

Academia Oamenilor de Știință din România



Raport de progres nr. 3 pentru proiectul **Platformă digitală pentru estimarea nivelului de degradare seismică a** **clădirilor utilizând tehnici de machine learning** **DIGITERRA**

Domeniu științific: Științe Geonomice

Cuvinte cheie: cutremur, degradare seismică, digitalizare, machine learning, reziliență

Director de proiect:

Conf. Dr. Ing. Vasile Calofir

Membrii echipei de cercetare:

Lt. Dr. Ing. Munteanu Ruben Iacob

As. Dr. Ing. Mircea Simoiu



Obiectivul general al proiectului este crearea unui cadru digital accesibil, cu adresare largă, atât pentru specialiști, cât și pentru nespecialiști în domeniul construcțiilor, care să faciliteze o înțelegere realistă în ceea ce privește nivelul actual și nivelul așteptat de degradare structurală a clădirilor la incidența unui eveniment seismic.

Obiective specifice

OS1: Realizarea unei rutine în Matlab care să genereze modele numerice pentru diferite tipuri de clădiri și să asocieze acestora accelerograme seismice.

OS2: Alegerea caracteristicilor (features) clădirilor și a accelerogramelor ce sunt considerate a avea un impact semnificativ în deteriorarea structurală a clădirilor și obținerea prin simulare numerică a indicelui global de degradare seismică.

OS3: Proiectarea cu ajutorul algoritmilor de machine learning a unui model de estimare a indicelui de degradare structurală pentru clădiri supuse la acțiuni seismice.

OS4: Dezvoltarea unui instrument digital de tip open-source, implementat în cadrul unei aplicații web, care să realizeze o interfață între utilizator și modelul de estimare a indicelui de degradare.

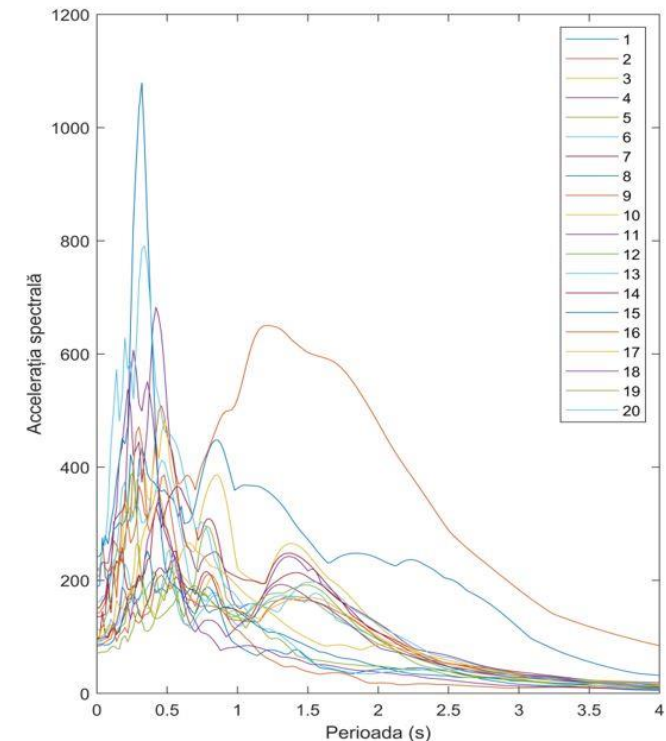
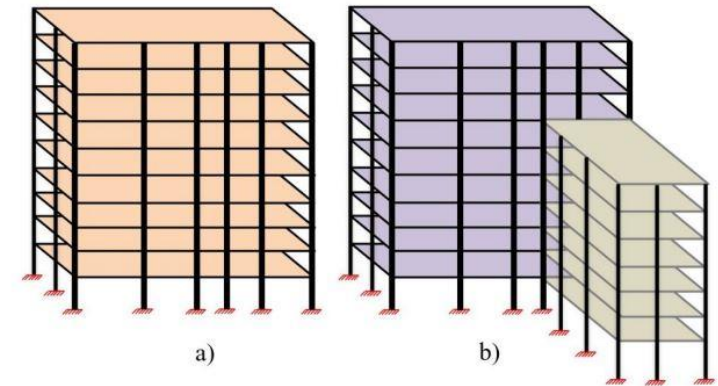



Diagrama Gantt a proiectului

		Diagrama Gantt a proiectului																			
Anul		2023										2024									
Proiect de cercetare AOSR		4	5	6	7	8	9	10	11	12	1	2	3	4	5	6	7	8	9	10	11
Nr.		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
Et.1	<i>Proiectarea structurii de simulare pentru generarea datelor de antrenare, validare și testare a algoritmilor de machine learning</i>																				
Act.1	Stabilirea unei proceduri de generare a tipurilor de clădiri în cadre	✓	✓																		
Act.2	Generarea modelelor matematice pentru fiecare clădire în parte și asocierea accelerogramelor corespunzătoare			✓	✓																
Et.2	<i>Obținerea prin simulare numerică a indicelui de degradare seismică pentru clădirile selectate</i>																				
Act.3	Selectarea principalelor caracteristici ale clădirii și ale seismului cu grad ridicat de impactare a indicelui de degradare					✓															
Act.4	Crearea unui set de date compus din caracteristicile selectate și din indicele de degradare obținut în urma simulărilor						✓	✓													
Et.3	<i>Dezvoltarea unui model de machine learning pentru predicția indicelui de degradare seismică</i>																				
Act.5	Pregătirea și normalizarea datelor în vederea antrenării modelului								✓												
Act.6	Alegerea și antrenarea modelului de învățare automată									✓	✓	✓	✓								
Act.7	Validarea, optimizarea și testarea modelului													✓	✓	✓					
Et.4	<i>Proiectarea și implementarea unei aplicații web care să interfațeze cu utilizatorul modelul de estimare a indicelui de degradare</i>																				
Act.8	Implementarea interfeței web																				
Act.9	Crearea legăturii dintre interfața și modelul ML selectat																				
Act. 10	Testarea aplicației și realizarea documentației																				
A	<i>Activități manageriale și diseminare</i>																				
1	Raport financiar				✓					✓											
2	Raport științific				✓					✓											
3	Diseminarea rezultatelor cercetării în articole internaționale de jurnal și de conferință						✓	✓	✓	✓	✓	✓	✓	✓	✓						

Rezultatele obținute și prezentate în raportul 1 și 2 au fost publicate în jurnalul Results in Engineering de la ELSEVIER având:

Cite score = 5.8 și Impact Factor = 6

Results in Engineering 22 (2024) 102250



Contents lists available at ScienceDirect

Results in Engineering

journal homepage: www.sciencedirect.com/journal/results-in-engineering



Research paper

Innovative approach to estimate structural damage using linear regression and K-nearest neighbors machine learning algorithms



Vasile Calofir^a, Ruben-Iacob Munteanu^a, Mircea-Stefan Simoiu^{a,*}, Karol-Cristian Lemnaru^b

^a Department of Automatic Control and Industrial Informatics, Politehnica University of Bucharest, Bucharest, RO 060042, Romania

^b Department of Electrotechnics and Measurements, Technical University of Cluj-Napoca, Cluj-Napoca, RO 400114, Romania

ARTICLE INFO


Keywords:

Machine learning algorithms
Nonlinear dynamic analysis
Seismic structural damage
Time efficient seismic simulations


ABSTRACT

Conventional structural design methodologies often utilize elastic analysis techniques, such as the equivalent static force method and the response spectrum method. While these methods are known for their simplicity and computational efficiency, they prove inadequate in capturing the extent of structural damage caused by seismic forces. Additionally, employing nonlinear dynamic analysis to estimate structural damage represents a challenging and intricate task, posing difficulties for many structural designers. Consequently, the objective of this paper is to present an innovative methodology for evaluating seismic structural damage of moment-resisting frame structures. This involves the utilization of machine learning algorithms, which have been trained and tested on a large data set generated using a newly developed and numerically efficient simulation procedure. The machine learning algorithms employ both linear regression and K-nearest neighbors approaches to accurately replicate the Park-Ang structural damage index.


Real vs. predicted analysis for the test dataset, using Linear regression and the following features: PGA.of.the_recording_scale.1, PGA.of.the_recording_scale.2, T3, T1, T2, E, MstX, Fund.Freq1




Real vs. predicted analysis for the test dataset, using optimised K Nearest Neighbours and the following features: PGA.of.the_recording_scale.1, PGA.of.the_recording_scale.2, T3, T1, T2, E, MstX, Fund.Freq1



Real vs. predicted analysis for the test dataset, using Linear regression and the following features: Fund.Freq1, Fund.Freq2, PGA.of.the_recording_scale.1, PGA.of.the_recording_scale.2, b.Hieght, dim.x, dim.y, b.st, h.st, b.gr, h.gr, E, MstY, MstX, Mgr, Lshape, bay2, no.span.2, no.bay.2, no.story.2, T1, T2, T3



Real vs. predicted analysis for the test dataset, using optimised K Nearest Neighbours and the following features: Fund.Freq1, Fund.Freq2, PGA.of.the_recording_scale.1, PGA.of.the_recording_scale.2, b.Hieght, dim.x, dim.y, b.st, h.st, b.gr, h.gr, E, MstY, MstX, Mgr, Lshape, bay2, no.span.2, no.bay.2, no.story.2, T1, T2, T3



Implementarea algoritmilor de machine learning

I. Antrenarea modelelor

- ✓ Regresie liniară – *Raport 2*
- ✓ Regresia de tip KNN (K-Nearest Neighbors) – *Raport 2*
- ✓ Regresie liniară regularizată de tipul Ridge Regression și Lasso Regression - *Raport 3*
- ✓ Regresie Elastic Net - *Raport 3*
- ✓ Support Vector Regression (SVR) - *Raport 3*
- ✓ Regresii de tip Random Forest - *Raport 3*
- ✓ Regresia Gradient Boosting - *Raport 3*
- ✓ Rețele Neuronale - *Raport 3*

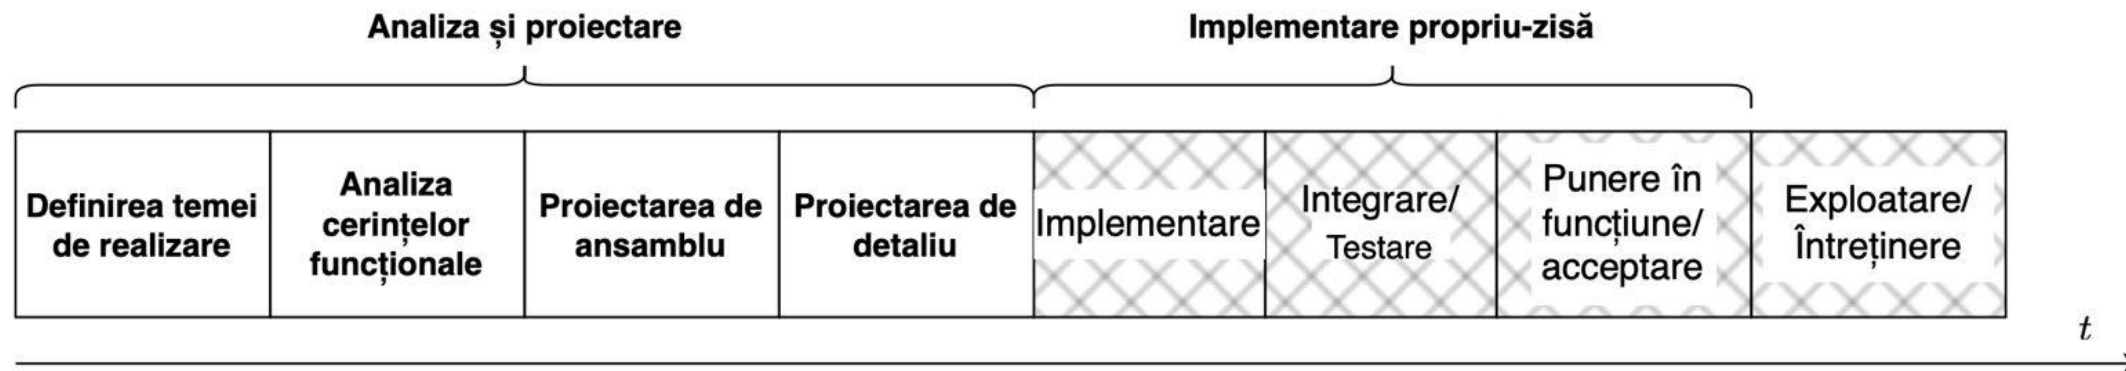
II. Analiza performanțelor pentru fiecare din tipurile de modele alese

- ✓ Mean Absolute Error (MAE)
- ✓ Mean Squared Error (MSE)
- ✓ R-squared

III. Optimizarea modelelor de machine learning prin ajustarea hiperparametrilor, adăugarea sau eliminarea caracteristicilor de intrare (feature selection)

Implementarea platformei web

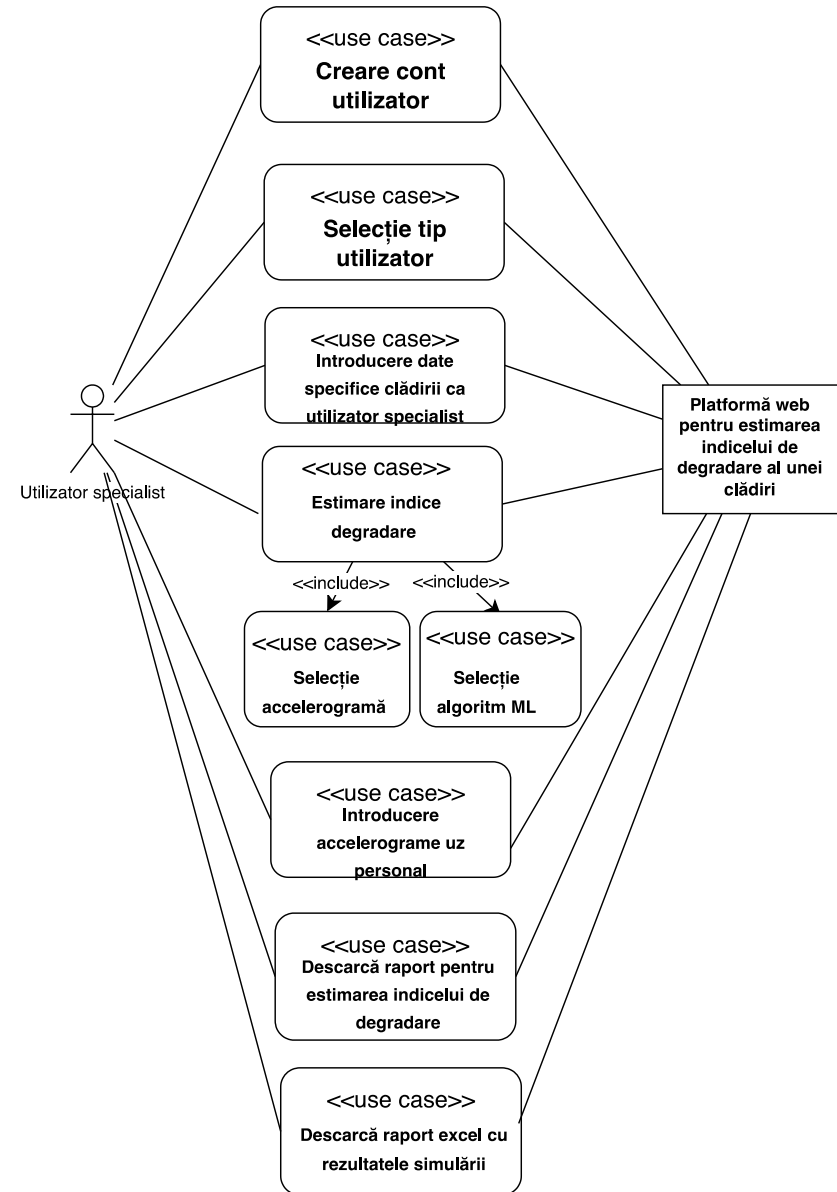
- Pentru implementarea platformei web, prima etapă constă în elaborarea unei analize de sistem
- **Analiza de sistem** – modalitate formală de a determina:
 - Setul de cerințe funcționale
 - Arhitectura
 - Tehnologiile folosite pentru a satisface cerințele
- Utilitate - minimizarea riscului de implementare



Analiza de sistem

Studiu de caz: stabilirea cazurilor de utilizare

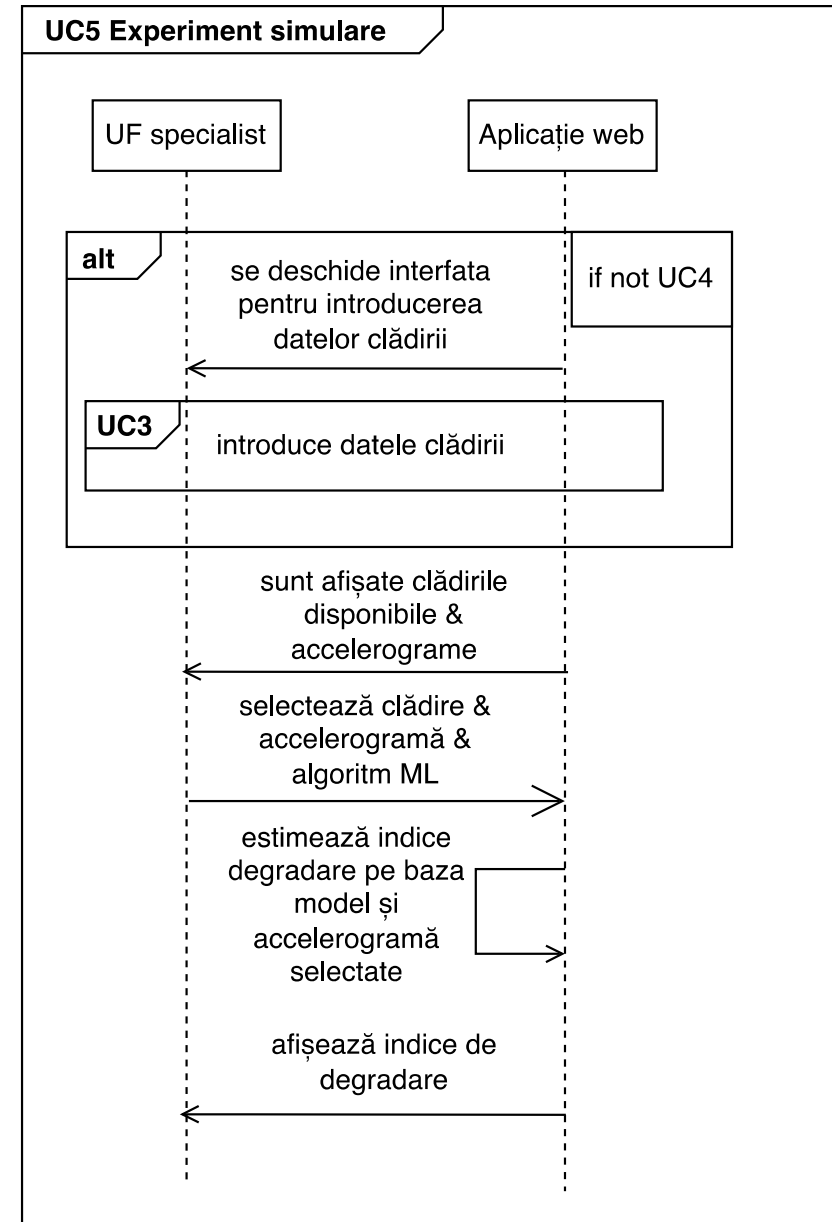
- Caz de utilizare - interacțiune bine definită între utilizator/utilizatori și sistem
- Nu implică o dimensiune temporală
- Reprezentare grafică intuitivă pentru a permite definirea împreună cu utilizatorii finali



Analiza de sistem

Studiu de caz: stabilirea diagramelor secvențiale

- Diagrama secvențială – descriere temporală a unui caz de utilizare
- Interacțiunea este descrisă la nivel principal (fiind o fază incipientă a analizei de sistem)



Următorii pași . . .

Dezvoltarea platformei web de estimare a indicelui de degradare:

- Definirea cerințelor funcționale
- Proiectarea unei arhitecturi
- Implementarea propriu zisă
- Testarea platformei web

Utilizarea algoritmilor de machine learning pentru estimarea indicelui de degradare la clădiri supuse unui tren de accelerograme

- Actualizarea rutinei de simulare pentru estima indicele de degradare după acțiunea a două sau trei cutremure semnificative la care a fost supusă clădirea pe durata de viață
- Antrenarea algoritmilor de machine learning pentru estimarea indicelui de degradare
- Implementarea acestei opțiuni în cadrul aplicației web

VĂ MULȚUMESC PENTRU ATENȚIE!