



Maschinelles Lernen-gestützte Zuverlässigkeitsanalyse von niederschlagsbedingten Hangrutschungen an wurzelverstärkten Hängen

Barbara Maria Świtata¹, Carlotta Guardiani², Enrico Soranzo², Wei Wu²

¹ Institute of Hydro-Engineering, Polish Academy of Sciences, Gdańsk, Poland

² Institut für Geotechnik, Universität für Bodenkultur, Wien

enrico.soranzo@boku.ac.at

Motivation & Ziel

- Niederschlagsbedingte Rutschung weltweit häufig, Vorhersage entscheidend
- Vegetation verstärkt Hänge, inhärente Variabilität meist vernachlässigt
- Versagenswahrscheinlichkeit aus FEM + ML

Numerisches Modell

- Erweiterung von modifiziertem Cam-Clay für ungesättigte, wurzelverstärkte Böden

$$p'_{c,ini} = p'_{c0} e^{[b(1-S_{ini}) + R_p m_r^{ini}]}$$

- In Abaqus als UMAT implementiert
- Idealisierter Hang mit 0,6 m faseriger Wurzelschicht (z. B. Bromus inermis)
- Niederschlagsintensität: 16 mm/h (starker Regen), stufenweise

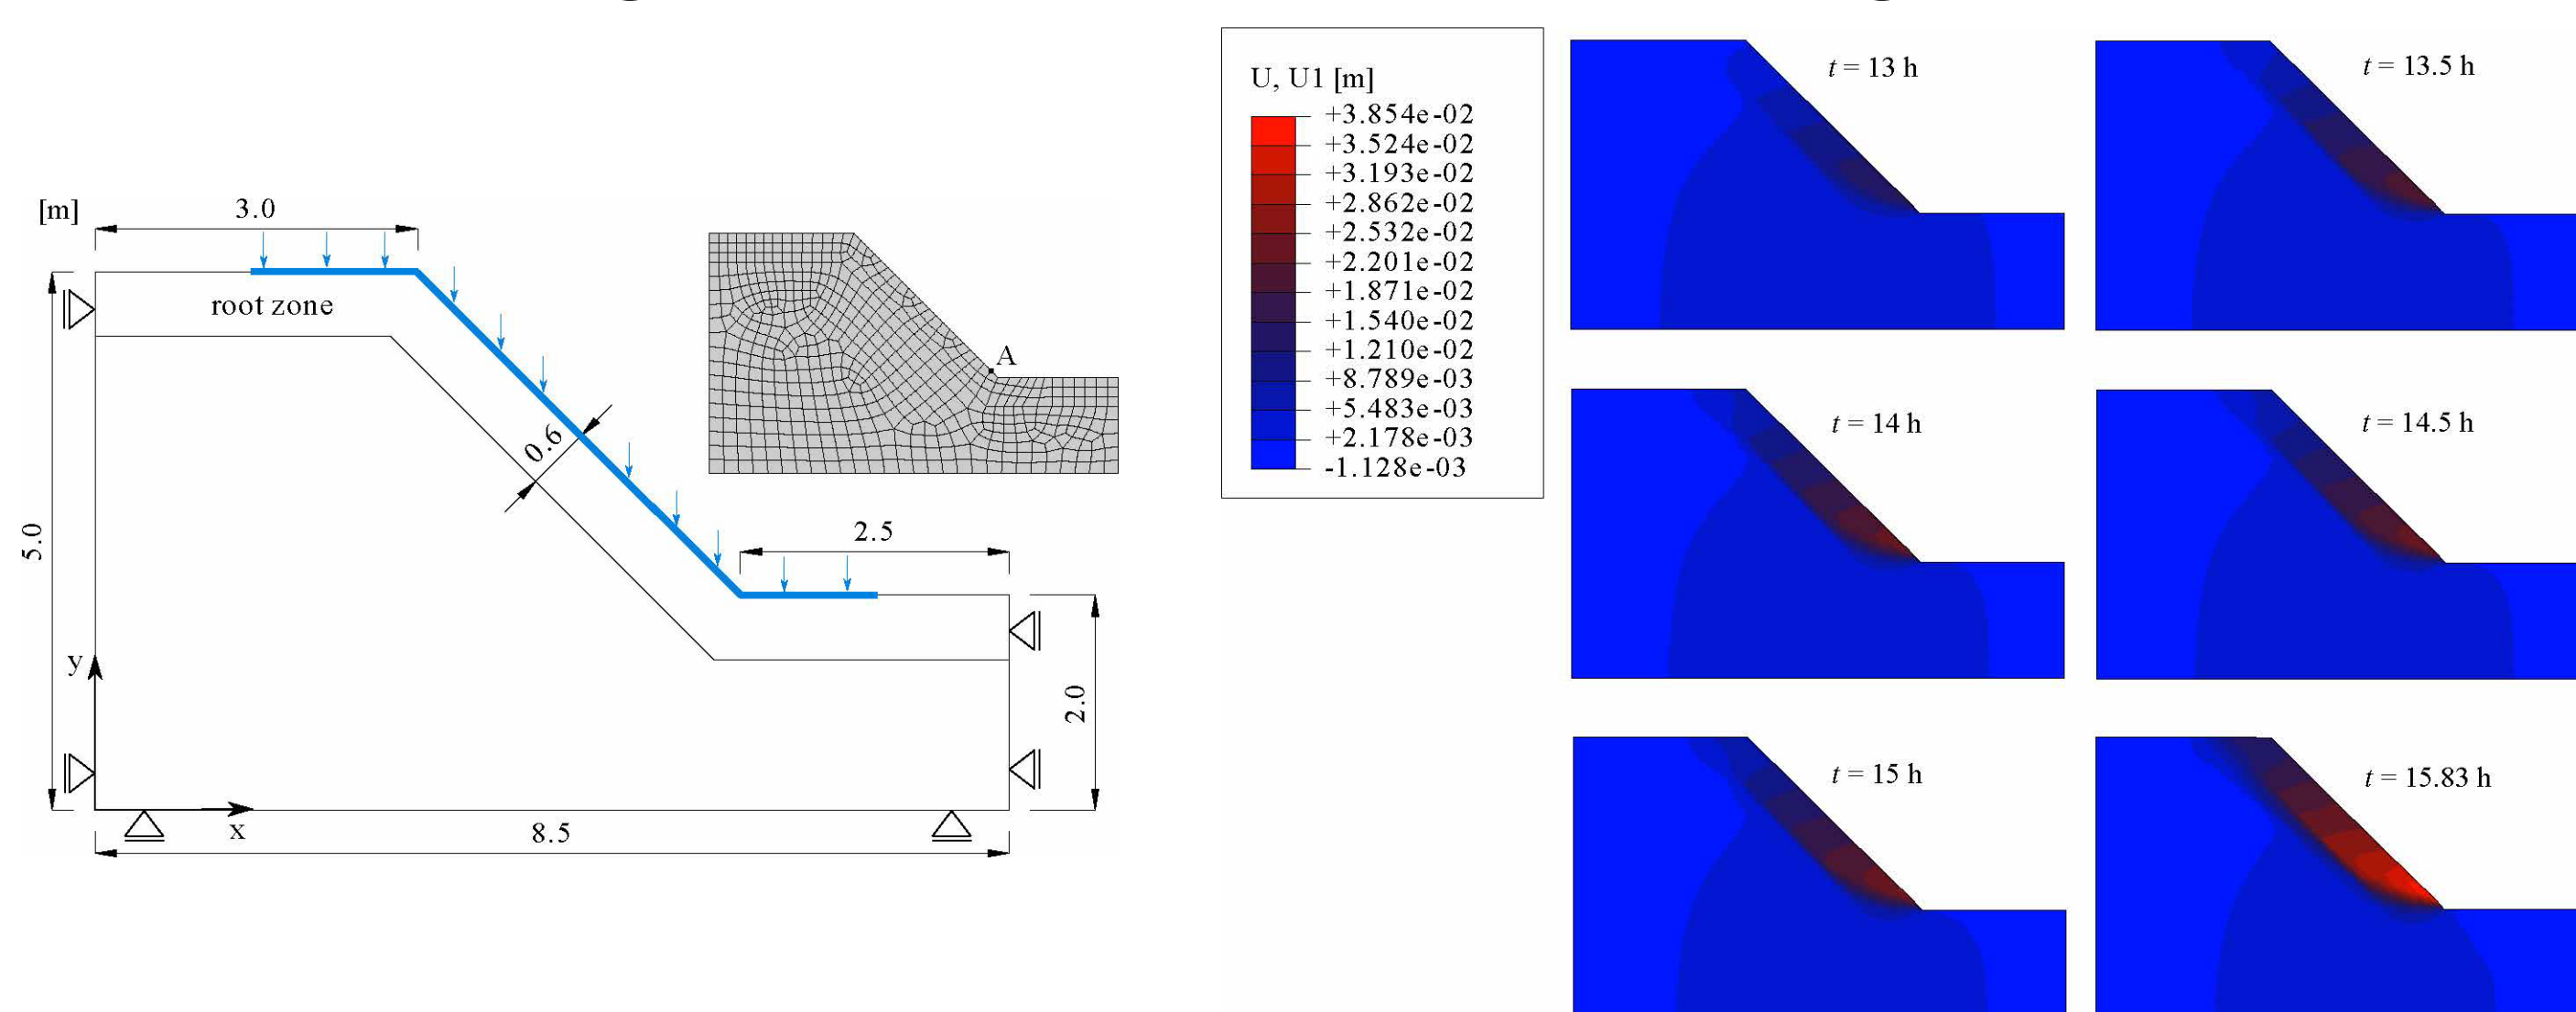


Abbildung 1: Geometrie, Randbedingungen und Diskretisierung des Hanges (links); Zeitverlauf der horizontalen Verschiebung (rechts)

Zuverlässigkeitsanalyse

- Kleine Stichprobe: 1.000 LHS → vollständigen FEM-Simulationen (~4 Minuten jeweils auf Supercomputer)
- Große Stichprobe: 1.000.000 Monte-Carlo → durch Ersatzmodell
- Versagen: horizontale Verschiebung > 0,02H = 0,025 m

Symbol	Unit	Mean value	COV	Correlation	Distribution	Lower bound	Upper bound
R_p	-	2.5	0.3	-	Uniform;Normal	1	4
m_r^{ini}	%	2	0.3	-	Uniform;Normal	0.5	3.5
k_{sa}	m/s	5e-6	0.8	-	Lognormal	4.5e-6	-
a	kPa	0.7	0.2	$\rho_{a,m} = -0.25$	Lognormal	0	1.5
n	-	2.16	0.1	-	Lognormal	1.67	-




Abbildung 2: Vorhersage der horizontalen Verschiebung mit XGBoost für die gleichförmig verteilte Merkmale nach 15 Stunden (links); CDF der Verschiebung: Vergleich Messung und Vorhersage (rechts)

Maschinelles Lernen

- Merkmale: R_p , m_r^{ini} , k_s , a , n
- Kategorien: horizontale Verschiebung bei $t = 13 - 15$ h
- Datenaufteilung: 70% Training / 30% Test
- Hyperparameteroptimierung: 5-fache Kreuzvalidierung + GridSearch
- XGBoost als Ersatzmodell ausgewählt

Algorithm	R^2_{test} for uniformly distributed data					R^2_{test} for normally distributed data				
	13 h	13.5 h	14 h	14.5 h	15 h	13 h	13.5 h	14 h	14.5 h	15 h
Linear regression	0.504	0.473	0.495	0.514	0.524	0.497	0.458	0.521	0.549	0.564
Decision tree	0.915	0.876	0.907	0.920	0.910	0.916	0.892	0.892	0.880	0.937
Random forest	0.967	0.962	0.960	0.966	0.961	0.967	0.974	0.972	0.966	0.975
Extreme gradient boosting	0.976	0.976	0.975	0.978	0.975	0.981	0.980	0.980	0.979	0.982

Ergebnisse

- Versagenswahrscheinlichkeit von 2% auf 22% über Niederschlagsereignis
- Große Stichprobe stabilisiert p_f Schätzung
- Ersatzmodell von FEM-Konvergenzfehlern nicht betroffen

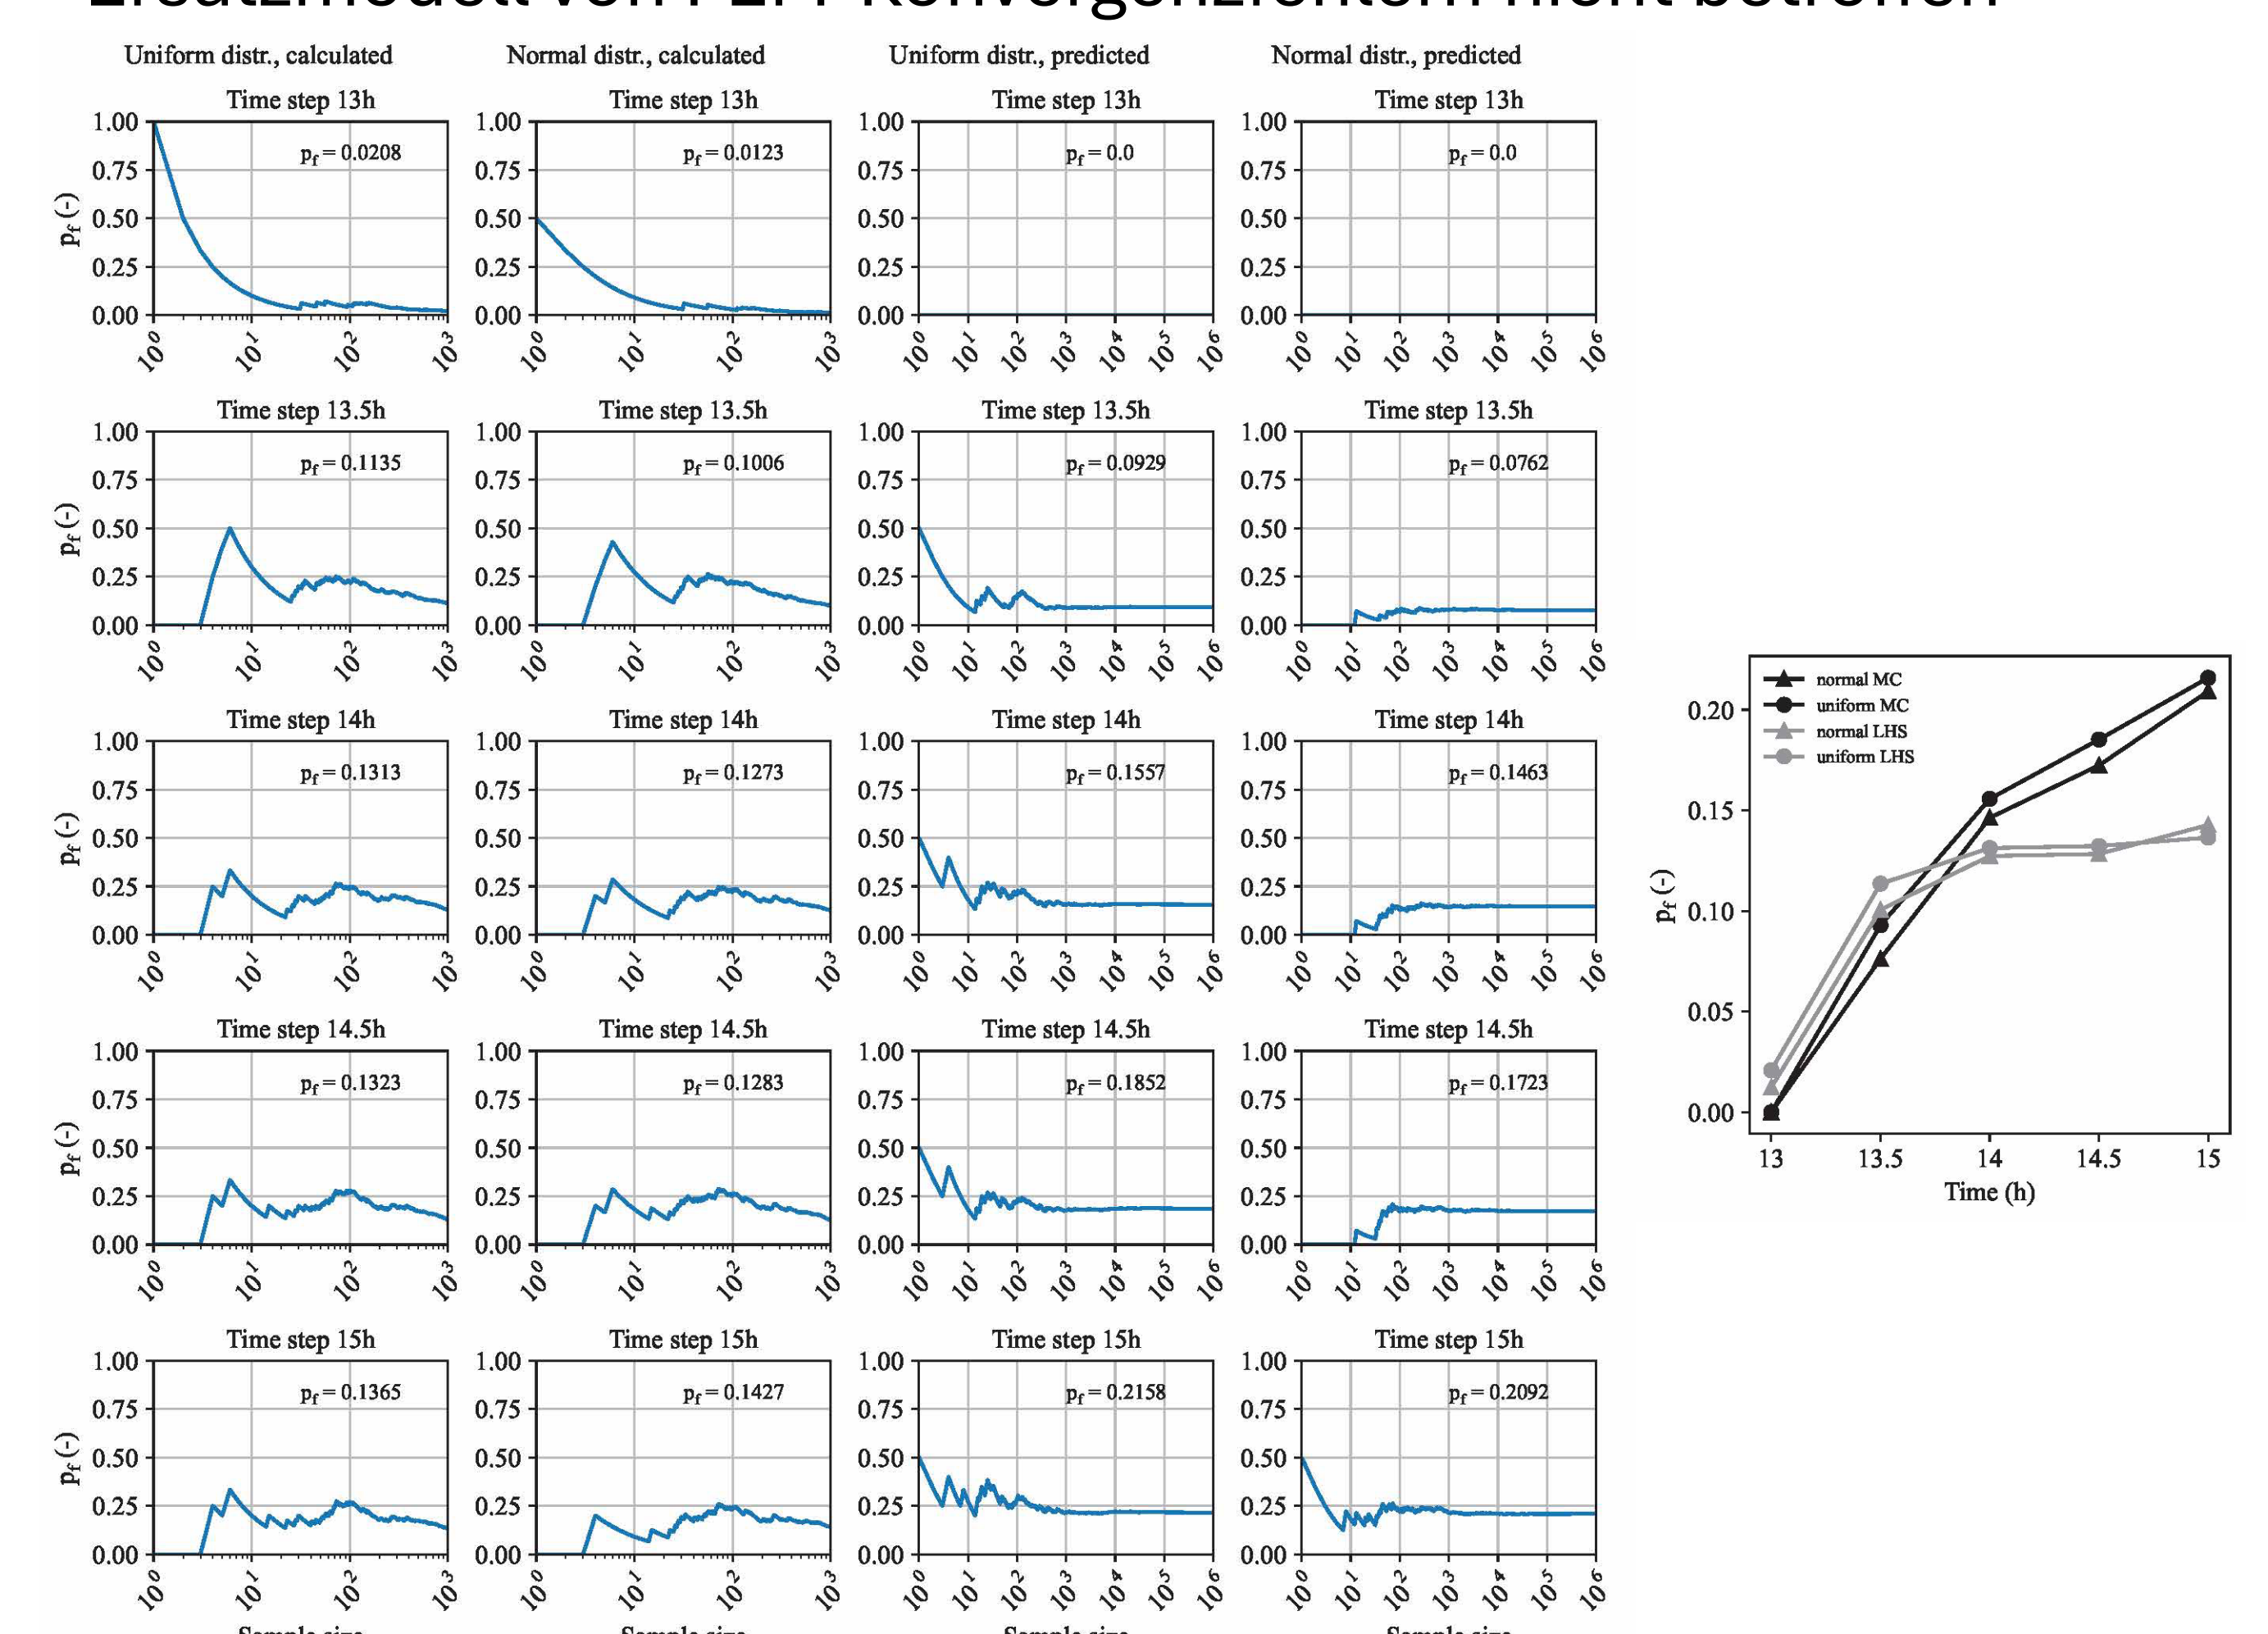


Abbildung 3: Versagenswahrscheinlichkeit aus 1000 numerischen Ergebnissen (1. und 2. Spalte) und Ersatzmodell mit 1.000.000 Ergebnisse (3. und 4. Spalte) (links); Variation der Versagenswahrscheinlichkeit über Zeit mit unterschiedlichen Verteilungen und Datengrößen (rechts)

Schlussfolgerungen und Ausblick

1. ML-Ersatzmodelle effektiv für geotechnische Zuverlässigkeit (XGBoost erreicht $R^2 \geq 0,975$ mit nur 1.000 Trainingsproben)
2. Versagenswahrscheinlichkeit bewachsener Hänge effizient an 1 Million+ Stichproben bei vernachlässigbaren Rechenkosten geschätzt
3. Ergebnisse können Echtzeit-Frühwarnsysteme in Erdbebenregionen informieren