

TEZĂ DE ABILITARE

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

Domeniul: Inginerie Civilă și Instalații

CS Dr. Romulus-Dumitru Costache

Institutul Național de Hidrologie și Gospodărire a Apelor · Universitatea Transilvania din Braşov

Braşov, 2026

CUPRINS

- ✓ Realizări științifice, profesionale și academice
- ✓ Contribuții la estimarea susceptibilității la inundații și viituri rapide prin metode moderne (Cap. 1 - Cap. 3 - Teză Abilitare)
- ✓ Planuri de evoluție și dezvoltare a carierei

REALIZĂRI ȘTIINȚIFICE


Am desfășurat o activitate de cercetare susținută, concretizată în **110 articole ISI** publicate în reviste Q1/Q2 (Web of Science), din care **19 „Highly Cited Paper”** (Top 1%).

- 28 articole ca prim autor, din care 4 ca unic autor

15 articole suplimentare – autor corespondent

- Citări: 7018 (Web of Science) · 8168 (Scopus) · 10786 (Google Academic)

H-index: 50 (WoS) · 50 (Scopus) · 57 (Google Academic)



ACTIVITATE EDITORIALĂ ȘI RECUNOAȘTERE INTERNAȚIONALĂ

Guest Editor, boarduri editoriale și distincții științifice

Guest Editor – Numere speciale

Water · Land · Hydrology · Frontiers in Remote Sensing – 2 numere speciale publicate ulterior în format carte (Book Reprint)

Land

Membru al Boardului Editorial · IF = 3,2

Hydrology (ESCI)

Membru al Boardului Editorial · IF = 3,2

Premiul Danubius Young Researcher (2020)

România – distincție acordată de Ministerul Federal al Educației, Științei și Cercetării din Austria și Institutul pentru Regiunea Dunării și Europa Centrală

Scientific Reports

Membru al Boardului Editorial · IF = 3,9

Advances in Civil Engineering

Membru al Boardului Editorial · IF = 1,6

Frontiers in Remote Sensing (ESCI)

Membru al Boardului Editorial · IF = 3,7

World's Top 2% Scientists – Stanford/Elsevier (2025)

Locul 7.768 mondial (toate disciplinele) · Locul 4 național (România) · Domeniul Ingineria Geologică și Geomatică: locul 79 mondial din peste 75.000 cercetători și locul 1 național

REALIZĂRI PROFESIONALE

Am contribuit la dezvoltarea activității Institutului Național de Hidrologie și Gospodărire a Apelor (INHGA) în domeniul prognozei și avertizării hidrologice, precum și la derularea, în calitate de Director de proiect, a unor proiecte de cercetare naționale și europene la Universitatea Transilvania din Brașov.

- 2014-2015 – ESRI România

primele experiențe profesionale în domeniul aplicațiilor GIS

- din 2015 – Cercetător Științific, INHGA

activitate principală: emiterea Avertizărilor pentru Viituri Rapide pentru întreg teritoriul României

- 2018-2026 – 4 Burse Postdoctorale ICUB

Institutul de Cercetare al Universității din București, program dedicat tinerilor cercetători

- 2021 - prezent - 3 proiecte de cercetare, toate câștigate prin competiție - Universitatea Transilvania din Brașov

PROIECTE DE CERCETARE (DIRECTOR / RESPONSABIL)

Toate cele 3 proiecte derulate la Universitatea Transilvania din Braşov, câştigate prin competiţie

RO-FLOOD-SUSCEP

Analiza integrată a susceptibilităţii la viituri rapide şi inundaţii la nivelul României utilizând algoritmi de învăţare automată şi statistici bivariate

CONTRACT

PD226 / 08.04.2021
(cod PN-III-P1-1.1-PD-2019-0424-P)

FINANŢATOR / PROGRAM

Proiect de Cercetare Postdoctorală – UEFISCDI, Programul 1 (Dezvoltarea sistemului naţional de cercetare-dezvoltare), PN III

PERIOADĂ

08.04.2021 - 31.12.2022

ROL

Director de proiect

MULTICARE (PN IV)

Tehnologii bazate pe emisii scăzute de carbon rezistente la hazarde multiple şi servicii digitale la scară multiplă destinate unui mediu construit durabil şi centrat pe utilizator

CONTRACT

50PHE / 03.01.2024
(cod PN-IV-P8-8.1-PRE-HE-ORG-2023-0135)

FINANŢATOR / PROGRAM

Proiect Premiere Orizont Europa – Instituţii, UEFISCDI, Programul 5.8 (Cooperare Europeană şi Internaţională), PN IV

PERIOADĂ

03.01.2024 - 31.12.2025

ROL

Director de proiect

MULTICARE (Horizon Europe)

Multi-hazard low-carbon resilient technologies and multi-scale digital services for a future-proof, sustainable & user-centred built environment

CONTRACT

Project no. 101123467
(call HORIZON-CL5-2022-D4-02)

FINANŢATOR / PROGRAM

European Climate, Infrastructure and Environment Executive Agency (CINEA) – Horizon Europe

PERIOADĂ

01.10.2023 - 30.09.2027

ROL

Responsabil de proiect

Parcurs educațional și didactic

1

Liceu (2004-2008)

Colegiul Național „Gh. Lazăr” – matematică-informatică; 2 Olimpiade Naționale de Geografie



2

Licență (2008-2011)

Fac. de Geografie, Univ. din București – Meteorologie și Hidrologie



3

Master (2011-2013)

specializarea Climatologie și Hidrologie

4

Doctorat (2013-2017)

Școala Doctorală „Simion Mehedinți” – *Evaluarea vulnerabilității structurale la viituri și inundații în sectorul superior și mijlociu al bazinului hidrografic al râului Buzău*



5 Activitate didactică (din 2023)

- 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** - Univ. Transilvania din Brașov - Facultatea de Construcții.
- Predarea unui curs de aplicații GIS în domeniul hazardelor naturale studenților străini în cadrul **Blended Intensive Programme - BIP** - Univ. Transilvania din Brașov - Facultatea de Construcții.

**Contribuții la estimarea susceptibilității la inundații
și viituri rapide prin metode moderne (Cap. 1 - Cap.
3 - Teză Abilitare)**

INTRODUCERE

Direcția generală de cercetare din prezenta lucrare se referă la **Utilizarea metodelor moderne în vederea estimării susceptibilității la viituri rapide și inundații.**

- **Contextul global și național**

peste 20 mld € pierderi economice anuale la nivel global; în România, evenimentele din 2005 (1,5 mld €, peste 70 de victime) și din 2024 (Galați-Vaslui, 6 victime) confirmă gravitatea persistentă a acestui hazard

- **Cele trei subdirecții de cercetare ale tezei**

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

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS (Fuzzy-AHP) PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

- Subdirecția de cercetare nr. 1

combinarea analizei multicriteriale decizionale (AHP) cu modelele fuzzy pentru estimarea susceptibilității la inundații

- Articol ISI de bază

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: 10.1016/j.jhydrol.2020.124808 (IF 4,5, Q1 – Highly Cited Paper, Top 1%)

- Proiect de cercetare

RO-FLOOD-SUSCEP (PN-III-P1-1.1-PD-2019-0424-P), Contract PD226/08.04.2021, UEFISCDI – Programul 1, PN III (08.04.2021-31.12.2022), Director de proiect la Universitatea Transilvania din Brașov

- Obiectiv

calcularea Indicelui de Susceptibilitate la Inundații (ISI) prin modelul combinat Fuzzy-AHP, pe cuprinsul bazinului hidrografic al râului Buzău

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.2. Studiu de caz


- Suprafață 5.350 km², toate formele de relief
Altitudini între 1 m și 1.925 m; pante de peste 25° în zona superioară

- Istoric hidrologic sever
Debit maxim istoric de 2.100 m³/s (1975, stația Măgura);

Inundații majore s-au produs și în 1970, 2005, 2010, 2016, 2019, afectând numeroase localități din zonă dar și principalele elemente de infrastructură rutieră precum Drumul Național 2 (E85) și DN 10.

- Clima
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.

- Utilizarea terenului
Pădure - 40,7%, teren arabil - 30,9%, zone construite - 4,6%.



CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.3. Date

- 205 locații afectate de inundații (1970-2019)

identificate din date IGSU/ANAR și validate prin teledetecție (NDWI, Landsat 5/7/8, Sentinel 1/2/3);

- 12 factori de condiționare - Altitudine; Pantă; Orientarea versanților; Curbura în plan; Topographic Position Index; Topographic Wetness Index; Indicele de convergență; Grupa hidrologică de sol; Utilizarea terenului; Distanța față de râuri; Precipitațiile; Litologia.

- Factori determinanți (exemple)

panta $< 3^\circ$ ocupă 35% din suprafață, dar 65% din locațiile inundate; grupa de sol B (54% din suprafață) concentrează 58% din inundații





Fig. 1.2 Factorii de condiționare a inundațiilor

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.4. Metode – fluxul metodologic



CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.4. Metode – Aplicarea AHP pentru ponderarea claselor de factor

- **Construcția matricei de comparație pe perechi**
- Clasele factorilor geografici sunt introduse într-o matrice de comparație. Toate clasele luate în considerare sunt comparate între ele prin acordarea unor puncte în cadrul matricei, reflectând importanța clasei respective în raport cu cea cu care este comparată. Valorile punctajelor sunt subiective, depinzând de experiența cercetătorului.
- Ponderea finală se calculează după crearea matricei standardizate.
- Valorile din matricea standardizată rezultă prin raportarea fiecărui punctaj din matricea de comparație la suma punctajelor de pe coloana respectivă, în timp ce ponderea finală este dată de media aritmetică a valorilor coeficienților din matricea standardizată, calculată, de această dată, pe fiecare rând.

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU
ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

Tabelul 1.1. Matricea de evaluare AHP (captură din teză)

1.4. Metode – Aplicarea AHP pentru ponderarea claselor de factor

- Construcția matricei de comparație pe perechi

Sursă: Costache R. et al. (2020), Journal of Hydrology, 585, 124808 – Anexa metodologică, secțiunea 1.4.2.

Factori și clase/categorii	Matrice de comparație pe perechi												Ponderi normalizate	Factori și clase/categorii	Matrice de comparație pe perechi										Ponderi normalizate		
	[1]	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]	[12]			[1]	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]				
Clasă/categorie														Clasă/categorie													
Panta														Curbura în plan													
[1] < 3°	1												0.439	[1] -11.8 – 0	1									0.089			
[2] 3 – 7°	1/2	1											0.246	[2] 0.1 – 0.5	4	1								0.324			
[3] 7 – 15°	1/4	1/2	1										0.181	[3] 0.6 – 8.5	6	2	1							0.587			
[4] 15 – 25°	1/5	1/3	1/3	1									0.089	Orientarea versanților													
[5] > 25°	1/6	1/5	1/6	1/3	1								0.045	[1] Zone plate	1									0.032			
TPI														[2] Nord	5	1											0.072
[1] (-20) – (-3.8)	1												0.458	[3] Nord-Est	4	3	1							0.104			
[2] (-3.7) – (-1.1)	1/2	1											0.258	[4] Est	4	4	5	1						0.218			
[3] (-1) – 1.3	1/4	1/2	1										0.158	[5] Sud-Est	4	3	3	4/5	1					0.164			
[4] 1.4 – 4.5	1/6	1/4	1/3	1									0.082	[6] Sud	5	2	2	5/7	2/3	1				0.144			
[5] 4.6 – 20	1/7	1/5	1/3	1/3	1								0.045	[7] Sud-Vest	2	4	2/3	3/8	3/4	4/5	1			0.113			
TWI														[8] Vest	3	5/4	4/3	4/9	2/3	3/5	4/5	1				0.090	
[1] -9.7 – 4.5	1												0.408	[9] Nord-Est	3	1/2	1/3	1/2	1/2	1/3	4/9	2/3	1	0.063			
[2] 4.6 – 8.4	1/2	1											0.299	Indice de convergență													
[3] 8.5 – 12	1/3	1/2	1										0.159	[1] (-100) – (-3)	1									0.489			
[4] 13 -15	1/4	1/5	1/2	1									0.084	[2] (-2.9) – (-2)	1/3	1								0.272			
[5] 16 – 25	1/6	1/6	1/4	1/2	1								0.049	[3] (-1.9) – (-1)	1/4	1/3	1							0.122			
Utilizarea terenurilor														[4] (-1) – 0	1/6	1/4	1/2	1									0.074
[1] Zone construite	1												0.241	[5] 0 – 100	1/8	1/7	1/3	1/2	1					0.044			
[2] Zone agricole	1/3	1											0.116	Grupa hidrologică de sol													
[3] Vii	1/5	1/2	1										0.076	[1] A	1									0.072			
[4] Livezi	1/3	1/3	1/5	1									0.067	[2] B	2	1								0.145			
[5] Pășuni	1/2	3	4	2	1								0.203	[3] C	3	2	1							0.201			
[6] Păduri	1/8	1/5	1/4	1/5	1/5	1							0.023	[4] D	7	3	5	1						0.582			
[7] Pajiști	1/3	1/3	2	2	1/3	5	1						0.070	Distanța față de râuri (m)													
[8] Mlaștini	1/3	1/3	1/2	1/2	1/4	2	1	1					0.051	0 – 50	1									0.319			
[9] Arbuști	1/2	3	4	1/3	1/3	4	2	2	1				0.152	50 – 100	1/2	1								0.226			
Litologie														100 – 150	1/3	1/2	1										0.156
[1] 1	1												0.031	150 – 200	1/4	1/3	1/2	1						0.108			
[2] 2	1/2	1											0.076	200 – 400	1/5	1/4	1/3	1/2	1					0.068			
[3] 3	1	1/3	1										0.094	400 – 700	1/6	1/5	1/4	1/3	1/2	1				0.062			
[4] 4	1/4	2	3	1									0.128	700 – 1000	1/7	1/6	1/5	1/4	1/3	1/4	1			0.038			
[5] 5	1/8	1/4	1	1/4	1								0.042	> 1000	1/7	1/8	1/7	1/6	1/3	1/5	1/4	1		0.022			
[6] 6	1/7	1/4	1	1/3	2	1							0.074	Altitudinea (m)													
[7] 7	1/6	1	2	1/2	3	1	1						0.064	2 – 200	1									0.310			
[8] 8	1/2	6	8	6	9	8	6	1					0.194	200 – 400	1/2	1								0.208			
[9] 9	1/3	3	5	4	8	6	4	1/3	1				0.095	400 – 600	1/3	1/2	1							0.171			
[10] 10	1/6	2	3	2	4	4	3	1/5	1/2	1			0.084	600 – 800	1/4	1/3	1/3	1						0.107			
[11] 11	1/7	1/3	1/2	1/3	1	1/2	1/3	1/9	1/7	1/4	1		0.062	800 – 1000	1/5	1/3	1/4	1/2	1					0.088			
[12] 12	1/9	1/	1/2	1/3	1	1/2	1/3	1/9	1/7	1/4	1	1	0.057	1000 – 1200	1/6	1/5	1/5	1/3	1/3	1				0.058			
Precipitații														1200 – 1400	1/6	1/6	1/5	1/5	1/4	1/3	1						0.038
[1] 460 – 500	1												0.023	> 1400	1/8	1/7	1/6	1/7	1/8	1/7	1/5	1		0.019			
[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														

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.4. Metode – Aplicarea metodei Fuzzy-AHP pentru determinarea ponderilor factorilor care influențează potențialul de inundație

- FAHP reprezintă o combinație între teoria mulțimilor fuzzy și metoda AHP, fiind utilizată pentru a îmbunătăți calitatea analizei și a reduce subiectivitatea în atribuirea ponderilor factorilor.
- Pentru determinarea ponderilor celor 12 factori, a fost utilizat algoritmul de analiză extinsă, a cărei primă etapă a constatat în construirea matricei fuzzy triunghiulare de mai jos.

Tabel 1.2. Matricea de evaluare 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
Distanța față de râuri(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
Grupa de sol (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
Indicele de convergență (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
Litologia (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
Orientarea (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

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.4. Metode – Aplicarea metodei Fuzzy-AHP pentru determinarea ponderilor factorilor care influențează potențialul de inundație

- Odată ce matricea este construită, se va trece la aplicarea funcției aritmetice fuzzy, care constă în adunarea fiecărui rând din cadrul matricei conform:

$$RS_i = \sum_{j=1}^n a'_{ij} = \left(\sum_{j=1}^n l_{ij}, \sum_{j=1}^n m_{ij}, \sum_{j=1}^n u_{ij} \right), \quad i = 1, \dots, n, \text{ unde } a'_{ij} = (l_{ij}, m_{ij}, u_{ij}) = a'^{-1}_{ij} = (1/l_{ij}, 1/m_{ij}, 1/u_{ij}).$$

- Următorul pas a constat în normalizarea relației anterioare pentru a determina valorile sintetice fuzzy extinse pentru fiecare număr fuzzy l, m și n din cadrul matricei. Această etapă a fost realizată prin aplicarea următoarei relații:

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

- Mai departe valoarea sintetică fuzzy extinsă S'_i va fi utilizată pentru calcularea gradului de posibilitate $S'_i \geq S'_j$ care se calculează conform relației:

$$V(S'_i \geq S'_j) = \begin{cases} 1, & \text{if } m_i \geq m_j, \\ \frac{u_i - l_j}{(u_i - m_i) + (m_j - l_j)}, & l_j \leq u_i, \quad i, j = 1, \dots, n; j \neq i \quad (7) \text{ unde } S'_i = (l_i, m_i, u_i) \text{ and } S'_j = (l_j, m_j, u_j). \\ 0, & \text{altfel} \end{cases}$$

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.4. Metode – Aplicarea metodei Fuzzy-AHP pentru determinarea ponderilor factorilor care influențează potențialul de inundație

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

- Considerând valoarea minimă a gradelor de posibilitate $\{\min, \{V(S'_i \geq S'_k)\}, , k, = 12 \dots n \ k \neq i\}$ estimate pentru fiecare din cei 12 factori conform Tabelului 1.4, atunci ponderea fiecărui factor se va calcula după cum urmează:

$w(a_i) = [w, (a_1), w, (a_2) \dots w(a_{12})]^T$, unde a_i reprezintă factorii de condiționarea inundabilității.

- Astfel fiecare valoare $\min\{V(S'_i \geq S'_k)\}$, prezentată în Tabel 1.4, va fi divizată la suma tuturor celor 12 valori aferente predictorilor de inundabilitate.
- Ultima valoare (**Weight**) din coloana asociată fiecărui factor reprezintă ponderea aferență acestora în vederea calculării Indicelui Susceptibilității la Inundații (ISI).

Altitudine = 1	Distanța față de râuri = 2	Utilizarea terenurilor = 3	Soluri = 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	Lithologia = 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	Precipitațiile = 10	Curbura în plan = 11	Orientarea versanților = 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

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.5. Determinarea Indicelui Susceptibilității la inundații (ISI)

- Valorile ISI au rezultat din agregarea ponderată a factorilor geografici în mediul GIS. Astfel, conform relației de mai jos, coeficienții AHP ai claselor/categoriilor de factori au fost înmulțiți cu ponderile FAHP specifice fiecărui factor, după care toate produsele au fost însumate. Întregul proces a fost realizat cu ajutorul algebrei cartografice.
- Astfel, în algebra cartografică a fost folosită următoarea formulă:

$$ISI = Panta_{AHP} * Panta_{FAHP} + Altitudine_{AHP} * Altitudine_{FAHP} + TWI_{AHP} * TWI_{FAHP} + TPI_{AHP} * TPI_{FAHP} + Distanța Râu_{AHP} * Distanța Râu_{FAHP} + Utilizare teren_{AHP} * Utilizare teren_{FAHP} + Indice de Convergență_{AHP} * Indice de Convergență_{FAHP} + Sol_{AHP} * Sol_{FAHP} + Litologia_{AHP} * Litologia_{FAHP} + Precipitații_{AHP} * Precipitații_{FAHP} + Curbura în plan_{AHP} * Curbura în plan_{FAHP} + Orientarea versanților_{AHP} * Orientarea versanților_{FAHP}$$

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.5. Determinarea Indicelui Susceptibilității la inundații (ISI)

- Valorile ISI pe suprafața bazinului hidrografic al râului Buzău sunt cuprinse între 0,04 și 0,81 și au fost grupate în cinci clase utilizându-se metoda de clasificare Natural Breaks (Pragurilor Naturale).
- Astfel, valorile foarte scăzute și scăzute ale ISI sunt cuprinse între 0,04 și 0,29 și ocupă circa 50% din bazinul hidrografic al râului Buzău. Conform Fig. 1.8, acestea ocupă suprafețe extinse în bazinul superior și mijlociu.
- Valorile medii ale ISI sunt răspândite pe aproape 34% din zona supusă cercetării.
- În restul de bazin hidrografic ce însumează o pondere de circa 16% 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. 1.8 Valorile ISI rezultate în urma aplicării Fuzzy-AHP




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

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.6. Validarea rezultatelor

- Rata de Succes – $AUC = 0,953$

eșantionul de antrenament (70% din cele 205 locații istorice)

- Rata de Predicție – $AUC = 0,932$

eșantionul independent de validare (30%)

- Interpretare

Valorile AUC mai mari de 0.9 indică o performanță foarte ridicată a modelului Fuzzy-AHP aplicat pentru determinarea susceptibilității la inundații.




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

CAPITOLUL 1. UTILIZAREA FUZZY-ANALYTICAL HIERARCHY PROCESS PENTRU ESTIMAREA SUSCEPTIBILITĂȚII LA INUNDAȚII

1.7. Concluzii

- Integrarea AHP cu logica fuzzy reduce subiectivitatea ponderării bazate pe experți, menținând un cadru decizional structurat și transparent.
- 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 fiind predictorii-cheie.

- Validare robustă

Curba ROC confirmă o capacitate predictivă puternică ($AUC > 0,9$), consecventă cu literatura internațională

- Direcțiile viitoare includ seturi de date cu rezoluție mai mare și modele hibride Fuzzy-AHP combinate cu tehnici de învățare automată.

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

- Subdirecția de cercetare nr. 2

utilizarea metodelor bazate pe arbori de decizie pentru estimarea susceptibilității la viituri rapide

- 3 articole ISI de bază

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>.

- 2 proiecte de cercetare

RO-FLOOD-SUSCEP (Contract PD226/08.04.2021) și MULTICARE – PN IV (Contract 50PHE/03.01.2024), ambele cu rol de Director de proiect la Universitatea Transilvania din Brașov

- Obiectiv

calcularea Flash-Flood Potential Index (FFPI) prin modele individuale și hibride, aplicate bazinului superior și mijlociu al râului Prahova

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.2. Studiu de caz

Sectorul superior și mijlociu al bazinului hidrografic al râului Prahova:

- este situat în partea central-sudică a României;
- suprafața este de circa 2600 km²;
- panta medie relativ ridicată: 12,43°;
- gradul de împădurire 48,2%;
- grupa hidologică de sol A este predominantă cu circa 801 km²;
- una din cele mai dezvoltate regiuni ale României din punct de vedere al infrastructurii, populației și turismului.




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

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.3. Date

- Ortofotoplanuri (Google Earth) de pe care s-au vectorizat zonele afectate de fenomene asociate torențialității => 260 km² de suprafețe afectate de torențialitate din care 70% au fost utilizate pentru instruirea modelelor în vreme ce 30% au fost păstrate pentru validarea rezultatelor.
- Modelul Digital de Teren pe baza căruia au fost derivați indicii morfometrici care influențează scurgerea apei la suprafață;
- Baza de date Corine Land Cover din care s-a extras modul de utilizare a terenurilor;
- Harta Digitală a Solurilor din România, 1:200.000 din care au fost derivate grupele hidrologice de sol;
- Harta Geologică a României, 1:200.000 din care au fost preluate formațiunile litologice.




Fig. 2.2. Distribuția spațială a zonelor afectate de torențialitate

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.3. Date

- Factorii de condiționare ai viiturilor rapide: panta; indicele de convergență; orientarea versanților; Modified Fournier Index; Curve Number; litologia; TPI; TWI; curbura în plan; curbura în profil; indicele de formă a bazinului hidrografic; suprafața din amonte a bazinului hidrografic.
- Aspecte de remarcat:
 - Se remarcă pantele cuprinse între 15 - 25° în care se găsesc cei mai mulți pixeli cu torențialitate, precum și pantele de peste 25° în care există cea mai mare densitate a fenomenelor de torențialitate;*
 - De asemenea pășunile conțin peste 60% din totalul zonelor cu fenomene de torențialitate, în vreme ce în cuprinsul arealelor forestiere acestea aproape lipsesc;*
 - Din perspectiva orientării versanților cele mai mari suprafețe cu torențialitate apar pe suprafețele estice și sud-estice.*





Fig. 2.3 Factorii de condiționare a viiturilor rapide

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.4. Metode – fluxul metodologic



CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.5.1. Capacitatea predictivă

- Metoda **Correlation-based features selection** (CFS) se bazează pe relația următoare:

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

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.

- Ierarhia

panta (AM = 0,294), Curve Number (AM = 0,258) și litologia (AM = 0,193) formează tripleta cu cea mai mare putere discriminantă

- Validitatea întregului set

toți cei 12 factori au înregistrat AM > 0 și au fost păstrați în analiză




Fig. 2.4 Capacitatea de predicție a factorilor (valori medii de merit – AM)

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.5.2. Modelul Weights of Evidence

- Această metodă bazată pe date reprezintă un model statistic bivariat Bayesian utilizat pe scară largă în domeniul geostiințelor și ingineriei.
- La baza aplicării metodei stă determinarea celor 2 ponderi W^+ - ponderea pozitivă, W^- - ponderea negativă:

$$W^+ = \ln \frac{\frac{Npix_1}{Npix_1 + Npix_2}}{\frac{Npix_3}{Npix_3 + Npix_4}} \quad W^- = \ln \frac{\frac{Npix_2}{Npix_1 + Npix_2}}{\frac{Npix_4}{Npix_3 + Npix_4}}$$

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.

- Ponderea finală conform Costache and Zaharia (2017) se calculează prin următoarea relație: $Wf = Wplus + Wmin total - Wmin$, unde $Wplus$ este ponderea pozitivă a clasei unui factor, $Wmin$ este ponderea negativă a clasei unui factor, $Wmintotal$ este totalul ponderilor negative ale tuturor claselor din cadrul unui factor.

- Mai departe pentru determinarea finală a $FFPI_{WoE}$ a fost utilizată următoarea ecuație:

$$FFPI_{WoE} = \sum_{j=1}^n Wf_{ij}$$

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

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.5.2. Modelul Weights of Evidence

- 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).

Tabel 2.1. Valorile coeficienților WOE pentru fiecare clasă/categorie de factori geografici

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
	Nord-Est	9.07	6.11	-0.47	0.67

Factor	Clasă	Pixelii claselor (%)	Pixelii torențiali (%)	Coeficientul WOE	Coeficientul WOE standardizat
Indicele de convergență	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
	(-96) – (-3)	52.81	52.77	0.01	0.50
Curve Number	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 (km²)	< 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

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.5.2. Modelul Weights of Evidence - calculul FFPI

- 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.
- Prima clasă, care denotă valori FFPI WOE foarte mici, ocupă aproximativ 12,6% din suprafața studiată. În aceste zone 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.




Fig. 2.5 Distribuția spațială a valorilor FFPI WOE

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.5.3. Arborii de decizie (RF, LMT, ADT)

Rotation Forest (RF)

Metodă de clasificare de tip ansamblu, propusă de Rodriguez et al. (2006), care extrage caracteristici prin împărțirea aleatorie a factorilor în K subseturi, cărora li se aplică Analiza Componentelor Principale (PCA). Se obține o matrice de rotație pentru fiecare arbore component, îmbunătățind diversitatea clasificatorilor. Fiind un model ansamblu, oferă precizie superioară metodelor cu un singur clasificator, fiind aplicată individual și hibrid (RF-WOE) în Weka.

Logistic Model Tree (LMT)

Combinație între Regresia Logistică și arborii de decizie (Landwehr et al., 2005), formată din noduri interne și frunze terminale. La nivelul frunzelor se aplică o funcție de regresie logistică asupra rezultatelor arborelui, prin algoritmul LogitBoost, iar tăierea arborelui se realizează cu algoritmul CART. Oferă învățare rapidă, fără ajustarea unor parametri sensibili, și eficiență ridicată, fiind aplicată individual și hibrid (LMT-WOE) în Weka.

Alternating Decision Tree (ADT)

Propus de Freund și Mason (1999), combină algoritmul de amplificare AdaBoost cu structura arborelui decizional, alternând straturi de noduri de predicție cu noduri de decizie. Nodurile de predicție conțin o valoare numerică, iar cele de decizie specifică o condiție. Comparativ cu CART sau Random Forest, ADT produce structuri mai simple și reguli de clasificare mai ușor interpretabile, fiind aplicat individual și hibrid (ADT-WOE) în Weka.

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.5.3. Performanțele modelelor individuale și hibrid în cadrul procesului de antrenament și ponderea factorilor geografici




Fig. 2.6 Corelația dintre numărul de iterații și acuratețea modelelor

Factorii de condiționare a viiturilor rapide




Fig. 2.7 Ponderea factorilor geografici




Fig. 2.8 Arborii de decizie optim segmentați (a. modelul ADT; b. Modelul ADT-WoE)

Tabel 2.2 Parametrii de optimizare a modelelor aplicate în prezentul studiu

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

- Fig. 2.6 ilustrează evoluția acurateței celor șase modele (RF, RF-WOE, LMT, LMT-WOE, ADT, ADT-WOE) pe parcursul a 20 de iterații succesive de antrenament. Valorile optime, extrase din punctele de maxim ale acestor curbe, sunt sintetizate în Tabelul 2.2. RF atinge acuratețea maximă (93,4%) după 18 iterații (seed 4), fiind urmat îndeaproape de ADT (93,1%, 19 iterații, seed 3).
- Fig. 2.7 confirmă panta, Curve Number și litologia drept factorii cu ponderea cea mai mare, consecvent pe toate cele șase modele.
- Fig. 2.8 detaliază structura arborilor optim segmentați pentru ADT și ADT-WOE.

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE

PRIN ARBORI DE DECIZIE

2.5.4. Calculul FFPI prin arbori de decizie

- Pentru determinarea FFPI au fost folosite valorile ponderilor factorilor geografici în algebra cartografică.
- În toate cele trei perechi, integrarea WOE generează nuclee de risc ridicat mai omogene și mai bine delimitate spațial
- Modelele individuale prezintă, în schimb, distribuții mai difuze și fragmentate ale acelorași clase FFPI
- Ambele clase (Mare și Foarte Mare) se concentrează predominant în zonele de nord-vest și nord ale bazinului

- **Ierarhia celor 6 modele – clasele Mare + Foarte Mare (pondere cumulată)**
 1. LMT – 43,7% (pondere maximă)
 2. RF – 42,1%
 3. RF-WOE – 40,4%
 4. ADT – 36,7%
 5. ADT-WOE – 35,0%
 6. LMT-WOE – 30,3% (pondere minimă)




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




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




Fig. 2.11 Distribuția spațială a valorilor FFPI (a. modelul ADT; b. modelul ADT-WOE)

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.5.5. Validarea rezultatelor (Curba ROC)

▪ Interpretare generală

Toate cele 7 modele depășesc $AUC = 0,8$ în ambele rate, iar 6 din 7 trec de 0,9 la Rata de Succes – performanță „excelentă” (Yesilnacar & Topal, 2005).

Combinarea cu WOE reduce, per ansamblu, diferența dintre acuratețea de antrenament și cea de validare, crescând mai ales stabilitatea modelelor, nu neapărat acuratețea brută.

Rata de Succes (antrenament) – ierarhie

ADT-WOE – 0,917 (*maxim*)

RF – 0,91

LMT – 0,909

LMT-WOE – 0,906

WOE – 0,903

RF-WOE – 0,893

ADT – 0,889 (*minim*)

Rata de Predicție (validare) – ierarhie

ADT-WOE – 0,886 (*maxim*)

LMT-WOE – 0,881

LMT – 0,876

RF-WOE – 0,872

ADT – 0,863

WOE – 0,841

RF – 0,825 (*minim*)




Fig. 2.12 Curba ROC (a. Rata de Succes; b. Rata de Predicție)

CAPITOLUL 2. DETERMINAREA POTENȚIALULUI DE FORMARE A VIITURILOR RAPIDE PRIN ARBORI DE DECIZIE

2.6. Concluzii

- **Contribuție metodologică**
Elimină ponderarea egală, subiectivă a FFPI clasic → introduce scheme de ponderare bazate pe date (WOE) + istoric torențial.
- **Performanță – validare ROC**
ADT-WOE → cel mai bun model general (AUC 0,917/0,886), generalizare robustă
RF → overfitting sever, corectat prin hibridizare
LMT → stabil, cu sau fără WOE
- **Efectul WOE – neuniform**
LMT-WOE → reduce puternic riscul extrem
RF-WOE → „solidifică” spațial riscul, fără să-l reducă
ADT-WOE → redistribuie intern (Foarte Mare → Mare)
- **Factori determinanți**
Panta · conectivitatea hidrologică · utilizarea terenurilor
- **Aplicabilitate**
Bazinul Prahova – risc mediu-ridicat pe suprafețe extinse → utilitate directă pentru avertizare timpurie și planificare spațială
- **Limite & direcții viitoare**
Incertitudine date de intrare → extinderea seturilor de date, alte metode ansamblu, testare în alte bazine

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

- Subdirecția de cercetare nr. 3

metode de inteligență artificială pentru detectarea zonelor susceptibile la viituri rapide în bazine hidrografice mici

- 2 articole ISI de bază

Costache R., Hong H., Pham Q.B. (2020) – Science of the Total Environment, 711, 134514, DOI: 10.1016/j.scitotenv.2019.134514 (IF 6,551, Q1, Highly Cited); Abedi R., Costache R.# et al. (2022) – Geocarto International, 37(19), 5479-5496, DOI: 10.1080/10106049.2021.1920636 (IF 3,8, Q2, Highly Cited)

- Proiect de cercetare

RO-FLOOD-SUSCEP (Contract PD226/08.04.2021), Director de proiect la Universitatea Transilvania din Brașov

- Obiectiv


combinarea Rețelelor Neuronale Artificiale (MLP) cu Indicele Statistic (SI) și compararea cu alte 4 metode de machine learning

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.1. Studiu de caz

Bazinul hidrografic al râului Bâsca Chiojdului:

- Situat în partea central-sud-estică a României (Fig. 3.1);
- Afluent de dreapta al Buzăului;
- Altitudini: 242 - 1463 m;
- Panta medie: 12,3°;
- Grad de împădurire: 50%;
- Grupe hidrologice de sol: predominant C și D;
- Suprafață relativ redusă: 340 km²



Expunere ridicată la fenomenele asociate scurgerii accelerate a apei pe versanți




Fig. 3.1 Localizarea bazinului hidrografic al râului Bâsca Chiojdului și a zonelor torențiale


- Cele mai devastatoare viituri rapide au avut loc în 1975, când debitul Bâsca Chiojdului a atins valoarea maximă istorică de 300 m³/s, în 1990 când debitul a fost egal cu 170 m³/s și în 2005 când valorile debitului au fost de 236 m³/s.

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.2. Date - zonele torențiale

Cum au fost obținute zonele torențiale

- Digitalizare pe bază de imagini aeriene și măsurători de teren
criteriu: prezența unitară a microformelor torențiale (ravene, rigole) – Costache & Zaharia, 2017
- 36 de poligoane identificate, ~34 km² (10% din suprafața bazinului)
convertite din shapefile poligon în format raster, celulă 30 m – identică cu rezoluția DEM SRTM
- 37.723 pixeli torențiali rezultați
împărțiți 70% antrenament (26.406 px) / 30% validare (11.317 px), prin Generate Subset Polygons (ArcGIS Pro 2.2)
- Set de control non-torențial, aceeași dimensiune (37.723 px)
selecție aleatorie din zone cu pantă ~0°, unde scurgerea de suprafață este aproape imposibilă; împărțit tot 70%/30%
- Clasificare binară finală
1 = prezența proceselor torențiale; 0 = absența acestora



CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.2. Date - factorii de condiționare a viiturilor rapide

Aspecte de remarcat – factorii de condiționare

- 10 factori: 7 morfometrici (din DEM) + 3 vectoriali
panta, L-S Factor, indice de convergență, SPI, TWI, curbură în profil, TPI · utilizare teren, grupă hidrologică de sol, litologie
- Clasificare diferențiată pe factor
Natural Breaks pentru L-S Factor, TWI, TPI; praguri din literatură pentru pantă, curbură, indice de convergență, SPI
- L-S Factor – combină lungimea și înclinarea pantei
exponenți m, n optimizați automat de SAGA GIS, în funcție de caracteristicile DEM
- SPI – capacitatea de transport a sedimentelor de-a lungul rețelei hidrografice
formulă derivată din panta locală și suprafața contributivă amonte (Moore et al., 1991)
- Factori vectoriali – diversitate ridicată în bazin
8 categorii de utilizare a terenului, toate cele 4 grupe hidrologice de sol, 10 grupe litologice – toți converșiți în raster 30 m pentru omogenitate cu factorii morfometrici





Fig. 3.2 Factorii de condiționare ai viiturilor rapide

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.3. Metode – fluxul metodologic



CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.4.1 Testarea capacității de predicție și analiza de multicoliniaritate

- Valoarea **Information Gain (IG)** pentru fiecare predictor al viiturii rapide a fost estimată folosind următoarea formulă:

$$IG(Y_i|X_i) = H(Y) - H(Y|X_i)$$

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

- Cea mai mare valoare (IG = 0,0775) a fost atribuită 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).
- Pe ultimele două poziții, cu IG = 0, se află curbura în profil și Stream Power Index. Aceste 2 variabile au fost excluse din analiza ulterioară.

Tabelul 3.1. Capacitatea predictivă și analiza multicoliniarității 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

- Multicoliniritatea** a fost estimată prin utilizarea indicatorilor Tollerance (TOL) și Variance Inflation (VIF)
- 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.

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.4.2. Calcularea Statistical Index (SI)

- Ponderile indicelui statistic pentru fiecare clasă/categorie de factori au fost calculate folosind următoarea formulă:

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

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.

Ponderile SI pe factori de condiționare (Tabelul 3.1)

- Panta:** -1,17 (clasa 0°-3°) → 0,5 (clasa >25°)
relație direct proporțională – panta mare favorizează scurgerea rapidă, deci pondere SI mai mare
- TPI (Topographic Position Index):** valoare maximă 0,32, atribuită clasei 4,6-20
indică zonele de relief convex/culmi, unde scurgerea se concentrează mai puternic
- TWI (Topographic Wetness Index):** valoare maximă 0,12, în clasa medie 7,79-10,21
ponderea maximă apare la o umiditate topografică moderată, nu la extreme

Tabelul 3.1. Valori SI normalizate și ponderi ale factorilor de condiționare a viiturilor rapide
**Pp(%) - procentul ocupat de pixelii fiecărei clase; Pt(%) - procentul de pixeli torențiali.*

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					

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.4.3. Aspecte teoretice ale modelelor de inteligență artificială utilizate

Regresia Logistică (LR)

Determină relația dintre variabila binară dependentă (prezență/absență torențialitate) și predictorii independenți, prin modelul $p = 1/(1+e^{-z})$, unde Z este o combinație liniară a coeficienților de regresie (β_i). Predictorii pot fi continui, discreți sau micști.

Random Forest (RAF)

Metodă ansamblu (Breiman, 2001) care construiește mulți arbori decizionali pe subseturi aleatorii de date și caracteristici (bootstrap), agregând predicțiile prin vot majoritar. Reduce semnificativ riscul de supra-ajustare comparativ cu un singur arbore.

Classification and Regression Tree (CART)

Metodă bazată pe reguli, care segmentează recursiv datele prin selectarea predictorului ce reduce cel mai mult entropia. Acceptă variabile numerice, binare și categoriale, rezultând un arbore decizional tăiat ulterior (pruning) pentru claritate.

Support Vector Machine (SVM)

Bazat pe minimizarea riscului structural, caută un hiperplan optim care separă cele două clase într-un spațiu de caracteristici transformat printr-o funcție kernel (Radial Basis). Vectorii suport – punctele cele mai apropiate de hiperplan – definesc granița optimă de decizie.

Multilayer Perceptron (MLP)

Rețea neuronală feed-forward ce surprinde relații neliniare complexe. Prin propagare înainte se calculează ieșirile, iar prin backpropagation ponderile sunt ajustate iterativ pentru a minimiza eroarea medie pătratică (RMSE), până la o valoare acceptabilă.

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.4.4. Aplicarea modelelor AI - performanța obținută de acestea în procesul de antrenament

Tabelul 3.2. Valorile indicatorilor statistici de performanță în faza de antrenament pentru modelele aplicate

Model	Acuratețe (%)	Kappa	AUC (antrenament)
LR-SI	90,1	0,803	0,915
CART-SI	91,3	0,826	0,929
MLP-SI	92,4	0,848	0,942
RAF-SI	89,6	0,792	0,903
SVM-SI	89,0	0,781	0,894

- Toate cele 5 modele hibride depășesc pragul de acuratețe 89%, confirmând eficiența integrării Statistical Index cu algoritmi de învățare automată.
- **MLP-SI** domină clar ierarhia – acuratețe maximă (92,4%), Kappa maxim (0,848) și AUC maxim (0,942) – urmat de **CART-SI** (91,3%/0,929).
- **SVM-SI** înregistrează cea mai slabă performanță (89,0%/0,894), deși rămâne competitiv.
- Valorile Kappa > 0,8 pentru toate modelele indică un acord „aproape perfect” între predicție și observație, validând robustețea întregii abordări metodologice.

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.4.5. Rezultate - faza de antrenament CART-SI – arbore de decizie optim (Fig. 3.3)

- Structură optimă

11 noduri terminale, după eliminarea diviziunilor ne semnificative (pruning), din arborele inițial complex

- Ierarhia factorilor din structura arborelui
utilizarea terenului (0,21) > panta (0,18) > litologie (0,16) > grupa hidrologică de sol (0,15) > L-S Factor (0,11) > TWI (0,09) > TPI (0,07) > indicele de convergență (0,03)




Fig. 3.3 Schema arborelui de regresie optim tăiat pentru zona de studiu

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.4.5. Rezultate - faza de antrenament MLP-SI – valori RMSE și structura (Fig. 3.4a; b)

- Proces încercare-eroare
s-a testat eroarea RMSE pentru 50 de arhitecturi MLP, cu 1 până la 50 de neuroni ascunși
- Scădere continuă până la 19 neuroni
RMSE scade de la 0,473 (1 neuron) la 0,014 (19 neuroni), apoi se stabilizează la 0,014 până la 50 de neuroni
- Justificare arhitecturală
un număr excesiv de neuroni ascunși poate cauza supra-ajustare, motiv pentru care s-a ales arhitectura optimă cu 19 neuroni (Fig. 3.4a)
- Arhitectură feed-forward
10 factori de intrare, un strat ascuns cu 19 neuroni, ieșire binară torențial/non-torențial (Fig. 3.4b)
- Utilizare ulterioară
ponderea fiecărui predictor, obținută după antrenament, a fost folosită într-o sumă ponderată pentru calculul FFPI MLP-SI




Fig. 3.4 (a) Valorile RMSE pentru arhitecturi MLP de la 1 la 50 de neuroni ascunși; (b) structura MLP pentru arhitectura cu 19 neuroni ascunși

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.4.5. Rezultate - faza de antrenament RAF-SI – eroarea OOB (Fig. 3.5)

- Optimizarea numărului de arbori

eroarea OOB scade odată cu creșterea numărului de arbori, stabilizându-se la 0,0831 începând cu 234 de arbori

- Arhitectura finală RAF-SI

structură cu 234 de arbori decizionali

- Ierarhia predictorilor

utilizarea terenului (0,23) > panta (0,2) > litologie (0,13) > grupa hidrologică de sol (0,12) > TWI (0,11) > L-S Factor (0,09) > TPI (0,08) > indicele de convergență (0,04)




Fig. 3.5 Valorile erorii OOB (Out-of-Bag) pentru maxim 300 de arbori

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.4.5. Rezultate - faza de antrenament LR-SI și SVM-SI

LR-SI – pragul optim de decizie (cut-off)

Cut-off	Specif. (%)	Senzit. (%)	Sumă
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

Cut-off optim = 0,7

valoarea limită care maximizează suma Specificitate + Senzitivitate ($91,2 + 89,1 = 180,3$), fiind utilizată în configurarea finală a modelului hibrid LR-SI

SVM-SI – parametrii C și γ

- Configurare – nucleu RBF (Radial Basis Function)
SVM-SI a fost antrenat în Weka 3.8.6, utilizând coeficienții SI drept date de intrare pentru pixelii torențiali/netorențiali
- Parametrul de penalizare C
controlează gradul de toleranță la erorile de clasificare, prevenind supraajustarea (overfitting) modelului
- Termenul γ (gamma)
controlează gradul de neliniaritate al hiperplanului de separare din spațiul de caracteristici transformat
- Optimizare prin validare încrucișată
au fost testate multiple perechi (C, γ) până la identificarea combinației cu cea mai bună precizie
- Valorile optime obținute
 $C = 2,1 \cdot \gamma = 0,12$ – configurația finală utilizată pentru calcularea FFPI SVM-SI

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.4.6. Valoarile FFPI pe fiecare model

Interpretare generală

- Procentul din bazin acoperit cu valori Mari și Foarte Mari ale FFPI variază între 26,7% și 38,8%, confirmând un grad ridicat de expunere a bazinului Bâsca Chiojdului la fenomenele de viituri rapide.
- Pentru majoritatea modelelor, aceste valori ridicate se concentrează în special în partea centrală a bazinului.

Ierarhia celor 6 modele – clasele Mare + Foarte Mare

1. SVM-SI – 38,8% (*pondere maximă*)
2. MLP-SI – 32%
3. CART-SI – 31%
4. SI – 30,7%
5. RAF-SI – 30%
6. LR-SI – 26,7% (*pondere minimă*)

Ecart total ≈ 12 puncte procentuale între SVM-SI (maxim) și LR-SI (minim).




Fig. 3.6 Distribuția spațială a valorilor FFPI (a. SI; b. LR-SI; c. CART-SI; d. RAF-SI; e. MLP-SI; f. SVM-SI)

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.5. Validarea rezultatelor

Interpretare generală

- Toate cele 6 modele depășesc $AUC = 0,9$ în ambele rate, confirmând performanță „excelentă” (Yesilnacar & Topal, 2005) și validând robustețea abordării prin hibridizarea SI cu algoritmi de învățare automată
- Diferențele dintre modele sunt reduse, dar statistic semnificative (test Wilcoxon, $p < 0,05$), fără a indica un decalaj major de performanță în cadrul setului

Rata de Succes (antrenament) – ierarhie

1. MLP-SI – 0,94 (*maxim*)
2. CART-SI – 0,939
3. RAF-SI – 0,933
4. SVM-SI – 0,929
5. LR-SI – 0,925
6. SI – 0,92 (*minim*)

Rata de Predicție (validare) – ierarhie

1. MLP-SI – 0,927 (*maxim*)
2. CART-SI – 0,922
3. SVM-SI – 0,918
4. RAF-SI – 0,914
5. SI – 0,91
6. LR-SI – 0,901 (*minim*)




Fig. 3.7 Curbele ROC pentru cele șase modele aplicate (a. Rata de Succes; b. Rata de Predicție)

CAPITOLUL 3. DETECTAREA ZONELOR SUSCEPTIBILE LA VIITURI RAPIDE CU AJUTORUL INTELIGENȚEI ARTIFICIALE

3.6. Concluzii

- Studiul susceptibilității la viituri rapide s-a bazat pe compararea metodei statistice bivariate (SI) cu cinci modele de ****inteligență artificială**** (LR-SI, CART-SI, MLP-SI, RAF-SI, SVM-SI), toate antrenate pe 8 predictorii și un eșantion prezență/absență a torențialității. Rezultatele arată că ****26,3-38,8%**** din zona de cercetare prezintă potențial mare-foarte mare, iar validarea prin curba ROC confirmă ****MLP-SI**** drept cel mai eficient model (AUC = 0,94 antrenament / 0,927 validare).
- Rezultatele pot fi afectate de anumite incertitudini – erori de digitalizare a zonelor torențiale și reprezentarea spațială inexactă a factorilor de condiționare – însă principala noutate rămâne utilizarea celor cinci modele de inteligență artificială pentru calcularea FFPI într-un bazin hidrografic mic.
- Practic, rezultatele pot fi valorificate direct de INHGA pentru prognoză și avertizare, iar autoritățile centrale și locale le pot folosi pentru a prioritiza intervențiile în zonele susceptibile – atât preventiv (interzicerea defrișărilor, împădurire, gestionarea zonelor torențiale), cât și post-eveniment (creșterea rezilienței, restaurare socio-economică și sprijin pentru populația afectată).

PLANUL DE DEZVOLTARE PROFESIONALĂ A CARIEREI UNIVERSITARE

Este structurat în jurul a patru piloni

I

Dezvoltarea direcțiilor de cercetare științifică

Consolidarea, extinderea și internaționalizarea direcțiilor de cercetare inițiate în teză – modele predictive, teledetecție, multi-hazard, Digital Twin.

II

Cariera academică și dezvoltarea didactică

Predare, supervizare doctorală și dezvoltare curriculară, bazate pe experiența ca profesor asociat GIS și pe programul Erasmus+ BIP.

III

Colaborare instituțională și internațională


Extinderea parteneriatelor naționale și europene (Horizon Europe), precum și a colaborărilor cu autorități publice.

IV

Vizibilitate și impact științific

Publicare de rang înalt, activitate editorială susținută și participare constantă la comunitatea științifică internațională.

5.1. Direcții de cercetare – de la modele predictive la Digital Twin



- **Continuitate directă cu teza**

agenda va continua să se concentreze pe evaluarea susceptibilității la inundații și viituri rapide, extinsă acum spre analiza integrată multi-hazard

- **Cadru instituțional**

rolul de coordonator în proiectul Horizon Europe MULTICARE oferă platforma pentru cercetare interdisciplinară internațională

5.2. CARIERĂ ACADEMICĂ ȘI DEZVOLTARE DIDACTICĂ

- Îmi voi consolida cariera academică prin predare, supervizare doctorală și dezvoltare curriculară.
 - **Voi propune patru cursuri noi:**
 1. Aplicații GIS și teledetecție în inginerie și știința mediului
 2. Modelare hidrologică și evaluarea pericolelor
 3. Tehnici de machine learning pentru analiza geospațială
 4. Managementul riscului și planificare spațială
 - Componentă practică accentuată
instruire aplicată utilizând ArcGIS, QGIS și Python

5.2. TEME DE DOCTORAT PROPUSE

Trei direcții pentru viitorii studenți doctoranzi, cu metodologie și obiective proprii

1. Evaluare multi-risc bazată pe AI în vederea managementului durabil al bazinelor hidrografice

Cadru integrat pentru susceptibilitate, hazard și risc (inundații, viituri, alunecări, eroziune) în scenarii climatice actuale/viitoare. Metode: GIS/RS, machine learning, decizie multicriterială, analiza datelor climatice.

2. Evaluarea vulnerabilității infrastructurii rutiere prin utilizarea combinată a GIS și modelării hidraulice

Identificarea segmentelor rutiere critice și cuantificarea vulnerabilității fizice/funcționale. Metode: GIS/RS, modelare hidraulică 1D/2D, indici de vulnerabilitate.

3. Dezvoltarea unui sistem integrat de avertizare timpurie pentru viituri rapide (EWS)

Proгноza viiturilor rapide prin combinarea monitorizării hidrometeo în timp real cu modelarea hidrologică/hidraulică. Metode: GIS/RS, modelare 1D/2D, hidrografe unitare.

5.2. STANDARD DE FORMARE DOCTORALĂ

Toți doctoranzii vor beneficia de expertiza acumulată pentru îndeplinirea cerințelor minime de publicare necesare finalizării studiilor doctorale.

- Minimum 4 publicații per doctorand

din care cel puțin 1 articol ISI, condiție standard pentru finalizarea studiilor doctorale

- Participare la conferințe științifice

încurajare pentru participarea la International Scientific Conference CIBv – Civil Engineering and Building Services, organizată de Facultatea de Construcții a Universității Transilvania

- Continuitate metodologică

toate cele 3 teme se bazează direct pe competențele metodologice dezvoltate în Capitolele 1-3 ale prezentei teze (GIS, teledetecție, machine learning, decizie multicriterială)

5.3. CONSOLIDAREA COLABORĂRII NAȚIONALE ȘI INTERNAȚIONALE

Implicarea actuală în multiple proiecte de cercetare, inclusiv inițiative Horizon Europe, demonstrează capacitatea de a lucra în echipe multidisciplinare și internaționale.

- Termen scurt – consolidarea colaborărilor existente
instituții din Europa și Asia, unde există deja coautorat pe numeroase lucrări științifice
- Termen mediu – inițierea de noi proiecte
coordonarea de noi proiecte naționale și europene, cu accent pe Horizon Europe și granturi naționale
- Parteneriate cu autorități publice
autorități de gospodărire a apei, agenții de mediu și servicii de urgență, pentru transferul cunoștințelor în practică

5.4-5.5. VIZIBILITATE ȘTIINȚIFICĂ ȘI OBIECTIVE PE TERMEN LUNG

Îmbunătățirea vizibilității și a impactului științific, alături de poziționarea pe termen lung ca expert de top în evaluarea riscurilor naturale, încheie structura planului de dezvoltare a carierei.

- Vizibilitate și impact științific (5.4)

creșterea impactului prin publicare în reviste de rang înalt și activitate editorială continuă (consilii editoriale, redactor asociat/invitat)

- Obiective pe termen lung (5.5)

poziționare ca expert de top în evaluarea riscurilor naturale din ingineria civilă, la nivel național și internațional

- Dezvoltare instituțională

contribuție la infrastructura de cercetare și la înființarea de grupuri de cercetare axate pe analiza geospațială a riscurilor de mediu

MULȚUMESC PENTRU ATENȚIE!

CS Dr. Romulus-Dumitru Costache

Institutul Național de Hidrologie și Gospodărire a Apelor (INHGA)

Universitatea Transilvania din Brașov – Facultatea de Construcții

Întrebări și discuții