Quantile* (69.23%), *Natural Breaks* (64.22%) și *Equal Intervals* (59.35%) (Fig. 3.4d). Folosind Intervalele Geometrice, valorile normalizate ale FFPI MLP-SI, între 0,1 și 0,9, au fost reprezentate spațial. Prima clasă, între 0,1 și 0,21, acoperă aproximativ 5,6% din bazinul hidrografic al râului Bâsca, în timp ce a doua reprezintă aproximativ 16,5%. Valorile medii, între 0,46 și 0,61, sunt răspândite pe aproximativ 45% din total, în timp ce FFPI-ul ridicat și foarte ridicat este întâlnit pe 32% din aria de cercetare (Fig. 3.5d).

3.7.4.5. Modelul hibrid RAF-SI

Prin rularea modelului RAF-SI s-a observat că creșterea numărului de copaci generează o scădere a erorii OOB. Această tendință se menține până la 234 de arbori, OOB devenind stabil

la 0,0831 (Fig. 3.9). Prin urmare, pentru a obține FFPI, modelul RAF-SI aplicat a fost caracterizat de o structură cu 234 de copaci.




Fig. 3.9 Valorile erorii OOB pentru maxim 300 de arbori

Predictorul viiturilor rapide cu cea mai mare influență în modelul RAF-SI a fost utilizarea terenului (0,23), urmată de pantă (0,2), litologie (0,13), grupa hidrologică de sol (0,12), twi (0,11), L-S Factor (0,09), tpi (0,08) și indicele de convergență (0,04). În ceea ce privește valorile FFPI RAF-SI, cea mai bună clasificare a fost obținută prin aplicarea metodei *Geometrical Intervals* (71.52%), urmate de *Natural Breaks* (67.32%), *Quantile* (65.4%) și *Equal Intervals* (59.32%) (Fig. 3.4e). Metoda *Geometrical Intervals* utilizată pentru a reprezenta distribuția spațială a MLP-SI a relevat că prima clasă de potențial de viituri rapide acoperă doar 5,4% din zona studiată, în timp ce valorile mici sunt prezente pe aproximativ 24,6% din suprafața totală (Fig. 3.5e). Cele mai mari suprafețe (39,7%) sunt ocupate de valorile medii ale FFPI MLP-SI, în timp ce aproximativ 30% din zona de cercetare are un potențial de viituri rapide mare și foarte mare.

3.7.4.6. Modelul hibrid SVM-SI

Urmând procedura de antrenament a modelului hibrid SVM-SI, au fost derivate ponderile fiecărui predictor de viituri rapide. Astfel, panta a obținut cea mai mare pondere (0,25), urmată de utilizarea terenului (0,18), litologie (0,15), twi (0,12), grupa hidrologică de sol (0,1), L-S Factor (0,08), tpi (0,06) și indicele de convergență (0,06).

După aplicarea sumei ponderate, care a implicat utilizarea coeficienților SI și a ponderilor fiecărui predictor de viituri rapide, au fost derivate valorile FFPI SVM-SI. În continuare, au fost aplicate cele patru metode de clasificare pentru a stabili care este cea mai performantă.

Geometrical Intervals oferă din nou cea mai bună clasificare, cu un procent de 68,32% de pixeli torențiali în clasa foarte înaltă. Această metodă a fost urmată de *Quantile* (64,29%), *Equal Intervals* (61,3%) și *Natural Breaks* (59,3%) (Fig. 3.4f). Prin analiza rezultatelor clasificării Intervalelor Geometrice, se poate observa că valorile foarte mici ale FFPI SVM-SI sunt răspândite pe 11,1% din bazinul hidrografic Bâsca Chiojdului, în timp ce valorile mici ocupă 22,5%. Suprafețele situate pe un potențial mediu de viitură rapidă au o pondere de 27,6%, în timp ce valorile mari și foarte mari acoperă un procent total de 38,8%.

3.7.5. Validarea rezultatelor

Conform Fig. 3.10a, cel mai performant model în ceea ce privește pixelii zonelor de antrenament este MLP-SI (AUC = 0,94), urmat de CART-SI (AUC = 0,939), RAF-SI (AUC = 0,933), SVM-SI (AUC = 0,929), LR-SI (AUC = 0,925) și SI (AUC = 0,92).




Fig. 3.10 Curbele ROC aferente celor șase modele aplicate (a. Rata de Succes; b. Rata de Predicție)

Valorile AUC mai mari de 0,85 în toate cele trei cazuri evidențiază o eficiență foarte ridicată a tuturor modelelor utilizate pentru a determina zonele cu potențial de viituri rapide. În ceea ce privește rata de predicție, MLP-SI a fost, de asemenea, primul cu AUC = 0,927, urmat de CART-SI (AUC = 0,922), SVM-SI (AUC = 0,918), RAF-SI (AUC = 0,914), SI (AUC = 0,91) și LR-SI (AUC = 0,901) și (Fig. 3.10b).

Semnificativitatea diferențelor dintre valorile AUC a fost evaluată prin testul Wilcoxon. De obicei, dacă valoarea p depășește 0,05 și valoarea z variază între -1,96 și +1,96, atunci putem afirma că diferențele dintre valorile AUC nu sunt semnificative din punct de vedere statistic.

În ceea ce privește Rata de Succes, cea mai mare diferență statistică, evidențiată printr-o valoare z egală cu -12,084, a fost înregistrată în cazul comparației dintre modelele SI și MLP-SI (Tabelul 3.5). Pentru Rata de Predicție, cea mai mare diferență statistică (valoarea z = -10,322) a fost estimată în urma comparației dintre modelele LR-SI și MLP-SI. Cu toate acestea, conform rezultatelor testului Wilcoxon signed-rank, valorile p rezultate din toate comparațiile sunt mai mici de 0,05. Prin urmare, putem afirma că toate diferențele dintre valorile ASC sunt semnificative statistic.

Tabel 3.5. Semnificația statistică a diferențelor dintre valorile AUC (Wilcoxon signed-rank test)

Comparația perechilor AUC	Rata de Succes			Rata de Predicție		
	<i>z-value</i>	<i>p-value</i>	Semnificația	<i>z-value</i>	<i>p-value</i>	Semnificația
SI vs LR-SI	-3.187	<0.05	YES	+2.931	<0.05	YES
SI vs CART-SI	-11.437	<0.05	YES	-5.231	<0.05	YES
SI vs MLP-SI	-12.082	<0.05	YES	-8.095	<0.05	YES
SI vs RAF-SI	-4.637	<0.05	YES	-2.851	<0.05	YES
SI vs SVM-SI	-3.4555	<0.05	YES	-3.635	<0.05	YES
LR-SI vs CART-SI	-8.58	<0.05	YES	-9.346	<0.05	YES
LR-SI vs MLP-SI	-9.227	<0.05	YES	-10.322	<0.05	YES
LR-SI vs RAF-SI	-2.913	<0.05	YES	-4.732	<0.05	YES
LR-SI vs SVM-SI	-2.421	<0.05	YES	-5.843	<0.05	YES
CART-SI vs MLP-SI	-2.245	<0.05	YES	-3.165	<0.05	YES
CART-SI vs RAF-SI	+6.817	<0.05	YES	+5.253	<0.05	YES
CART-SI vs SVM-SI	+7.997	<0.05	YES	+3.546	<0.05	YES
MLP-SI vs RAF-SI	+7.465	<0.05	YES	+6.784	<0.05	YES
MLP-SI vs SVM-SI	+8.644	<0.05	YES	+5.532	<0.05	YES
RAF-SI vs SVM-SI	+2.256	<0.05	YES	-4.642	<0.05	YES

3.8. Discuții

Determinarea valorilor FFPI pe bazinul hidrografic al râului Bâsca Chiojdului a fost deja efectuată în alte cercetări din literatura internațională. Prima încercare de a calcula valorile FFPI pe bazinul hidrografic al râului Bâsca Chiojdului, bazată pe o simplă suprapunere a factorilor de condiționare ai viiturilor rapide în mediu GIS, fără a lua în considerare zonele deja afectate de fenomene torențiale, a fost realizată de (Pravalie and Costache, 2014). Prin compararea cu

rezultatele prezentului studiu, se poate observa că ponderile a 28% din suprafețele cu valori FFPI mari și foarte mari obținute de Pravalie and Costache (2014) sunt apropiate de ponderile obținute prin aplicarea LR-SI (26,3%), RAF-SI (30,4%), CART-SI (30,9%), SI (31,4%) și MLP-SI (32%). Acest fapt se întâmplă chiar dacă metodele utilizate pentru determinarea variabilității spațiale a valorilor FFPI au fost diferite. O altă încercare de a determina valorile FFPI în bazinul hidrografic al râului Bâsca Chiojdului a fost realizată de Costache and Zaharia (2017). În studiul menționat, calcularea valorilor FFPI a fost efectuată utilizând două modele statistice: Ponderile Dovezilor și Raportul de Frecvență. În acest caz, aplicarea Ponderilor Dovezilor a evidențiat o pondere de 33% pentru valorile FFPI mari și foarte mari, în timp ce aplicarea Raportului de Frecvență a relevat o pondere de 39%, similară cu ponderile obținute în cazul SVM-SI (38,8%). Se poate observa faptul că în prezentul studiu, precum și în cazul celor două studii anterioare, valorile mari și foarte mari ale indicelui de potențial al viiturii rapide sunt localizate în partea centrală a bazinului hidrografic al râului Bâsca Chiojdului. De asemenea, este important de menționat că aplicarea curbei ROC oferă rezultate mai precise în prezentul studiu, în care valoarea minimă ASC a ratei de succes a fost de 0,92 (SI), comparativ cu 0,73 (Weights of Evidence) obținută în studiul anterior realizat de Costache and Zaharia (2017). Mai mult, rezultatele precise obținute în prezentul studiu recomandă implicarea metodelor și a celor opt condiționări ale viiturilor rapide în calcularea FFPI în alte zone. De fapt, acești predictorii ai viiturilor rapide, care pot fi considerați relevanți pentru determinarea FFPI, au fost utilizați în trecut, împreună cu alți predictorii, pentru a evalua susceptibilitatea la viituri rapide în alte zone.

Astfel, Costache (2019a) a încercat să calculeze FFPI-ul pe bazinul hidrografic al râului Prahova (România) printr-un număr de 4 modele hibride rezultate din combinarea modelelor LR și SVM, pe de o parte, cu Raportul de Frecvență (FR) și Ponderile Evidenței (WoE), pe de altă parte. Rezultatele obținute de Costache (2019a) au relevat că valorile FFPI mari și foarte mari acoperă între 31% (SVM-WoE) și 45% (LR-WoE) din zona studiată. În schimb, performanțele modelelor, estimate prin intermediul Curbei ROC, au fost ușor mai mici decât performanțele obținute în cercetarea de față, utilizând tot Curba ROC. Numeroase modele bazate pe arbori de decizie au fost utilizate în alte studii de Costache (2019c) pentru a estima FFPI-ul pe bazinul hidrografic al râului Prahova. Și în acest caz, performanțele modelelor în termeni de Curbă ROC au fost ușor mai mici decât performanțele obținute în cercetarea de față. Modelul SI autonom oferă rezultate foarte bune în evaluarea susceptibilității la viituri rapide în bazinul hidrografic al râului

Haraz (Iran). Astfel, Khosravi et al. (2016) au arătat că modelul SI autonom poate atinge o precizie de 99,71% în ceea ce privește evaluarea susceptibilității la viituri rapide.

Utilizarea unor astfel de metode moderne, caracterizate printr-o precizie ridicată în prezicerea zonelor potențial afectate de viituri rapide și inundații, este de o importanță deosebită în contextul predicțiilor privind schimbările climatice globale. Astfel, în viitor, se așteaptă o creștere a frecvenței viiturilor rapide datorită schimbărilor în manifestarea precipitațiilor, care vor avea un caracter torențial mai pronunțat (Maghsood et al., 2019). Trebuie menționat că magnitudinea viiturilor rapide este de așteptat să crească în viitor datorită activităților de defrișare care se desfășoară pe suprafețe extinse din zona muntoasă a României (Petrișor, 2015), precum și datorită extinderii suprafețelor urbanizate, care determină transformarea mai multor suprafețe în zone impermeabile. Activitățile de defrișare și creșterea severității și frecvenței viiturilor rapide vor avea un impact direct și asupra transportului de material lemnos și al încărcăturii de pat, care va fi mai activ în viitor (Hooke, 2019). În bazinul hidrografic al râului Bâsca Chiojdului, transportul încărcăturii de pat are o influență ridicată asupra dinamicii albiei, ceea ce poate influența în continuare caracteristicile inundațiilor și viiturilor rapide (Murărescu et al., 2012). În timpul evenimentelor de viituri rapide, dinamica sedimentelor și transportul de material lemnos pot fi foarte periculoase pentru clădirile și elementele de infrastructură afectate de acest fenomen. Prin urmare, este foarte important, în lucrările de cercetare viitoare, să se identifice, în cadrul bazinului hidrografic Bâsca Chiojdului, acele bazine hidrografice torențiale care sunt susceptibile la transportul de sedimente și material lemnos.

3.9. Concluzii

În prezent, o parte foarte importantă a activității cercetătorului este reprezentată de studiul susceptibilității la viituri rapide. În prezentul studiu, potențialul de viituri rapide (PPFV) a fost calculat utilizând o metodă statistică bivariată (SI) și alte cinci ansambluri (LR-SI, CART-SI, MLP-SI, RAF-SI, SVM-SI). Aceste modele au fost antrenate printr-un număr de 8 predictorii de viituri rapide, împreună cu un eșantion reprezentând prezența/absența zonelor afectate de fenomene torențiale. Conform algoritmilor aplicați, un procent între 26,3% și 38,8% din zona de cercetare este acoperit cu valori mari și foarte mari ale PPFV. Aplicarea curbei ROC în procesul de validare a rezultatelor a relevat că modelul MLP-SI are cea mai mare eficiență dintre modelele aplicate ($AUC = 0,94$ – zone de antrenament; $AUC = 0,927$ – zone de validare). Ca orice altă cercetare, rezultatele obținute în prezentul studiu ar putea fi supuse unor erori și incertitudini datorate anumitor factori, cum ar fi: posibile erori apărute în digitalizarea zonelor afectate de

fenomenele torențiale; erori care ar putea apărea din cauza reprezentării spațiale inexacte a factorilor de condiționare a viiturilor rapide.

Putem afirma că principala noutate a prezentului studiu o reprezintă utilizarea celor cinci modele hibride pentru calcularea valorilor FFPI pentru un bazin hidrografic mic.

Pentru a crește acuratețea prognozei și avertizării viiturilor rapide, rezultatele prezentului studiu ar putea fi utilizate cu succes de Institutul Național de Hidrologie și Gospodărire a Apelor din România. Din punct de vedere al implicațiilor politice, rezultatele prezentului studiu pot reprezenta un instrument util pentru autoritățile centrale și locale, care ar trebui să prioritizeze intervențiile în zonele mai susceptibile la apariția viiturilor rapide decât alte regiuni. Aceste intervenții ar putea consta în măsuri luate înainte de evenimentele de viituri rapide, care au ca scop reducerea susceptibilității la aceste pericole, și după evenimentele de viituri rapide, care ar trebui să se refere la creșterea rezilienței mediului afectat, restaurarea elementelor socio-economice afectate și la sprijinirea populației afectate. Interzicerea defrișărilor în zonele susceptibile, prin modificări ale legislației, împădurirea și gestionarea corectă a zonelor torențiale sunt cele mai importante măsuri luate pentru reducerea susceptibilității la viituri rapide.

(B-ii) Planuri de evoluție și dezvoltare a carierei

Capitolul 4. Evoluția academică anterioară anului 2026

4.1. Introducere

Evoluția profesională a subsemnatului s-a fost conturată încă din perioada preuniversitară când interesul pentru domeniile științelor ingineresti și științelor pământului, cu focus pe analiza hazardelor naturale, era foarte ridicat. Astfel, am absolvit Colegiul Național Gh. Lazăr din București la specializarea matematică-informatică. De asemenea, pe perioada liceului am participat la două Olimpiade Naționale de Geografie și m-am calificat la Olimpiada Națională de Științele Pământului (Fizică, Chimie, Geografie și Biologie).

Ulterior am urmat cursurile Facultății de Geografie a Universității din București la toate cele 3 cicluri de învățământ: licență, master și doctorat. Teza de doctorat am susținut-o în anul 2016, în timp ce în anul 2017 am obținut titlul de doctor. În toată această perioadă a studiilor universitare am dezvoltat un interes major în ceea ce privește domeniul evaluării hazardelor naturale prin intermediul Sistemelor Informaționale Geografice și a modelelor statistice bivariate. Totodată, în teza de doctorat intitulată *Evaluarea vulnerabilității structurale la viituri rapide și inundații în bazinului superior și mijlociu al bazinului hidrografic al râului Buzău*, am analizat daunele pe care cele două hazarde le pot provoca în cadrul infrastructurii din zona studiată. Astfel, domeniul Ingineriei Civile a fost foarte bine reprezentat în cercetările asociate tezei de doctorat. Pe perioada studiilor de master și doctorat am publicat primele articole BDI și ISI. În continuare sunt prezentate studiile absolvite, activitatea științifică, precum și cea profesională.

4.2. Studiile universitare absolvite

Mai jos sunt redată în ordine cronologică:

- 2008-2011: Universitatea din București, Facultatea de Geografie – specializarea *Meteorologie și Hidrologie*, studii de licență (Diplomă de licență);
- 2011-2013: Universitatea din București, Facultatea de Geografie – specializarea *Climatologie și Hidrologie*, studii de master (Diplomă de master);
- 2013-2016: Universitatea din București, Facultatea de Geografie – Școala Doctorală *Simion Mehedinți*, doctorat (Diplomă de doctor).

4.3. Activitatea profesională

Activitatea profesională a început ca angajat al ESRI România în anii 2014 și 2015. Din anul 2015 am început activitatea ca angajat al Institutului Național de Hidrologie și Gospodărire a Apelor (INHGA) din București. În cadrul INHGA sunt angajat și în prezent pe postul de Cercetător Științific, principala activitate fiind aceea de emitere a Avertizărilor pentru Viituri Rapide pentru întreg teritoriu al României.

Totodată trebuie scos în evidență faptul că în decursul celor 12 ani de la obținerea primului loc de muncă am condus sau am fost cooptat ca membru în echipele mai multor proiecte de cercetare la instituții precum Universitatea Transilvania din Brașov și Institutul Național de Cercetare-Dezvoltare Delta Dunării Tulcea. În acest sens doresc să menționez că cele 3 proiecte pe care le-am coordonat în calitate de Director sau Responsabil din partea Partenerului au fost sau sunt derulate și în prezent în cadrul Universității Transilvania din Brașov, Facultatea de Construcții, Departamentul de Inginerie Civilă în perioada 2021 – 2026 după cum urmează:

- **PN-III-P1-1.1-PD-2019-0424-P** - Analiza integrată a susceptibilității la viituri rapide și inundații la nivelul României utilizând algoritmi de învățare automată și statistici bivariate (acronim: **RO-FLOOD-SUSCEP**); **Contract nr.:** PD226 / 08.04.2021; **Proiect de Cercetare Postdoctorală** finanțat de UEFISCDI prin **Programul 1** - Dezvoltarea sistemului național de cercetare-dezvoltare din **PN III. Perioada:** 08.04.2021 – 31.12.2022.

Director de proiect la Universitatea Transilvania din Brașov.

- **PN-IV-P8-8.1-PRE-HE-ORG-2023-0135** - Tehnologii bazate pe emisii scăzute de carbon rezistente la hazarde multiple, și servicii digitale la scară multiplă destinate unui mediu construit durabil și centrat pe utilizator (acronim: **MULTICARE**); **Contract nr.:** 50PHE / 03.01.2024; **Proiect Premiere Orizont Europa - Instituții** finanțat de UEFISCDI prin **Programul 5.8 - Cooperare Europeană și Internațională** din **PN IV. Perioada:** 03.01.2024 – 31.12.2025.

Director de proiect la Universitatea Transilvania din Brașov.

- **Project no. 101123467** - Multi-hazard low-carbon resilient technologies and multi-scale digital services for a future-proof, sustainable & user-centred built environment (acronim: **MULTICARE**); **call:** HORIZON-CL5-2022-D4-02; **Granting authority:** European Climate, Infrastructure and Environment Executive Agency; **Perioada:** 01.10.2023 - 30.09.2027.

Responsabil de proiect din partea Universității Transilvania din Brașov.

Toate cele 3 proiecte de mai sus au fost câștigate prin competiție.

În perioada 2018 – 2026 am fost beneficiarul a patru Burse Postdoctorale oferite de Institutul de Cercetare al Universității din București (ICUB) pentru tineri cercetători.

Oficial, mi-am început cariera didactică la Facultatea de Construcții a Universității Transilvania din Brașov în anul 2023 când am predat în regim de Plata cu ora modulul de GIS al cursului de *Sisteme de informații în managementul proiectelor de construcții (ISCPM02)* susținut la programul de master în limba engleză *Managementul proiectelor în regenerare urbană*.

4.4. Activitatea de cercetare științifică

Activitatea mea de cercetare științifică s-a concentrat pe dezvoltarea și aplicarea unor metodologii avansate pentru evaluarea, modelarea și gestionarea dezastrelor naturale, cu accent deosebit pe analiza susceptibilității la inundații și inundații fulgerătoare. De-a lungul carierei mele academice și profesionale, am urmărit o agendă de cercetare interdisciplinară care integrează Sistemele Informaționale Geografice (GIS), teledetecția, modelarea hidraulică și hidrologică, învățarea automată, inteligența artificială și statistica spațială. Această direcție de cercetare a permis dezvoltarea unor abordări inovatoare pentru înțelegerea distribuției spațiale a dezastrelor naturale și a impactului acestora atât asupra mediilor naturale, cât și asupra celor construite. Prin numeroase studii publicate în reviste internaționale de mare impact, am investigat performanța unei game largi de modele statistice, de învățare automată și hibride, inclusiv Random Forest, Support Vector Machine, Regresia Logistică, Rețelele Neuronale Artificiale, Arborii de Decizie, tehnicile de Învățare Ansamblu și Analiza Decizională Multicriterială Fuzzy. Aceste studii au contribuit la avansarea metodelor de modelare predictivă și au furnizat instrumente practice pentru atenuarea hazardelor și managementul riscurilor.

Astfel, după perioada doctoratului activitatea de cercetare științifică a constat atât în publicarea a peste 100 de articole științifice în domeniul ingineriei și științelor pământului cât și prin participarea în cadrul unor contracte de cercetare, de interes fiind cele 3 proiecte prezentate anterior.

Din punct de vedere al articolelor publicate, subsemnatul a reușit publicarea unui număr de 110 articole ISI în reviste incluse în prima (Q1) sau a doua (Q2) quartilă a Web of Science. Dintre acestea 28 de articole au fost publicate în calitate de prim autor iar 4 dintre ele în calitate de singur autor. Totodată, este de notat faptul că pentru alte 15 articole din cele 110 am fost autor corespondent. De asemenea, 19 articole sunt sau au fost de-a lungul timpului recunoscute de

Web of Science ca **Highly Cited paper – Included in the Top 1%** în diferitele domenii de cercetare.

Din activitatea de cercetare științifică mai face partea Editarea în calitate de Guest Editor a unor Numere Speciale (Special Issues) pentru reviste precum: Water, Land, Hydrology, Frontiers in Remote Sensing. Două dintre Numerele Speciale au fost publicate în format carte (Book Reprint).

Activitatea editorială este completată de prezența subsemnatului în Boardul Editorial al unor reviste ISI precum:

- ✓ Scientific Reports (Factor Impact = 3.9);
- ✓ Land (Factor Impact = 3.2);
- ✓ Advances in Civil Engineering (Factor Impact = 1.6);
- ✓ International Journal of RF and Microwave Computer-Aided Engineering (Factor Impact = 1);
- ✓ Hydrology (Factor Impact = 3.2 – ESCI)
- ✓ Frontiers in Remote Sensing (Factor Impact = 3.7 – ESCI).

Vizibilitatea și impactul internațional al activității mele științifice au fost recunoscute prin mai multe premii obținute la conferințe sau concursuri științifice. În acest sens doresc să menționez că în 2020, am fost selectat câștigător al Premiului *Danubius Young Researcher* din partea României, o distincție internațională acordată de Ministerul Federal al Educației, Științei și Cercetării din Austria și de Institutul pentru Regiunea Dunării și Europa Centrală. Acest premiu a recunoscut excelența, originalitatea și relevanța societală a contribuțiilor mele de cercetare în domeniul evaluării pericolelor naturale și al modelării mediului. O confirmare suplimentară a relevanței științifice a muncii mele este includerea mea în Clasamentul World's Top 2% Scientists, întocmit de Universitatea Stanford și Elsevier. În ediția din 2025 a clasamentului, m-am poziționat printre cei mai influenți cercetători din lume, clasându-mă pe locul 7.768 la nivel global în toate disciplinele științifice și pe locul 4 la nivel național în România. În domeniul Ingineriei Geologice și Geomatice, m-am clasat pe locul 79 la nivel mondial din peste 75.000 de cercetători și pe locul 1 la nivel național.

Per ansamblu, activitatea mea științifică demonstrează o traiectorie de cercetare coerentă și susținută, caracterizată prin inovație metodologică, colaborare interdisciplinară, recunoaștere internațională și contribuții semnificative la îmbogățirea cunoștințelor în domeniul evaluării hazardelor naturale, managementul riscului hidrologic, analiza geospațială și aplicațiile inteligenței artificiale în inginerie și științe ale mediului. Aceste realizări oferă o bază solidă

pentru supervizarea cercetărilor doctorale și pentru dezvoltarea de noi direcții de cercetare în domeniul Ingineriei Civile.

În final doresc să menționez valorile principalilor indicatorilor scientometrici ai subsemnatului:

- Număr citări în Web of Science – 5942
- Număr citări în Scopus – 7364
- Număr citări în Google Academic – 9843

- H-index în Web of Science – 47
- H-index în Scopus – 48
- H-index în Google Academic – 56

Capitolul 5. Plan de dezvoltare profesională a carierei universitare

Dezvoltarea viitoare a carierei mele academice și de cercetare se bazează pe consolidarea și extinderea direcțiilor științifice abordate în teza de abilitare, și anume aplicarea Sistemelor Informaționale Geografice (GIS), a teledetecției și a metodelor avansate bazate pe date pentru evaluarea, predicția și gestionarea pericolelor hidrologice. Bazându-mă pe experiența mea anterioară ca cercetător, director de proiect și colaborator în inițiative de cercetare naționale și internaționale, planul meu de carieră este structurat în jurul a patru piloni principali: (i) dezvoltarea cercetării științifice, (ii) consolidarea academică și didactică, (iii) colaborarea instituțională și internațională și (iv) vizibilitatea și impactul științific.

5.1. Dezvoltarea Direcțiilor de Cercetare Științifică

Un obiectiv major al viitoarei mele cariere academice este consolidarea, extinderea și internaționalizarea direcțiilor de cercetare inițiate în timpul studiilor doctorale și postdoctorale și dezvoltate în continuare prin participarea mea la proiecte de cercetare naționale și internaționale. Bazându-mă pe realizările științifice prezentate în această teză de abilitare, agenda mea viitoare de cercetare va continua să se concentreze pe evaluarea susceptibilității la inundații și viituri rapide, analiza riscului hidrologic și aplicarea tehnologiilor geospațiale avansate pentru managementul hazardelor naturale.

Pe termen scurt și mediu, eforturile mele de cercetare se vor concentra pe dezvoltarea de modele predictive care integrează inteligența artificială, învățarea automată, modele de tip deep learning și tehnicile decizionale multicriteriale. O atenție deosebită va fi acordată modelelor hibride capabile să combine punctele forte ale abordărilor bazate pe date cu metode de tip expert-judgment, cum ar fi Fuzzy-AHP, inferența Bayesiană și algoritmi de tip ansamblu. Aceste abordări vor contribui la reducerea incertitudinii modelului, îmbunătățirea preciziei predicției și creșterea transferabilității modelelor de evaluare a hazardelor în diferite contexte geografice și de mediu.

O direcție importantă de cercetare va implica integrarea datelor de teledetecție de înaltă rezoluție, derivate din imagini satelitare, date LiDAR, platforme UAV și sisteme de monitorizare a mediului în timp real. Disponibilitatea tot mai mare a unor astfel de seturi de date oferă oportunități semnificative pentru îmbunătățirea rezoluției spațiale și temporale a evaluărilor hazardelor și pentru dezvoltarea de modele dinamice de susceptibilitate capabile să se adapteze continuu la condițiile de mediu în schimbare.

Un alt obiectiv strategic este tranziția de la evaluarea unui singur pericol la o analiză integrată multi-hazard și multi-risc. Schimbările climatice, transformările utilizării terenurilor și presiunile antropice tot mai mari necesită analize complexe capabile să evalueze simultan interacțiunile dintre inundații, inundații fulgerătoare, alunecări de teren, eroziunea solului, secete și alte pericole de mediu. Implicarea mea ca cercetător principal și coordonator de proiect în proiecte naționale și ca lider de proiect în cadrul proiectului Horizon Europe MULTICARE oferă un cadru excelent pentru urmărirea acestei direcții de cercetare interdisciplinară și pentru consolidarea colaborărilor cu instituții de cercetare europene de top.

O direcție deosebit de promițătoare pentru cercetări viitoare se referă la dezvoltarea și implementarea tehnologiilor Digital Twin pentru managementul riscului de inundații și planificarea infrastructurii rezistente. Digital Twins reprezintă replici virtuale dinamice ale sistemelor fizice care integrează date de la senzori în timp real, informații geospațiale, modele hidraulice și hidrologice și algoritmi de inteligență artificială. În acest context, intenționez să dezvolt cadre Digital Twins pentru bazinele hidrografice și mediile urbane, care vor permite monitorizarea continuă, simularea scenariilor și analiza predictivă a proceselor legate de inundații. Astfel de sisteme au potențialul de a îmbunătăți semnificativ capacitățile de avertizare timpurie, strategiile de răspuns la situații de urgență și deciziile de planificare pe termen lung, oferind factorilor de decizie informații în timp real și perspective predictive.

În ansamblu, în ceea ce privește direcțiile de cercetare științifică, pe viitor, îmi propun să contribui la dezvoltarea unor sisteme operaționale de asistență decizională care integrează tehnologii GIS, inteligența artificială, Digital Twins, modelarea hidraulică și fluxurile de date de mediu în timp real. Aceste sisteme vor sprijini agențiile guvernamentale, autoritățile de management al apei și administrațiile locale în reducerea riscului la dezastre, planificarea adaptării la schimbările climatice și dezvoltarea teritorială durabilă. Experiența mea acumulată în cadrul Institutului Național de Hidrologie și Gospodărire a Apelor, combinată cu activitățile mele academice la Universitatea Transilvania din Brașov și participarea mea în rețele internaționale de cercetare, oferă o bază solidă pentru reducerea decalajului dintre cercetarea științifică și implementarea operațională.

5.2. Carieră academică și dezvoltare didactică

Un al doilea obiectiv major este consolidarea carierei mele academice prin predare, supervizare și dezvoltare curriculară. Experiența mea anterioară ca profesor asociat la Facultatea de Construcții a Universității Transilvania din Brașov, unde am predat cursul de GIS în limba engleză la nivel de master, reprezintă un punct de plecare important pentru o implicare academică ulterioară. De asemenea, în Septembrie 2024, la aceeași instituție am susținut un curs intensiv în cadrul a Blended Intensive Programme – BIP (Program Erasmus+ intensiv mixt), unde am expus modul în care tehnicile geospațiale pot fi utilizate în vederea estimării expunerii la hazarde naturale.

Pe termen scurt, intenționez să-mi extind activitățile didactice prin dezvoltarea și susținerea de cursuri în domenii precum:

- Aplicații GIS și teledetecție în științele mediului;
- Modelare hidrologică și evaluarea pericolelor;
- Tehnici de învățare automată pentru analiza geospațială;
- Managementul riscului și planificare spațială.

Aceste cursuri vor fi concepute pentru a reflecta cele mai recente progrese științifice și pentru a oferi studenților atât cunoștințe teoretice, cât și abilități practice. Se va pune un accent deosebit pe instruirea practică utilizând software specializat (de exemplu, ArcGIS, QGIS) și instrumente de programare (de exemplu, Python), în conformitate cu expertiza mea profesională.

O altă componentă cheie a dezvoltării mele academice este supervizarea studenților doctoranzi. Îmi propun să contribui la formarea unei noi generații de specialiști în domeniul evaluării riscurilor naturale din domeniul ingineriei civile prin implicarea studenților în proiecte de cercetare în curs de desfășurare și încurajarea participării acestora la publicații științifice. În mare măsură temele de doctorat pe care le voi propune în momentul în care voi deveni conducător de doctorat se vor referi la:

1. Evaluarea multi-risc bazată pe inteligență artificială în vederea managementului durabil al bazinelor hidrografice în contextul schimbărilor climatice

În cazul acestei teme așteptările sunt ca studenții să dezvolte un cadru integrat pentru evaluarea susceptibilității, a hazardului și a riscului asociate unor procese hidro-geomorfologice multiple (inundații, viituri rapide, alunecări de teren și eroziunea solului) în scenarii climatice actuale și viitoare, utilizând inteligența artificială și tehnologiile geospațiale.

Pentru realizarea unei lucrări de doctorat axată pe această tematică viitori studenți doctoranzi vor trebui să fie capabili să utilizeze următoarele categorii de metode: i) metode de analiză geospațială (GIS și Teledetecție); ii) metode de machine learning; iii) metode multi-criteriale decizionale; iv) tehnici de analiză a datelor climatice (analiza datelor pentru proiecții climatice).

2. Evaluarea vulnerabilității infrastructurii rutiere la inundații prin utilizarea combinată a tehnicilor geospațiale și a modelării hidraulice

În cadrul acestei teme așteptările sunt ca studenții doctoranzi să fie capabili să identifice segmentele rutiere critice expuse inundațiilor, să cuantifice vulnerabilitatea fizică și funcțională a infrastructurii de transport și să sprijine planificarea infrastructurii rezistente prin analiză spațială avansată, simulări hidraulice și metodologii de asistență decizională.

Pentru realizarea unei lucrări de doctorat axată pe această tematică viitori studenți doctoranzi vor trebui să fie capabili să utilizeze în principal următoarele categorii de metode: i) metode de analiză geospațială (GIS și Teledetecție); ii) metode de modelare hidraulică (modelare 1D și 2D); iii) metode de determinare a vulnerabilității infrastructurii la inundații (compunerea unor indici de vulnerabilitate).

3. Dezvoltarea unui sistem integrat de avertizare timpurie pentru prognoza viiturilor rapide

În cadrul acestei teme așteptările sunt ca studenții doctoranzi să aibă capacitatea să dezvolte un Sistem integrat de Avertizare Timpurie (EWS) pentru predicția viiturilor rapide prin combinarea tehnologiilor geospațiale, a modelării hidrologice și hidraulice, a monitorizării hidrometeorologice în timp real și a instrumentelor de asistență decizională.

Pentru realizarea unei lucrări de doctorat axată pe această tematică viitori studenți doctoranzi vor trebui să fie capabili să utilizeze în principal următoarele categorii de metode: i) metode de analiză geospațială (GIS și Teledetecție); ii) metode de modelare hidraulică (modelare 1D și 2D); iii) metode de modelare hidrologică (ploaie scurgere; de tip hidrograf unitar etc.); iv) metode de analiză a datelor hidrometeorologice; v) integrarea datelor de prognoză meteo în cadrul modelelor hidrologice.

Totodată, trebuie menționat faptul că toți studenții doctoranzi vor beneficia de expertiza mea în vederea realizării minimului de publicații necesar finalizării studiilor doctorale (4 articole dintre care 1 articol ISI). De asemenea, voi încuraja studenții doctoranzi să participe la cât mai multe conferințe științifice. Un exemplu de conferință științifică organizată de Facultatea de

Construcții a Universității Transilvania este **International Scientific Conference CIBv - Civil Engineering and Building Services.**

5.3. Consolidarea colaborării naționale și internaționale

O componentă centrală a strategiei mele de dezvoltare a carierei este extinderea colaborărilor de cercetare naționale și internaționale. Implicarea mea actuală în multiple proiecte de cercetare, inclusiv inițiativele Horizon Europe, demonstrează capacitatea mea de a lucra în echipe multidisciplinare și internaționale.

Pe termen scurt, îmi propun să consolidez colaborările existente cu instituții de cercetare și universități, în special în Europa și Asia, unde sunt deja coautor la numeroase lucrări științifice. Aceste colaborări vor fi dezvoltate în continuare prin proiecte comune de cercetare, co-supervizarea studenților și participarea la conferințe și ateliere internaționale.

Pe termen mediu, intenționez să inițiez și să coordonez noi proiecte de cercetare, atât la nivel național, cât și european. Experiența mea ca director de proiect și lider de echipă oferă o bază solidă pentru gestionarea inițiativelor de cercetare complexe. Mă voi concentra pe atragerea de finanțare din programe competitive, cum ar fi Horizon Europe, precum și din granturi naționale de cercetare, cu obiectivul de a sprijini atât cercetarea științifică, cât și dezvoltarea resurselor umane.

O altă direcție importantă este dezvoltarea de parteneriate cu autoritățile publice și părțile interesate implicate în managementul mediului și atenuarea riscurilor. Colaborarea cu instituții precum autoritățile de gospodărire a apei, agențiile de mediu și serviciile de urgență va asigura aplicabilitatea practică a rezultatelor cercetării și va facilita transferul de cunoștințe din mediul academic în practică.

5.4. Vizibilitate și impact științific

Îmbunătățirea vizibilității și a impactului științific reprezintă un alt obiectiv cheie al planului meu de carieră. Indicatorii mei scientometrici actuali (număr mare de citări și un indice hirsch semnificativ) reflectă o recunoaștere internațională puternică a activității mele de cercetare. Cu toate acestea, îmi propun să cresc și mai mult impactul muncii mele prin publicarea în reviste de rang înalt și prin contribuția la teme de cercetare inovatoare.

Pe lângă publicare, voi continua să mă implic în activități editoriale, inclusiv în roluri de membru al consiliului editorial, redactor asociat și redactor invitat pentru reviste internaționale. Aceste

activități nu numai că contribuie la comunitatea științifică, dar oferă și informații valoroase despre tendințele emergente de cercetare și standardele de publicare.

Participarea la conferințe internaționale, ateliere și rețele științifice va rămâne, de asemenea, o prioritate, deoarece aceste platforme facilitează schimbul de cunoștințe și dezvoltarea de noi colaborări.

5.5. Obiective pe termen lung

Pe termen lung, obiectivul meu este să devin un expert de top în domeniul evaluării riscurilor naturale din domeniul ingineriei civile, cu un profil academic și de cercetare puternic, atât la nivel național, cât și internațional. Îmi propun să contribui la avansarea cunoștințelor prin cercetare inovatoare, să sprijin luarea deciziilor bazate pe dovezi în managementul mediului și să joc un rol activ în comunitatea academică.

În plus, intenționez să contribui atât la dezvoltarea infrastructurii de cercetare cât și la înființarea de grupuri de cercetare axate pe analiza geospațială și evaluarea riscurilor de mediu. Prin integrarea cercetării, predării și colaborării, îmi propun să creez un mediu academic sustenabil care să promoveze excelența, inovația și impactul societal.

(B-iii) Bibliografie

- Agterberg, F.P., 1992. Combining indicator patterns in weights of evidence modeling for resource evaluation. *Nonrenewable Resour.* 1, 39–50.
- Akay, H., 2021. Flood hazards susceptibility mapping using statistical, fuzzy logic, and MCDM methods. *Soft Comput.* 25, 9325–9346. <https://doi.org/10.1007/s00500-021-05903-1>
- AlAli, A.M., Salih, A., Hassaballa, A., 2023. Geospatial-based analytical hierarchy process (AHP) and weighted product model (WPM) techniques for mapping and assessing flood susceptibility in the Wadi Hanifah Drainage Basin, Riyadh Region, Saudi Arabia. *Water* 15, 1943.
- Albulescu, A.-C., Minea, I., Boicu, D., Larion, D., 2022. Comparative multi-criteria assessment of hydrological vulnerability—case study: drainage basins in the Northeast Region of Romania. *Water* 14, 1302.
- Ali, S.A., Parvin, F., Pham, Q.B., Khedher, K.M., Dehbozorgi, M., Rabby, Y.W., Anh, D.T., Nguyen, D.H., 2022. An ensemble random forest tree with SVM, ANN, NBT, and LMT for landslide susceptibility mapping in the Rangit River watershed, India. *Nat. Hazards* 113, 1601–1633.
- Alkhasawneh, M.S., Ngah, U.K., Tay, L.T., Mat Isa, N.A., Al-batah, M.S., 2013. Determination of important topographic factors for landslide mapping analysis using MLP network. *Sci. World J.* 2013, 415023.
- Al-Kindi, K.M., Alabri, Z., 2024. Investigating the Role of the Key Conditioning Factors in Flood Susceptibility Mapping Through Machine Learning Approaches. *Earth Syst. Environ.* 8, 63–81. <https://doi.org/10.1007/s41748-023-00369-7>
- Arabameri, A., Yamani, M., Pradhan, B., Melesse, A., Shirani, K., Bui, D.T., 2019. Novel ensembles of COPRAS multi-criteria decision-making with logistic regression, boosted regression tree, and random forest for spatial prediction of gully erosion susceptibility. *Sci. Total Environ.*
- Arghiuș, C., Arghiuș, V., 2011. The quantitative estimation of the soil erosion using USLE type ROMSEM model: Case-study-the Codrului ridge and Piedmont (Romania). *Carpathian J Earth Env. Sci* 6, 59–66.
- Balezentiene, L., Streimikiene, D., Balezentis, T., 2013. Fuzzy decision support methodology for sustainable energy crop selection. *Renew. Sustain. Energy Rev.* 17, 83–93.
- Bouamrane, A., Derdous, O., Dahri, N., Tachi, S.-E., Boutebba, K., Bouziane, M.T., 2022. A comparison of the analytical hierarchy process and the fuzzy logic approach for flood

- susceptibility mapping in a semi-arid ungauged basin (Biskra basin: Algeria). *Int. J. River Basin Manag.* 20, 203–213.
- Breiman, L., 2001. Random forests. *Mach. Learn.* 45, 5–32.
- Breiman, L., Friedman, J.H., Olshen, R.A., Stone, C.J., 1984. Classification and regression trees. Belmont, CA: Wadsworth. Int. Group 432, 151–166.
- Buckley, J.J., 1985. Fuzzy hierarchical analysis. *Fuzzy Sets Syst.* 17, 233–247.
- Bui, D.T., Lofman, O., Revhaug, I., Dick, O., 2011. Landslide susceptibility analysis in the Hoa Binh province of Vietnam using statistical index and logistic regression. *Nat. Hazards* 59, 1413.
- Chapi, K., Singh, V.P., Shirzadi, A., Shahabi, H., Bui, D.T., Pham, B.T., Khosravi, K., 2017. A novel hybrid artificial intelligence approach for flood susceptibility assessment. *Environ. Model. Softw.* 95, 229–245.
- Chen, W., Peng, J., Hong, H., Shahabi, H., Pradhan, B., Liu, J., Zhu, A.-X., Pei, X., Duan, Z., 2018a. Landslide susceptibility modelling using GIS-based machine learning techniques for Chongren County, Jiangxi Province, China. *Sci. Total Environ.* 626, 1121–1135.
- Chen, W., Xie, X., Peng, J., Shahabi, H., Hong, H., Bui, D.T., Duan, Z., Li, S., Zhu, A.-X., 2018b. GIS-based landslide susceptibility evaluation using a novel hybrid integration approach of bivariate statistical based random forest method. *Catena* 164, 135–149.
- Chen, W., Xie, X., Wang, J., Pradhan, B., Hong, H., Bui, D.T., Duan, Z., Ma, J., 2017a. A comparative study of logistic model tree, random forest, and classification and regression tree models for spatial prediction of landslide susceptibility. *Catena* 151, 147–160.
- Chen, W., Xie, X., Wang, J., Pradhan, B., Hong, H., Bui, D.T., Duan, Z., Ma, J., 2017b. A comparative study of logistic model tree, random forest, and classification and regression tree models for spatial prediction of landslide susceptibility. *Catena* 151, 147–160.
- Chen, Y., Yu, J., Khan, S., 2013. The spatial framework for weight sensitivity analysis in AHP-based multi-criteria decision making. *Environ. Model. Softw.* 48, 129–140.
- Choubin, B., Moradi, E., Golshan, M., Adamowski, J., Sajedi-Hosseini, F., Mosavi, A., 2019. An Ensemble prediction of flood susceptibility using multivariate discriminant analysis, classification and regression trees, and support vector machines. *Sci. Total Environ.* 651, 2087–2096.

- Costache, R., 2025. Flood susceptibility estimation using randomization-based machine learning models. A case study at the Putna river basin, Romania. *Geomat. Nat. Hazards Risk* 16, 2548505. <https://doi.org/10.1080/19475705.2025.2548505>
- Costache, R., 2019a. Flash-flood Potential Index mapping using weights of evidence, decision Trees models and their novel hybrid integration. *Stoch. Environ. Res. Risk Assess.* 33, 1375–1402. <https://doi.org/10.1007/s00477-019-01689-9>
- Costache, R., 2019b. Flash-flood Potential Index mapping using weights of evidence, decision Trees models and their novel hybrid integration. *Stoch. Environ. Res. Risk Assess.* 33, 1375–1402.
- Costache, R., 2019c. Flash-Flood Potential assessment in the upper and middle sector of Prahova river catchment (Romania). A comparative approach between four hybrid models. *Sci. Total Environ.* 659, 1115–1134.
- Costache, R., 2014. Using GIS techniques for assessing lag time and concentration time in small river basins. Case study: Pecineaga river basin, Romania. *Geogr. Tech.* 9, 31–38.
- Costache, R., Bui, D.T., 2019. Spatial prediction of flood potential using new ensembles of bivariate statistics and artificial intelligence: A case study at the Putna river catchment of Romania. *Sci. Total Environ.* 691, 1098–1118.
- Costache, R., Crăciun, A., Ciobotaru, N., Bărbulescu, A., 2024. Intelligent Methods for Estimating the Flood Susceptibility in the Danube Delta, Romania. *Water* 16, 3511.
- Costache, R., Popa, M.C., Bui, D.T., Diaconu, D.C., Ciobotaru, N., Minea, G., Pham, Q.B., 2020. Spatial predicting of flood potential areas using novel hybridizations of fuzzy decision-making, bivariate statistics, and machine learning. *J. Hydrol.* 585, 124808.
- Costache, R., Pravalie, R., Mitof, I., Popescu, C., 2015. Flood vulnerability assessment in the low sector of Saratel Catchment. Case study: Joseni Village. *Carpathian J. Earth Environ. Sci.* 10, 161–169.
- Costache, R., Tin, T.T., Arabameri, A., Crăciun, A., Ajin, R., Costache, I., Islam, A.R.M.T., Abba, S., Sahana, M., Avand, M., 2022. Flash-flood hazard using deep learning based on H2O R package and fuzzy-multicriteria decision-making analysis. *J. Hydrol.* 609, 127747.
- Costache, R., Zaharia, L., 2017. Flash-flood potential assessment and mapping by integrating the weights-of-evidence and frequency ratio statistical methods in GIS environment—case study: Bâsca Chiojdului River catchment (Romania). *J. Earth Syst. Sci.* 126, 59.

- Crăciun, A., Costache, R., Bărbulescu, A., Pal, S.C., Costache, I., Dumitriu, C. Ștefan, 2022. Modern techniques for flood susceptibility estimation across the Deltaic Region (Danube Delta) from the Black Sea's Romanian Sector. *J. Mar. Sci. Eng.* 10, 1149.
- Dahal, R.K., Hasegawa, S., Nonomura, A., Yamanaka, M., Masuda, T., Nishino, K., 2008. GIS-based weights-of-evidence modelling of rainfall-induced landslides in small catchments for landslide susceptibility mapping. *Environ. Geol.* 54, 311–324.
- Dai, W., Ji, W., 2014. A mapreduce implementation of C4. 5 decision tree algorithm. *Int. J. Database Theory Appl.* 7, 49–60.
- Demissie, Z., Rimal, P., Seyoum, W.M., Dutta, A., Rimmington, G., 2024. Flood susceptibility mapping: Integrating machine learning and GIS for enhanced risk assessment. *Appl. Comput. Geosci.* 23, 100183.
- Diakakis, M., Deligiannakis, G., Pallikarakis, A., Skordoulis, M., 2016. Factors controlling the spatial distribution of flash flooding in the complex environment of a metropolitan urban area. The case of Athens 2013 flash flood event. *Int. J. Disaster Risk Reduct.* 18, 171–180.
- Dou, J., Yamagishi, H., Pourghasemi, H.R., Yunus, A.P., Song, X., Xu, Y., Zhu, Z., 2015. An integrated artificial neural network model for the landslide susceptibility assessment of Osado Island, Japan. *Nat. Hazards* 78, 1749–1776.
- Dou, J., Yunus, A.P., Bui, D.T., Merghadi, A., Sahana, M., Zhu, Z., Chen, C.-W., Khosravi, K., Yang, Y., Pham, B.T., 2019. Assessment of advanced random forest and decision tree algorithms for modeling rainfall-induced landslide susceptibility in the Izu-Oshima Volcanic Island, Japan. *Sci. Total Environ.* 662, 332–346.
- Ekmekcioğlu, Ö., Koc, K., Özger, M., 2021. District based flood risk assessment in Istanbul using fuzzy analytical hierarchy process. *Stoch. Environ. Res. Risk Assess.* 35, 617–637.
- Eristi, H., Demir, Y., 2012. The feature selection based power quality event classification using wavelet transform and logistic model tree. *Przeglad Elektrotechniczny* 88, 43–48.
- Farr, T.G., Rosen, P.A., Caro, E., Crippen, R., Duren, R., Hensley, S., Kobrick, M., Paller, M., Rodriguez, E., Roth, L., 2007. The shuttle radar topography mission. *Rev. Geophys.* 45.
- Feizizadeh, B., Roodposhti, M.S., Jankowski, P., Blaschke, T., 2014. A GIS-based extended fuzzy multi-criteria evaluation for landslide susceptibility mapping. *Comput. Geosci.* 73, 208–221.
- Felicísimo, Á.M., Cuartero, A., Remondo, J., Quirós, E., 2013. Mapping landslide susceptibility with logistic regression, multiple adaptive regression splines, classification and

- regression trees, and maximum entropy methods: a comparative study. *Landslides* 10, 175–189.
- Fitriani, W., Siahaan, A.P.U., 2016. Comparison Between WEKA and Salford System in Data Mining Software. *Int. J. Mob. Comput. Appl.* 3, 1–4.
- Freund, Y., Mason, L., 1999. The alternating decision tree learning algorithm. Presented at the *icml*, pp. 124–133.
- Gao, L., Ye, M., Lu, X., Huang, D., 2017. Hybrid method based on information gain and support vector machine for gene selection in cancer classification. *Genomics Proteomics Bioinformatics* 15, 389–395.
- Ghobadi, M., Ahmadipari, M., 2024. Enhancing flood susceptibility modeling: a hybrid deep neural network with statistical learning algorithms for predicting flood prone areas. *Water Resour. Manag.* 38, 2687–2710.
- Gigović, L., Pamučar, D., Bajić, Z., Drobnjak, S., 2017. Application of GIS-interval rough AHP methodology for flood hazard mapping in urban areas. *Water* 9, 360.
- Hall, M., Frank, E., Holmes, G., Pfahringer, B., Reutemann, P., Witten, I.H., 2009. The WEKA data mining software: an update. *ACM SIGKDD Explor. Newsl.* 11, 10–18.
- Hammami, S., Zouhri, L., Souissi, D., Souei, A., Zghibi, A., Marzougui, A., Dlala, M., 2019. Application of the GIS based multi-criteria decision analysis and analytical hierarchy process (AHP) in the flood susceptibility mapping (Tunisia). *Arab. J. Geosci.* 12, 653.
- Hanger, S., Linnerooth-Bayer, J., Surminski, S., Nenciu-Posner, C., Lorant, A., Ionescu, R., Patt, A., 2018. Insurance, public assistance, and household flood risk reduction: A comparative study of Austria, England, and Romania. *Risk Anal.* 38, 680–693.
- Hanley, J.A., McNeil, B.J., 1982. The meaning and use of the area under a receiver operating characteristic (ROC) curve. *Radiology* 143, 29–36.
- Hong, H., Liu, J., Bui, D.T., Pradhan, B., Acharya, T.D., Pham, B.T., Zhu, A.-X., Chen, W., Ahmad, B.B., 2018. Landslide susceptibility mapping using J48 Decision Tree with AdaBoost, Bagging and Rotation Forest ensembles in the Guangchang area (China). *Catena* 163, 399–413.
- Hong, H., Pradhan, B., Xu, C., Bui, D.T., 2015a. Spatial prediction of landslide hazard at the Yihuang area (China) using two-class kernel logistic regression, alternating decision tree and support vector machines. *Catena* 133, 266–281.

- Hong, H., Pradhan, B., Xu, C., Bui, D.T., 2015b. Spatial prediction of landslide hazard at the Yihuang area (China) using two-class kernel logistic regression, alternating decision tree and support vector machines. *Catena* 133, 266–281.
- Hooke, J., 2019. Extreme sediment fluxes in a dryland flash flood. *Sci. Rep.* 9, 1686.
- Hunt, E.B., Marin, J., Stone, P.J., 1966. Experiments in induction.
- Ibarra-Berastegi, G., Saénz, J., Ezcurra, A., Elías, A., Diaz Argandoña, J., Errasti, I., 2011. Downscaling of surface moisture flux and precipitation in the Ebro Valley (Spain) using analogues and analogues followed by random forests and multiple linear regression. *Hydrol. Earth Syst. Sci.* 15, 1895–1907.
- Jahani, B., Mohammadi, B., 2019. A comparison between the application of empirical and ANN methods for estimation of daily global solar radiation in Iran. *Theor. Appl. Climatol.* 137, 1257–1269.
- Javidi, M.M., Mansoury, S., 2017. Diagnosis of the disease using an ant colony gene selection method based on information gain ratio using fuzzy rough sets. *J. Part. Sci. Technol.* 3, 175–186.
- Jenness, J.S., Beier, P., Ganey, J.L., 2004. Associations between forest fire and Mexican spotted owls. *For. Sci.* 50, 765–772.
- Kader, Z., Islam, Md Rabiul, Aziz, M.T., Hossain, M.M., Islam, Md Rakibul, Miah, M., Jaafar, W.Z.W., 2024. GIS and AHP-based flood susceptibility mapping: a case study of Bangladesh. *Sustain. Water Resour. Manag.* 10, 170.
- Kahraman, C., Cebeci, U., Ulukan, Z., 2003. Multi-criteria supplier selection using fuzzy AHP. *Logist. Inf. Manag.* 16, 382–394.
- Kavzoglu, T., Sahin, E.K., Colkesen, I., 2014. Landslide susceptibility mapping using GIS-based multi-criteria decision analysis, support vector machines, and logistic regression. *Landslides* 11, 425–439.
- Khosravi, K., Pham, B.T., Chapi, K., Shirzadi, A., Shahabi, H., Revhaug, I., Prakash, I., Bui, D.T., 2018. A comparative assessment of decision trees algorithms for flash flood susceptibility modeling at Haraz watershed, northern Iran. *Sci. Total Environ.* 627, 744–755.
- Khosravi, K., Pourghasemi, H.R., Chapi, K., Bahri, M., 2016. Flash flood susceptibility analysis and its mapping using different bivariate models in Iran: a comparison between Shannon's entropy, statistical index, and weighting factor models. *Environ. Monit. Assess.* 188, 656.

- Kourgialas, N.N., Karatzas, G.P., 2011. Flood management and a GIS modelling method to assess flood-hazard areas—a case study. *Hydrol. Sci. Journal—Journal Sci. Hydrol.* 56, 212–225.
- Kucsicsa, G., Popovici, E.-A., Bălteanu, D., Grigorescu, I., Dumitrașcu, M., Mitrică, B., 2019. Future land use/cover changes in Romania: regional simulations based on CLUE-S model and CORINE land cover database. *Landsc. Ecol. Eng.* 15, 75–90.
- Landwehr, N., Hall, M., Frank, E., 2005. Logistic model trees. *Mach. Learn.* 59, 161–205.
- Lappas, I., Kallioras, A., 2019. Flood susceptibility assessment through GIS-based multi-criteria approach and analytical hierarchy process (AHP) in a river basin in Central Greece. *Int Res J Eng Technol* 6.
- Lee, S., Pradhan, B., 2007. Landslide hazard mapping at Selangor, Malaysia using frequency ratio and logistic regression models. *Landslides* 4, 33–41.
- Linzer, H.-G., Frisch, W., Zweigel, P., Gîrbacea, R., Hann, H.-P., Moser, F., 1998. Kinematic evolution of the Romanian Carpathians. *Tectonophysics* 297, 133–156.
- Liu, T., Shi, P., Fang, J., 2022. Spatiotemporal variation in global floods with different affected areas and the contribution of influencing factors to flood-induced mortality (1985–2019). *Nat. Hazards* 111, 2601–2625.
- Maghsood, F.F., Moradi, H., Bavani, M., Reza, A., Panahi, M., Berndtsson, R., Hashemi, H., 2019. Climate Change Impact on Flood Frequency and Source Area in Northern Iran under CMIP5 Scenarios. *Water* 11, 273.
- Mamede da Silva, P., de Miranda, F.P., Landau, L., 2018. Mapping the Brazilian Amazon fluvial sensitivity index to oil spills with Shuttle Radar Topography Mission (SRTM) data. *Geocarto Int.* 33, 555–572.
- Midi, H., Sarkar, S.K., Rana, S., 2010. Collinearity diagnostics of binary logistic regression model. *J. Interdiscip. Math.* 13, 253–267.
- Minea, G., 2013a. Assessment of the flash flood potential of Basca river catchment (Romania) based on physiographic factors. *Cent. Eur. J. Geosci.* 5, 344–353.
- Minea, G., 2013b. Assessment of the flash flood potential of Bâsca River Catchment (Romania) based on physiographic factors. *Open Geosci.* 5, 344–353.
- Mokhtari, E., Abdelkebir, B., Djenaoui, A., Hamdani, N.E.H., 2024. Integrated analytic hierarchy process and fuzzy analytic hierarchy process for Sahel watershed flood susceptibility assessment, Algeria. *Water Pract. Technol.* 19, 453–475.
- Moore, I.D., Grayson, R., Ladson, A., 1991. Digital terrain modelling: a review of hydrological, geomorphological, and biological applications. *Hydrol. Process.* 5, 3–30.

- Moore, I.D., Wilson, J.P., 1992. Length-slope factors for the Revised Universal Soil Loss Equation: Simplified method of estimation. *J. Soil Water Conserv.* 47, 423–428.
- Murărescu, O., Zarea, R., Țurloiu-Firică, R., Pehoiu, G., 2012. BÂSCA CHIOJDULUI RIVERBED DYNAMICS (ROMANIA) AND ITS IMPACT ON THE ENVIRONMENT. CASE STUDY: SECTOR AREA. *Present Environ. Sustain. Dev.* 6.
- Nachappa, T.G., Piralilou, S.T., Gholamnia, K., Ghorbanzadeh, O., Rahmati, O., Blaschke, T., 2020. Flood susceptibility mapping with machine learning, multi-criteria decision analysis and ensemble using Dempster Shafer Theory. *J. Hydrol.* 590, 125275.
- Naghibi, S.A., Ahmadi, K., Daneshi, A., 2017. Application of support vector machine, random forest, and genetic algorithm optimized random forest models in groundwater potential mapping. *Water Resour. Manag.* 31, 2761–2775.
- Nguyen, H.N., Fukuda, H., Nguyen, M.N., 2024. Assessment of the susceptibility of urban flooding using GIS with an analytical hierarchy process in Hanoi, Vietnam. *Sustainability* 16, 3934.
- NRCS, U., 2009. Chapter 7—hydrologic soil groups. *NRCS—National Eng. Handb. NEH Part 630—Hydrology* 7–1.
- Nsangou, D., Kpoumié, A., Mfonka, Z., Ngouh, A.N., Fossi, D.H., Jourdan, C., Mbele, H.Z., Mouncherou, O.F., Vandervaere, J.-P., Ngoupayou, J.R.N., 2022. Urban flood susceptibility modelling using AHP and GIS approach: case of the Mfoundi watershed at Yaoundé in the South-Cameroon plateau. *Sci. Afr.* 15, e01043.
- Ozcift, A., Gulten, A., 2011. Classifier ensemble construction with rotation forest to improve medical diagnosis performance of machine learning algorithms. *Comput. Methods Programs Biomed.* 104, 443–451.
- Petrișor, A.-I., 2015. Using CORINE data to look at deforestation in Romania: Distribution & possible consequences. *Urban. Arhit. Construcții* 6, 83–90.
- Pham, B.T., Bui, D.T., Pourghasemi, H.R., Indra, P., Dholakia, M., 2017. Landslide susceptibility assessment in the Uttarakhand area (India) using GIS: a comparison study of prediction capability of naïve bayes, multilayer perceptron neural networks, and functional trees methods. *Theor. Appl. Climatol.* 128, 255–273.
- Pham, B.T., Jaafari, A., Prakash, I., Bui, D.T., 2019. A novel hybrid intelligent model of support vector machines and the MultiBoost ensemble for landslide susceptibility modeling. *Bull. Eng. Geol. Environ.* 78, 2865–2886.

- Pimenta, L., Duarte, L., Teodoro, A.C., Beltrão, N., Gomes, D., Oliveira, R., 2025. GIS-Based Flood Susceptibility Mapping Using AHP in the Urban Amazon: A Case Study of Ananindeua, Brazil. *Land* 14, 1543.
- Popovici, E.-A., Bălteanu, D., Kucsicsa, G., 2013. Assessment of changes in land-use and land-cover pattern in Romania using Corine Land Cover Database. *Carpathian J. Earth Environ. Sci.* 8, 195–208.
- Pradhan, B., 2013. A comparative study on the predictive ability of the decision tree, support vector machine and neuro-fuzzy models in landslide susceptibility mapping using GIS. *Comput. Geosci.* 51, 350–365.
- Pradhan, B., 2011. Manifestation of an advanced fuzzy logic model coupled with Geo-information techniques to landslide susceptibility mapping and their comparison with logistic regression modelling. *Environ. Ecol. Stat.* 18, 471–493.
- Pradhan, B., 2010. Remote sensing and GIS-based landslide hazard analysis and cross-validation using multivariate logistic regression model on three test areas in Malaysia. *Adv. Space Res.* 45, 1244–1256.
- Pradhan, B., Lee, S., 2010. Delineation of landslide hazard areas on Penang Island, Malaysia, by using frequency ratio, logistic regression, and artificial neural network models. *Environ. Earth Sci.* 60, 1037–1054.
- Pradhan, B., Youssef, A., 2011. A 100-year maximum flood susceptibility mapping using integrated hydrological and hydrodynamic models: Kelantan River Corridor, Malaysia. *J. Flood Risk Manag.* 4, 189–202.
- Pravaliu, R., Costache, R., 2014. The analysis of the susceptibility of the flash-floods' genesis in the area of the hydrographical basin of Băscă Chiojdului river/Analiza susceptibilității genezei viiturilor în aria bazinului hidrografic al râului Băscă Chiojdului. University of Craiova, Department of Geography, p. 39.
- Rautela, P., Lakhera, R.C., 2000. Landslide risk analysis between Giri and Tons rivers in Himachal Himalaya (India). *Int. J. Appl. Earth Obs. Geoinformation* 2, 153–160.
- Regmi, A.D., Devkota, K.C., Yoshida, K., Pradhan, B., Pourghasemi, H.R., Kumamoto, T., Akgun, A., 2014. Application of frequency ratio, statistical index, and weights-of-evidence models and their comparison in landslide susceptibility mapping in Central Nepal Himalaya. *Arab. J. Geosci.* 7, 725–742.
- Rodriguez, J.J., Kuncheva, L.I., Alonso, C.J., 2006. Rotation forest: A new classifier ensemble method. *IEEE Trans. Pattern Anal. Mach. Intell.* 28, 1619–1630.

- Romanescu, G., Mihiu-Pintilie, A., Stoleriu, C.C., Carboni, D., Paveluc, L.E., Cimpianu, C.I., 2018. A comparative analysis of exceptional flood events in the context of heavy rains in the summer of 2010: Siret Basin (NE Romania) case study. *Water* 10, 216.
- Roodposhti, M.S., Rahimi, S., Beglou, M.J., 2014. PROMETHEE II and fuzzy AHP: an enhanced GIS-based landslide susceptibility mapping. *Nat. Hazards* 73, 77–95.
- Rosati, L., Fipaldini, M., Marignani, M., Blasi, C., 2010. Effects of fragmentation on vascular plant diversity in a Mediterranean forest archipelago. *Plant Biosyst.* 144, 38–46.
- Ryu, J., Jung, Y., Kong, D.S., Park, B.K., Kim, Y.S., Engel, B.A., Lim, K.J., 2016. Approach of land cover based asymptotic curve number regression equation to estimate runoff. *Irrig. Drain.* 65, 94–104.
- Săgeată, R., Dumitrescu, B., Grigorescu, I., Persu, M., 2013. Tipologii privind vulnerabilitatea la inundații a orașelor din România. *Wulfenia* 20, 274–290.
- Saha, S., Sarkar, D., Mondal, P., 2022. Efficiency exploration of frequency ratio, entropy and weights of evidence-information value models in flood vulnerability assessment: a study of raiganj subdivision, Eastern India. *Stoch. Environ. Res. Risk Assess.* 36, 1721–1742.
- Saharia, M., Kirstetter, P.-E., Vergara, H., Gourley, J.J., Hong, Y., Giroud, M., 2017. Mapping flash flood severity in the United States. *J. Hydrometeorol.* 18, 397–411.
- Saravanan, S., Abijith, D., 2022. Flood susceptibility mapping of Northeast coastal districts of Tamil Nadu India using multi-source geospatial data and machine learning techniques. *Geocarto Int.* 37, 15252–15281.
- Sarwar, J., Khan, S.A., Azmat, M., Khan, F., 2025. An application of hybrid bagging-boosting decision trees ensemble model for riverine flood susceptibility mapping and regional risk delineation. *Water Resour. Manag.* 39, 547–577.
- Senan, C.P., Ajin, R., Danumah, J.H., Costache, R., Arabameri, A., Rajaneesh, A., Sajinkumar, K., Kuriakose, S.L., 2023. Flood vulnerability of a few areas in the foothills of the Western Ghats: a comparison of AHP and F-AHP models. *Stoch. Environ. Res. Risk Assess.* 37, 527–556.
- Sewa, R., Poudel, B., Shrestha, S., Dahal, D., Kalra, A., 2026. Assessing Flood Susceptibility Using a Data-Driven, GIS-Based Frequency Ratio Model. *Atmosphere* 17, 231.
- Shahiri Tabarestani, E., Afzalimehr, H., 2022. A comparative assessment of multi-criteria decision analysis for flood susceptibility modelling. *Geocarto Int.* 37, 5851–5874.
- Shaikh, M.P., Yadav, S.M., Manekar, V.L., 2024. Flood hazards mapping by linking CF, AHP, and fuzzy logic techniques in urban areas. *Nat. Hazards Rev.* 25, 04023048.

- Sheela, K.G., Deepa, S., 2013. Neural network based hybrid computing model for wind speed prediction. *Neurocomputing* 122, 425–429.
- Shen, H., Huang, F., Fan, X., Shahabi, H., Shirzadi, A., Wang, D., Peng, C., Zhao, X., Chen, W., 2023. Improving the performance of artificial intelligence models using the rotation forest technique for landslide susceptibility mapping. *Int. J. Environ. Sci. Technol.* 20, 11239–11254.
- Shirzadi, A., Bui, D.T., Pham, B.T., Solaimani, K., Chapi, K., Kavian, A., Shahabi, H., Revhaug, I., 2017. Shallow landslide susceptibility assessment using a novel hybrid intelligence approach. *Environ. Earth Sci.* 76, 60.
- Siahkamari, S., Haghizadeh, A., Zeinivand, H., Tahmasebipour, N., Rahmati, O., 2018. Spatial prediction of flood-susceptible areas using frequency ratio and maximum entropy models. *Geocarto Int.* 33, 927–941.
- Soureshjani, M.H., Kimiagari, A.M., 2013. Calculating the best cut off point using logistic regression and neural network on credit scoring problem-A case study of a commercial bank. *Afr. J. Bus. Manag.* 7, 1414–1421.
- Swain, K.C., Singha, C., Nayak, L., 2020. Flood susceptibility mapping through the GIS-AHP technique using the cloud. *ISPRS Int. J. Geo-Inf.* 9, 720.
- Tariq, A., Yan, J., Ghaffar, B., Qin, S., Mousa, B., Sharifi, A., Huq, M.E., Aslam, M., 2022. Flash flood susceptibility assessment and zonation by integrating analytic hierarchy process and frequency ratio model with diverse spatial data. *Water* 14, 3069.
- Tehrany, M.S., Pradhan, B., Mansor, S., Ahmad, N., 2015. Flood susceptibility assessment using GIS-based support vector machine model with different kernel types. *Catena* 125, 91–101.
- Termeh, S.V.R., Kornejady, A., Pourghasemi, H.R., Keesstra, S., 2018. Flood susceptibility mapping using novel ensembles of adaptive neuro fuzzy inference system and metaheuristic algorithms. *Sci. Total Environ.* 615, 438–451.
- Tien Bui, D., Khosravi, K., Shahabi, H., Daggupati, P., Adamowski, J.F., Melesse, A.M., Thai Pham, B., Pourghasemi, H.R., Mahmoudi, M., Bahrami, S., 2019. Flood spatial modeling in northern Iran using remote sensing and gis: A comparison between evidential belief functions and its ensemble with a multivariate logistic regression model. *Remote Sens.* 11, 1589.

- Tien Bui, D., Pradhan, B., Lofman, O., Revhaug, I., 2012. Landslide susceptibility assessment in vietnam using support vector machines, decision tree, and Naive Bayes Models. *Math. Probl. Eng.* 2012.
- Tien Bui, D., Tuan, T.A., Klempe, H., Pradhan, B., Revhaug, I., 2016. Spatial prediction models for shallow landslide hazards: a comparative assessment of the efficacy of support vector machines, artificial neural networks, kernel logistic regression, and logistic model tree. *Landslides* 13, 361–378.
- Tikuye, B., Ray, R., Abeysingha, N.S., Gurau, S., 2025. Integrating multi-criteria decision analysis and geospatial data for flood susceptibility mapping in Texas, USA. *Prog. Disaster Sci.* 100462.
- Trigila, A., Iadanza, C., Esposito, C., Scarascia-Mugnozza, G., 2015. Comparison of Logistic Regression and Random Forests techniques for shallow landslide susceptibility assessment in Giampilieri (NE Sicily, Italy). *Geomorphology* 249, 119–136.
- Vahidnia, M.H., Alesheikh, A.A., Alimohammadi, A., 2009. Hospital site selection using fuzzy AHP and its derivatives. *J. Environ. Manage.* 90, 3048–3056.
- van Westen, C., 1997. Statistical landslide hazards analysis, ILWIS 2.1 for Windows application guide, ITC Publication.
- Van Westen, C., Rengers, N., Soeters, R., 2003. Use of geomorphological information in indirect landslide susceptibility assessment. *Nat. Hazards* 30, 399–419.
- Van Westen, C.J., Rengers, N., Terlien, M., Soeters, R., 1997. Prediction of the occurrence of slope instability phenomenon through GIS-based hazard zonation. *Geol. Rundsch.* 86, 404–414.
- Varra, G., Della Morte, R., Tartaglia, M., Fiduccia, A., Zammuto, A., Agostino, I., Booth, C.A., Quinn, N., Lamond, J.E., Cozzolino, L., 2024. Flood susceptibility assessment for improving the resilience capacity of railway infrastructure networks. *Water* 16, 2592.
- Vojtek, M., Vojteková, J., 2019. Flood susceptibility mapping on a national scale in Slovakia using the analytical hierarchy process. *Water* 11, 364.
- Wang, T.-C., Chen, Y.-H., 2008. Applying fuzzy linguistic preference relations to the improvement of consistency of fuzzy AHP. *Inf. Sci.* 178, 3755–3765.
- Wang, Y., Hong, H., Chen, W., Li, S., Pamučar, D., Gigović, L., Drobnjak, S., Tien Bui, D., Duan, H., 2018. A hybrid GIS multi-criteria decision-making method for flood susceptibility mapping at Shangyou, China. *Remote Sens.* 11, 62.

- Woznicki, S.A., Baynes, J., Panlasigui, S., Mehaffey, M., Neale, A., 2019. Development of a spatially complete floodplain map of the conterminous United States using random forest. *Sci. Total Environ.* 647, 942–953.
- Wu, S., Yu, M., Chen, L., 2017. Nonmonotonic and spatial-temporal dynamic slope effects on soil erosion during rainfall-runoff processes. *Water Resour. Res.* 53, 1369–1389.
- Wu, X., Kumar, V., Quinlan, J.R., Ghosh, J., Yang, Q., Motoda, H., McLachlan, G.J., Ng, A., Liu, B., Philip, S.Y., 2008. Top 10 algorithms in data mining. *Knowl. Inf. Syst.* 14, 1–37.
- Yang, X., Ding, J., Hou, H., 2013. Application of a triangular fuzzy AHP approach for flood risk evaluation and response measures analysis. *Nat. Hazards* 68, 657–674.
- Yaseen, A., Lu, J., Chen, X., 2022. Flood susceptibility mapping in an arid region of Pakistan through ensemble machine learning model. *Stoch. Environ. Res. Risk Assess.* 36, 3041–3061.
- Yeon, Y.-K., Han, J.-G., Ryu, K.H., 2010. Landslide susceptibility mapping in Injae, Korea, using a decision tree. *Eng. Geol.* 116, 274–283.
- Yilmaz, O.S., 2022. Flood hazard susceptibility areas mapping using Analytical Hierarchical Process (AHP), Frequency Ratio (FR) and AHP-FR ensemble based on Geographic Information Systems (GIS): a case study for Kastamonu, Türkiye. *Acta Geophys.* 70, 2747–2769.
- Youssef, A.M., Pourghasemi, H.R., Pourtaghi, Z.S., Al-Katheeri, M.M., 2016. Landslide susceptibility mapping using random forest, boosted regression tree, classification and regression tree, and general linear models and comparison of their performance at Wadi Tayyah Basin, Asir Region, Saudi Arabia. *Landslides* 13, 839–856.
- Zadeh, L.A., 1965. Fuzzy sets. *Inf. Control* 8, 338–353.
- Zaharia, L., Costache, R., Prăvălie, R., Ioana-Toroimac, G., 2017a. Mapping flood and flooding potential indices: a methodological approach to identifying areas susceptible to flood and flooding risk. Case study: the Prahova catchment (Romania). *Front. Earth Sci.* 11, 229–247.
- Zaharia, L., Costache, R., Prăvălie, R., Ioana-Toroimac, G., 2017b. Mapping flood and flooding potential indices: a methodological approach to identifying areas susceptible to flood and flooding risk. Case study: the Prahova catchment (Romania). *Front. Earth Sci.* 11, 229–247.
- Zaharia, L., Costache, R., Prăvălie, R., Minea, G., 2015. Assessment and mapping of flood potential in the Slănic catchment in Romania. *J. Earth Syst. Sci.* 124, 1311–1324.