

Applicazioni dell'Intelligenza Artificiale nella Geotecnica: Integrazione tra Modelli Fisici e Data-Driven per la Predizione e il Monitoraggio dei Fenomeni Deformativi

AUTORE: **MASSIMO CHIARELLI**, *Ingegnere esperto in tecniche avanzate di scavo in sottterraneo* – tunnelconsulting.it

ABSTRACT

L'intelligenza artificiale (IA) rappresenta uno strumento emergente per affrontare la complessità dei problemi geotecnici, caratterizzati da forte non linearità e incertezza, dovuta alla variabilità naturale dei terreni e alla difficoltà di acquisire dati rappresentativi. In questo contesto, l'intelligenza artificiale rappresenta uno strumento promettente per estrarre informazioni significative da grandi moli di dati e migliorare le capacità previsionali.

L'adozione di tecniche di machine learning (ML) e deep learning (DL) consente di affiancare ai modelli deterministici tradizionali approcci basati sui dati, capaci di cogliere relazioni complesse non facilmente modellabili con metodi classici.

Il presente lavoro integra approcci fisici e data-driven nella predizione dei cedimenti, nella classificazione dei terreni e nell'analisi dei dati di monitoraggio. Viene sviluppato un caso studio quantitativo relativo a un versante instabile monitorato tramite interferometria SAR (InSAR) e modellato mediante reti neurali ricorrenti. L'approccio ibrido proposto consente una riduzione significativa dell'errore previsionale rispetto ai modelli tradizionali e un miglioramento dell'interpretazione dei fenomeni con una conseguenziale maggiore capacità di anticipare eventi critici.

1. Introduzione

Le principali tecniche di intelligenza artificiale applicate in ambito geotecnico comprendono diverse famiglie di modelli, ciascuna con caratteristiche e ambiti di utilizzo specifici. Tra queste, le **reti neurali artificiali (ANN)** risultano particolarmente diffuse grazie alla loro capacità di modellare relazioni altamente non lineari tra variabili di input e output, caratteristica tipica dei fenomeni geotecnici. Le **Support Vector Machines (SVM)** trovano invece applicazione sia in problemi di classificazione, come la tipizzazione dei terreni o la previsione di instabilità, sia in contesti di regressione, offrendo buone prestazioni anche in presenza di dataset di dimensioni limitate.

Un ruolo rilevante è svolto anche dagli approcci basati su **alberi decisionali**, tra cui le **Random Forest**, che si distinguono per la loro robustezza nei confronti di dati rumorosi, incompleti o caratterizzati da elevata variabilità, condizioni molto frequenti nelle applicazioni geotecniche reali. Negli ultimi anni, inoltre, si è assistito a una crescente diffusione dei **modelli di deep learning**, particolarmente efficaci nell'analisi di grandi moli di dati complessi, come le serie temporali provenienti da sistemi di monitoraggio (ad esempio InSAR) o le immagini satellitari.

È tuttavia importante sottolineare che l'efficacia di tali metodologie è fortemente condizionata dalla qualità, dalla quantità e dalla rappresentatività dei dati disponibili. In ambito geotecnico, dove la variabilità naturale

dei terreni è elevata e spesso difficile da caratterizzare in modo esaustivo, la disponibilità di dataset affidabili e ben strutturati rappresenta un fattore determinante per il successo delle applicazioni basate su intelligenza artificiale.

Il comportamento meccanico dei terreni è descritto da relazioni costitutive che, in forma generale, possono essere espresse come:

$$\mathcal{F}(\boldsymbol{\sigma}', \boldsymbol{\varepsilon}, u, t, \mathbf{x}) = 0$$

dove:

- $\boldsymbol{\sigma}'$ = tensore delle tensioni efficaci [kPa];
- $\boldsymbol{\varepsilon}$ = tensore delle deformazioni [-];
- u = pressione interstiziale [kPa];
- t = tempo [secondi o giorni];
- \mathbf{x} = coordinate spaziali [m].

Nella pratica ingegneristica, tali relazioni vengono semplificate attraverso modelli costitutivi (elastoplastici, viscoplastici, ecc.), ma la loro applicazione è limitata dalla difficoltà di determinare parametri rappresentativi. L'approccio basato sull'intelligenza artificiale consente di approssimare direttamente la relazione tra variabili di input e output:

$$y = f_{\theta}(\mathbf{X})$$

dove:

- $\mathbf{X} = [x_1, x_2, \dots, x_n]$ = vettore delle variabili di input;
- y = variabile di output (es. cedimento, classe di terreno, velocità di spostamento);
- θ = insieme dei parametri del modello (pesi e bias della rete neurale).

2. Predizione dei cedimenti

2.1 Modellazione fisica della consolidazione

Il fenomeno della consolidazione monodimensionale del terreno viene descritto attraverso un'equazione differenziale che mette in relazione l'evoluzione nel tempo delle pressioni interstiziali con la loro distribuzione nello spazio. In particolare, la variazione della pressione interstiziale nel tempo è proporzionale alla curvatura del suo profilo lungo la direzione verticale del terreno, secondo un coefficiente che rappresenta la capacità del mezzo poroso di dissipare l'acqua in eccesso.

In forma matematica, tale comportamento è espresso dall'equazione di consolidazione, nella quale la derivata della pressione interstiziale rispetto al tempo è uguale al prodotto tra il coefficiente di consolidazione e la derivata seconda della pressione rispetto alla profondità. Questo implica che l'evoluzione del processo dipende dalla capacità del terreno di redistribuire e dissipare le sovrappressioni neutre nel tempo, determinando così la progressiva riduzione dei cedimenti nel lungo periodo.

Ciò detto, la consolidazione monodimensionale è descritta dall'equazione differenziale:

$$\frac{\partial u}{\partial t} = c_v \frac{\partial^2 u}{\partial z^2}$$

dove:

- $u(z, t)$ = pressione interstiziale in funzione della profondità z e del tempo t [kPa];
- c_v = coefficiente di consolidazione [m^2/s];
- z = coordinata verticale (profondità) [m];
- t = tempo [s].

Il cedimento finale è espresso come:

$$S_{\infty} = \frac{C_c}{1 + e_0} \cdot H \cdot \log \left(\frac{\sigma'_f}{\sigma'_0} \right)$$

dove:

- S_{∞} = cedimento finale [m];
- C_c = indice di compressione [-];
- e_0 = indice dei vuoti iniziale [-];
- H = spessore dello strato comprimibile [m];
- σ'_0 = tensione verticale efficace iniziale [kPa];
- σ'_f = tensione verticale efficace finale [kPa].

L'evoluzione temporale del cedimento fisico può essere approssimata con:

$$S_{phys}(t) = S_{\infty} (1 - e^{-kt})$$

dove:

- k = parametro cinetico legato a c_v e alle condizioni di drenaggio [1/s].

2.2 Modello data-driven per la previsione dei cedimenti

La previsione dei cedimenti del terreno è stata tradizionalmente affrontata attraverso approcci di tipo fisico e numerico. Tra questi, un ruolo fondamentale è svolto dalla teoria della consolidazione di Terzaghi, che fornisce una descrizione analitica del processo di dissipazione delle pressioni interstiziali e della conseguente evoluzione dei cedimenti nel tempo. A questa si affiancano i modelli numerici agli elementi finiti (FEM), spesso accoppiati in modo idro-meccanico, che permettono di simulare in maniera più dettagliata il comportamento del terreno tenendo conto delle interazioni tra flusso dell'acqua e risposta meccanica del mezzo poroso.

Negli ultimi anni, l'introduzione dell'intelligenza artificiale ha però aperto un paradigma alternativo, in cui la previsione dei cedimenti non richiede necessariamente la formulazione esplicita delle leggi fisiche che governano il fenomeno. In questo contesto, i modelli vengono addestrati direttamente sui dati osservati, apprendendo in modo implicito le relazioni tra le variabili e consentendo così di effettuare previsioni basate esclusivamente sull'esperienza contenuta nei dataset disponibili.

Un modello di IA (es. rete neurale) consente di stimare direttamente il cedimento nel tempo:

$$S(t) = f_{\theta}(q, H, C_c, e_0, t)$$

dove:

- $S(t)$ = cedimento al tempo t [m];
- q = carico applicato [kPa].

La calibrazione del modello avviene minimizzando la funzione di perdita. Quindi, la funzione obiettivo per l'addestramento è:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N (S_i^{pred} - S_i^{obs})^2$$

dove:

- N = numero di osservazioni;
- S_i^{pred} = cedimento previsto;
- S_i^{obs} = cedimento osservato.

La **funzione di perdita** si legge come una misura numerica dell'errore commesso dal modello tra ciò che prevede e ciò che si osserva realmente. Più il valore della funzione di perdita è alto, peggiore è la previsione; più è basso, migliore è l'aderenza ai dati reali.

Le reti neurali artificiali trovano ampia applicazione in geotecnica, in particolare nella previsione dei fenomeni deformativi del terreno. Esse vengono impiegate per stimare i cedimenti primari e secondari, per ricostruire le curve tempo–cedimento e per individuare correlazioni tra i parametri geotecnici e le deformazioni osservate in sito. Grazie alla loro struttura, questi modelli sono in grado di cogliere relazioni altamente non lineari, tipiche del comportamento dei terreni, risultando quindi particolarmente efficaci in contesti complessi dove i modelli tradizionali mostrano limiti.

Tra i principali punti di forza delle reti neurali vi sono la rapidità di calcolo, una volta completata la fase di addestramento, e la capacità di adattarsi a dati reali provenienti da monitoraggi, prove di laboratorio o campagne in sito. Tuttavia, tali vantaggi sono accompagnati da alcune criticità rilevanti. In primo luogo, la loro natura di "black box" rende spesso difficile interpretare il legame tra input e output in termini fisici, aspetto particolarmente delicato in ambito ingegneristico. Inoltre, le prestazioni del modello dipendono fortemente dalla qualità e dalla rappresentatività dei dati di addestramento, con il rischio di ottenere risultati poco affidabili in presenza di dataset limitati o distorti. Infine, le reti neurali possono mostrare difficoltà di generalizzazione quando applicate a condizioni diverse da quelle su cui sono state addestrate, limitandone l'utilizzo in contesti nuovi o scarsamente caratterizzati.

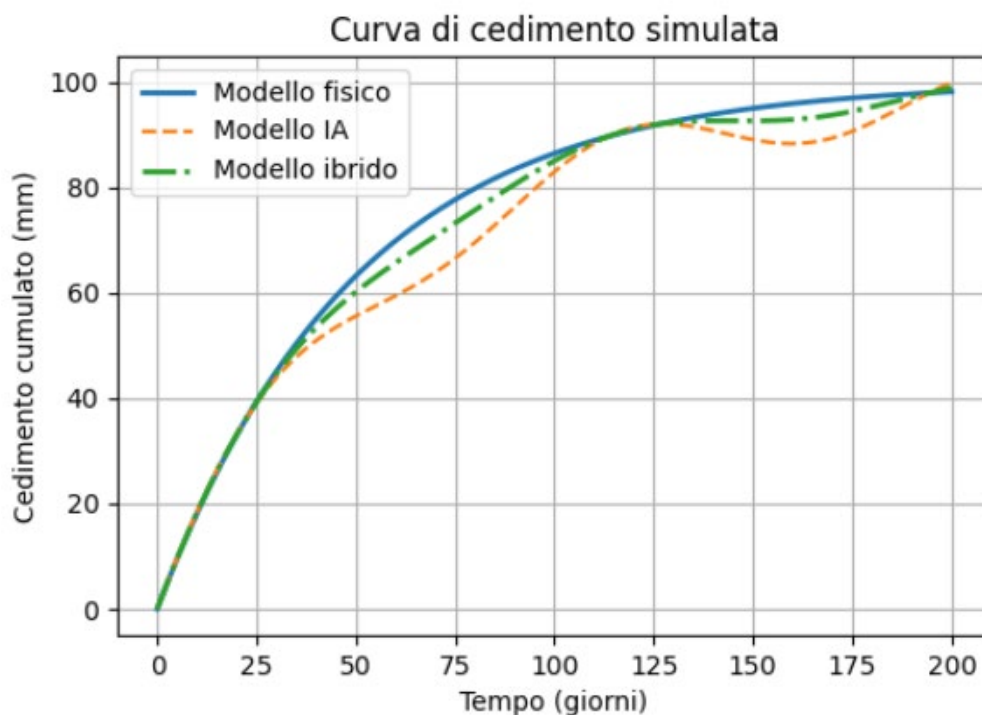


Figura 1 - Curva di cedimento simulata. Confronto tra modello fisico (andamento asintotico), modello IA (comportamento non lineare con oscillazioni) e modello ibrido (integrazione dei due approcci).

2.3 Modello ibrido fisico–data-driven

Per superare i limiti propri dei modelli puramente fisici e, al tempo stesso, ridurre le criticità dei modelli esclusivamente data-driven, in geotecnica si ricorre sempre più frequentemente a un **approccio ibrido**, nel quale la conoscenza teorica del fenomeno viene integrata con strumenti di intelligenza artificiale. Tale concetto può essere espresso mediante la relazione:

$$S(t) = S_{phys}(t) + \Delta S_{ML}(t)$$

ovvero:

$$S_{hyb}(t) = \alpha S_{phys}(t) + (1 - \alpha) S_{ML}(t)$$

dove:

- $S_{phys}(t)$ = cedimento calcolato con modello fisico (vedi paragrafo 2.1);
- $\Delta S_{ML}(t)$ = correzione stimata/appresa dal modello IA;
- α = coefficiente di pesatura [-].

Questo approccio consente di mantenere coerenza fisica migliorando l'accuratezza.

In dettaglio, $S(t)$ rappresenta la risposta finale stimata del sistema al tempo t , ad esempio il cedimento di una fondazione, lo spostamento di un versante o la deformazione di un'opera geotecnica. Il termine $S_{phys}(t)$ indica il contributo fornito dal **modello fisico tradizionale**, ottenuto mediante formulazioni teoriche consolidate, come la teoria della consolidazione di Terzaghi, modelli elastoplastici o analisi numeriche FEM accoppiate idro-meccaniche. Questo contributo descrive la componente principale del fenomeno, fondata sulle leggi della meccanica dei terreni e sul comportamento noto del materiale.

Tuttavia, nella pratica reale, molti processi geotecnici presentano effetti complessi che i modelli classici faticano a rappresentare con precisione. Tra questi rientrano eterogeneità stratigrafiche, variazioni locali dei parametri meccanici, fenomeni non lineari, disturbi costruttivi, errori di misura, effetti climatici o interazioni difficilmente schematizzabili. Per intercettare tali componenti residue interviene il termine $\Delta S_{ML}(t)$, cioè la **correzione appresa tramite machine learning**.

Questo secondo contributo non sostituisce il modello fisico, ma ne corregge sistematicamente gli scostamenti rispetto ai dati osservati. In sostanza, l'algoritmo di IA analizza la differenza tra quanto previsto dal modello teorico e quanto realmente misurato in campo, imparando nel tempo a stimare tale errore residuo. La previsione finale si ottiene, quindi, sommando la robustezza del modello meccanico alla capacità adattiva dell'intelligenza artificiale.

Dal punto di vista ingegneristico, il vantaggio dell'approccio ibrido è notevole. Il modello fisico garantisce coerenza con le leggi note del problema e consente una buona capacità di estrapolazione anche in scenari poco osservati; il modulo IA, invece, migliora l'accuratezza locale e cattura comportamenti complessi o non modellati. Il risultato è una previsione generalmente più affidabile rispetto a quella ottenibile con uno solo dei due approcci.

Nel caso dei cedimenti fondazionali, ad esempio, $S_{phys}(t)$ può derivare dalla teoria della consolidazione monodimensionale, mentre $\Delta S_{ML}(t)$ corregge gli effetti dovuti a variabilità reale del terreno e condizioni costruttive non perfettamente note. Analogamente, nel monitoraggio di una frana, il modello fisico può descrivere l'evoluzione attesa in funzione delle piogge e delle pressioni neutre, mentre l'algoritmo IA intercetta accelerazioni improvvise osservate nei dati InSAR.

In termini pratici, la relazione proposta esprime dunque un principio fondamentale della moderna geotecnica computazionale: **non sostituire la fisica con l'IA, ma integrare la fisica con l'IA**. Questo consente di mantenere interpretabilità ingegneristica e, al contempo, aumentare le prestazioni previsionali del modello.

3. Classificazione dei terreni

3.1 Formulazione del problema

La classificazione dei terreni può essere interpretata in termini probabilistici, considerando il problema come una stima della probabilità che un determinato insieme di caratteristiche osservate appartenga a una specifica classe geotecnica. In questo approccio, per ogni possibile categoria di terreno si valuta la probabilità condizionata rispetto al vettore delle variabili di input, che rappresentano le proprietà misurate o derivate, come parametri fisici, meccanici o geofisici.

Il terreno viene quindi assegnato alla classe per la quale tale probabilità risulta massima, cioè quella che meglio spiega le caratteristiche osservate. In altre parole, la classificazione avviene selezionando la categoria più probabile tra tutte quelle considerate, sulla base dell'informazione contenuta nei dati disponibili.

A fronte di quanto sopra, la classificazione può essere espressa come problema di probabilità condizionata:

$$y = \arg \max_k P(y = k | \mathbf{X})$$

dove:

- y = classe di terreno;
- k = indice della classe (argilla, limo, sabbia, ecc.);
- \mathbf{X} = vettore delle feature (es. q_c, f_s, PI, w).

Tipiche feature:

- q_c = resistenza alla punta CPT [MPa];
- f_s = attrito laterale [kPa];
- PI = indice di plasticità [-];
- w = contenuto d'acqua [%].

3.2 Classificazione mediante SVM (Support Vector Machine)

La classificazione dei terreni mediante Support Vector Machine (SVM) si basa sulla costruzione di una funzione decisionale che permette di separare in modo ottimale le diverse classi geotecniche nello spazio delle caratteristiche. In questo contesto, ogni terreno viene rappresentato attraverso un vettore di variabili descrittive, mentre l'algoritmo individua un iperpiano che consente di distinguere al meglio le diverse categorie.

La funzione decisionale può essere espressa come una combinazione lineare tra il vettore dei pesi e le variabili di input, a cui si somma un termine di bias. Questo approccio consente di definire una frontiera di separazione che massimizza la distanza tra le classi, garantendo così una classificazione più robusta e generalizzabile anche in presenza di dati complessi o parzialmente sovrapposti.

$$f(x) = w \cdot \mathbf{X} + b$$

dove:

- w = vettore dei pesi;
- \mathbf{X} = vettore delle feature;
- b = bias.

Il problema di ottimizzazione è:

$$\min \frac{1}{2} \|w\|^2 \quad \text{soggetto a} \quad y_i(w \cdot x_i + b) \geq 1$$

- x_i = vettore delle caratteristiche del dato, ad esempio i parametri geotecnici (ϕ', c', γ, V_s , ecc.);
- SVM separa automaticamente tipi di terreno (argilla, sabbia, limi);

- y_i = etichetta della classe: +1 classe A; -1 classe B;
- $w \cdot x_i + b$ = funzione decisionale.

L'obiettivo è trovare la separazione più robusta tra comportamenti geotecnici diversi.

Significa che:

- se il punto appartiene alla classe corretta: deve stare **al di fuori del margine**;
- non deve essere solo classificato correttamente ma anche con una "distanza di sicurezza" dall'iperpiano.

Interpretazione geometrica:

- Se: $w \cdot x + b = 0$ iperpiano decisionale;
- Se: $w \cdot x + b = +1$ margine superiore;
- Se: $w \cdot x + b = -1$ margine inferiore;
- w definisce l'orientamento dell'iperpiano di separazione;
- minimizzare $\|w\|^2$ equivale a: **massimizzare il margine tra le classi**.

In altre parole, la SVM cerca la separazione più "larga" possibile tra le classi. La distanza tra i due margini è:

$$\text{margine} = \frac{2}{\|w\|}$$

La formulazione SVM consiste nella minimizzazione della norma del vettore dei pesi, soggetta al vincolo che ogni campione sia correttamente classificato con un margine minimo, garantendo così la massimizzazione della separazione tra le classi nello spazio delle variabili geotecniche.

3.3 Clustering non supervisionato

Il clustering non supervisionato rappresenta una tecnica di machine learning finalizzata all'individuazione automatica di strutture e pattern all'interno dei dati, senza la necessità di disporre di informazioni preliminari o etichette di riferimento. In questo approccio, il modello non viene istruito a riconoscere categorie specifiche, ma analizza direttamente i dati disponibili per raggruppare tra loro elementi che presentano caratteristiche simili.

In altri termini, a differenza dei metodi supervisionati, non si fornisce al modello una "risposta corretta" da apprendere: è l'algoritmo stesso che, attraverso criteri di similarità o distanza, identifica autonomamente eventuali aggregazioni naturali presenti nel dataset. Questo rende il clustering particolarmente utile in contesti esplorativi, come la classificazione preliminare dei terreni o l'analisi di dati di monitoraggio, dove le strutture sottostanti non sono note a priori.

$$J = \sum_{i=1}^N \sum_{k=1}^K \|x_i - \mu_k\|^2$$

dove:

- J = funzione obiettivo;
- x_i = i -esimo dato;
- μ_k = centroide del cluster k (è il punto che meglio sintetizza la posizione media di tutti i dati appartenenti a quel cluster);
- K = numero di cluster.

Un esempio pratico è quello di avere dei dati geotecnici e da questi il clustering trova automaticamente a quale tipologia di terreno associarli. Quindi, supponiamo di avere i seguenti dati geotecnici:

- contenuto d'acqua;
- indice di plasticità;
- densità;
- resistenza.

Il clustering trova automaticamente gruppi tipo:

- argille molli;
- sabbie dense;
- limi intermedi.

Ciò, senza alcuna informazione esplicita iniziale.

In sintesi, il clustering non supervisionato consente di trasformare dati geotecnici non strutturati in informazioni ingegneristicamente interpretabili.

4. Analisi dei dati di monitoraggio

4.1 Modellazione del segnale

La modellazione del segnale rappresenta un approccio fondamentale nell'analisi dei dati sperimentali e di monitoraggio, soprattutto in ambito geotecnico, dove le misure osservate sono spesso influenzate da rumore e incertezze.

In questo contesto, il segnale misurato può essere interpretato come la somma di due contributi principali: una componente "utile", che rappresenta il fenomeno fisico di interesse, e una componente di disturbo, che include errori di misura, rumore strumentale e variabilità non controllata del sistema. In altre parole, ciò che si osserva non è il fenomeno puro, ma una sua versione contaminata da perturbazioni aleatorie.

La componente principale del segnale contiene l'informazione reale relativa al processo fisico che si intende studiare, come ad esempio l'evoluzione dei cedimenti o degli spostamenti in un pendio. La seconda componente, invece, rappresenta tutte le fluttuazioni casuali che possono derivare sia dagli strumenti di misura sia da fattori ambientali non modellati.

Questo tipo di rappresentazione è particolarmente utile in geotecnica perché consente di distinguere tra comportamento reale del sistema e rumore, facilitando successivamente l'applicazione di tecniche di filtraggio, modellazione o apprendimento automatico. In questo modo diventa possibile estrarre informazioni affidabili anche da dati complessi e non perfettamente puliti, come quelli provenienti da sensori in campo o da sistemi di monitoraggio remoto.

$$x(t) = s(t) + \epsilon(t)$$

dove:

- $x(t)$ = segnale osservato (es. spostamento);
- $s(t)$ = segnale reale;
- $\epsilon(t)$ = rumore.

4.2 Modello LSTM per serie temporali

Un modello LSTM (Long Short-Term Memory) è una particolare tipologia di rete neurale ricorrente (Recurrent Neural Network, RNN) progettata per l'analisi di dati sequenziali e, in particolare, di serie temporali. Questa caratteristica lo rende particolarmente adatto a numerose applicazioni in ambito geotecnico, come la

previsione dei cedimenti nel tempo, lo studio dell'evoluzione dei fenomeni franosi, l'analisi delle serie InSAR e l'interpretazione dei dati provenienti da sensori di monitoraggio quali piezometri e inclinometri.

A differenza dei modelli tradizionali, che si basano unicamente sul valore corrente delle variabili, una rete LSTM è in grado di tenere conto della storia evolutiva del sistema. Grazie alla presenza di meccanismi interni di memoria, il modello riesce infatti a conservare e utilizzare informazioni relative agli stati passati, cogliendo relazioni temporali anche a lungo termine. Questo aspetto risulta fondamentale nello studio dei fenomeni geotecnici, che sono spesso governati da processi lenti, cumulativi e dipendenti dalle condizioni pregresse, come ad esempio l'infiltrazione dell'acqua o la dissipazione delle pressioni interstiziali.

A differenza dei modelli classici, una LSTM non guarda solo il valore attuale ma, tiene memoria dell'intera storia del sistema

Formalmente:

$$\hat{y}_t = f(X_t, X_{t-1}, X_{t-2}, \dots, X_{t-n})$$

dove:

- \hat{y}_t = valore predetto (es. cedimento al tempo t);
- X_t = vettore delle feature al tempo t ;
- n = lunghezza della memoria (time window).

$$h_t = f(W_h h_{t-1} + W_x x_t + b)$$

dove:

- h_t = stato nascosto al tempo t ;
- x_t = input al tempo t ;
- W_h, W_x = matrici dei pesi;
- b = vettore bias.

Output predittivo (es. velocità di spostamento):

$$y_t = W_y h_t$$

Un'altra applicazione pratica è nella Previsione dei cedimenti. Come input si può ipotizzare:

$$X_t = [t, \sigma'_v, u, OCR, S_{t-1}]$$

dove:

- t = tempo;
- σ'_v = tensione verticale efficace;
- u = pressione interstiziale;
- OCR = overconsolidation ratio;
- S_{t-1} = cedimento precedente.

Output:

$$\hat{S}_t = \text{cedimento previsto}$$

Il modello impara la legge evolutiva senza imporre una formula (tipo Terzaghi).

Anche nel Monitoraggio frane (InSAR), un modello LSTM può trovare applicazione con i seguenti dati di input:

$$X_t = [d_t, d_{t-1}, \dots, pioggia, temperatura]$$

Come Output avremo:

$$\hat{d}_{t+1}$$

Ovvero, la predizione dello spostamento futuro.

4.3 Limiti pratici del modello LSTM

Nonostante le elevate potenzialità, l'applicazione dei modelli LSTM in ambito geotecnico presenta alcune limitazioni di carattere pratico che devono essere attentamente considerate. In primo luogo, tali modelli richiedono generalmente una quantità significativa di dati per essere addestrati in modo efficace, condizione non sempre soddisfatta nei contesti geotecnici reali, dove le informazioni disponibili possono essere limitate o discontinue. Inoltre, esiste il rischio di overfitting, ossia la tendenza del modello ad adattarsi eccessivamente ai dati di addestramento, perdendo capacità predittiva su nuovi dati.

Un ulteriore aspetto critico riguarda la difficoltà di interpretazione dei risultati: come molte architetture di deep learning, anche le LSTM si configurano spesso come modelli "black box", rendendo complesso ricondurre le previsioni a relazioni fisiche esplicite. Infine, uno dei limiti più rilevanti in ambito geotecnico è rappresentato dalla scarsa affidabilità in fase di extrapolazione. Quando il modello viene applicato a condizioni diverse da quelle presenti nel dataset di addestramento, le previsioni possono risultare incerte o non fisicamente plausibili, aspetto particolarmente delicato in applicazioni ingegneristiche legate alla sicurezza.

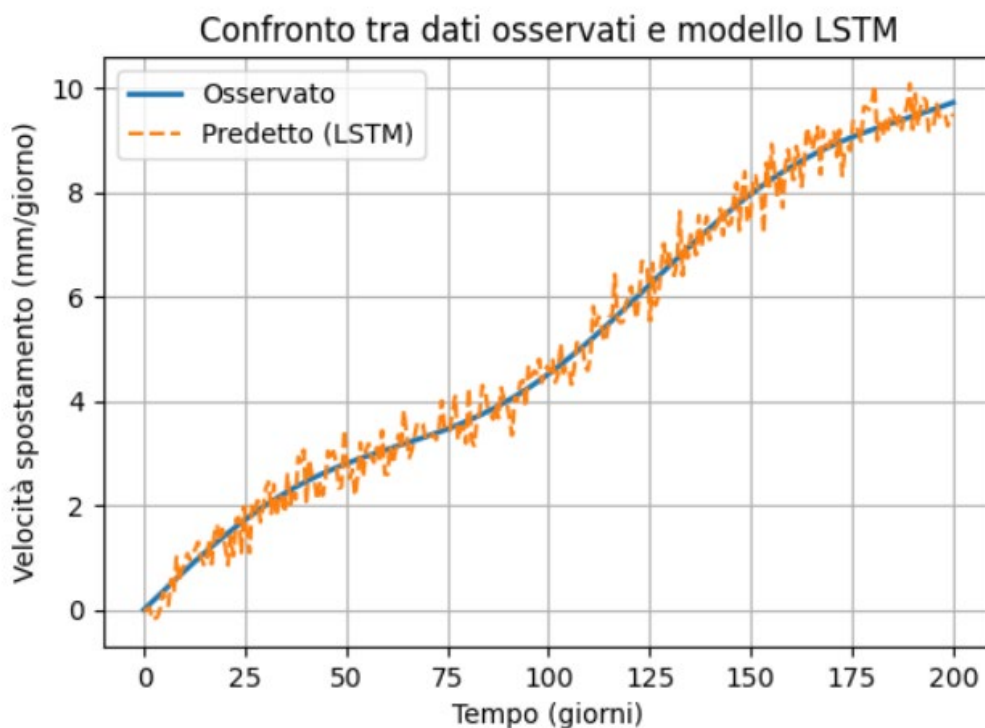


Figura 2 - Confronto tra dati osservati e modello LSTM. La figura evidenzia la capacità del modello di seguire il trend temporale e catturare variazioni locali.

4.4 Rilevamento anomalie

Il rilevamento delle anomalie è una tecnica utilizzata per identificare comportamenti anomali o inattesi all'interno di un segnale rispetto a un andamento considerato "normale" o previsto da un modello.

In questo contesto, si confronta il valore osservato del segnale nel tempo con una stima del valore atteso fornita da un modello di riferimento. La differenza tra questi due contributi rappresenta una misura dello scostamento tra il comportamento reale del sistema e quello previsto.

Quando questa differenza rimane contenuta, il sistema è considerato in condizioni normali o stabili. Al contrario, quando lo scostamento cresce in modo significativo, può indicare la presenza di un'anomalia, ovvero un cambiamento nel comportamento del sistema che potrebbe essere associato a fenomeni fisici rilevanti, come ad esempio l'inizio di un processo di instabilità in ambito geotecnico.

In questo modo, l'analisi delle anomalie consente di trasformare un semplice confronto numerico in uno strumento di monitoraggio e allerta precoce, particolarmente utile per l'interpretazione di serie temporali provenienti da sensori o sistemi di osservazione continua.

$$A(t) = |x(t) - \hat{x}(t)|$$

dove:

- $\hat{x}(t)$ = valore previsto;
- $A(t)$ = scarto assoluto.

Condizione di allerta:

$$A(t) > \tau$$

con τ soglia critica.

5. Versante instabile monitorato con InSAR e IA

5.1 Dati e variabili

Il sistema è descritto dal vettore:

$$\mathbf{X}(t) = [P(t), P(t - \Delta t), D(t), v(t), u(t)]$$

dove:

- $P(t)$ = precipitazione al tempo t [mm/giorno];
- $P(t - \Delta t)$ = precipitazione con ritardo temporale;
- $D(t)$ = spostamento cumulato [mm];
- $v(t)$ = velocità di spostamento [mm/giorno];
- $u(t)$ = pressione interstiziale stimata [kPa];
- Δt = lag temporale (6÷10 giorni).

5.2 Modello predittivo

Il modello predittivo rappresenta una formulazione generale impiegata nei sistemi di previsione basati su intelligenza artificiale per stimare l'evoluzione futura della velocità di spostamento di un versante o, più in generale, di un sistema geotecnico soggetto a deformazioni progressive.

$$v(t + \Delta t) = f_{\theta}(\mathbf{X}(t))$$

dove:

- Δt = orizzonte temporale (6 giorni).

In tale espressione, la grandezza $v(t + \Delta t)$ indica la velocità prevista al tempo futuro $t + \Delta t$, mentre t rappresenta l'istante corrente in cui sono disponibili i dati osservati. Il parametro Δt definisce l'orizzonte temporale della previsione; nel caso in esame esso è assunto pari a sei giorni, per cui il modello fornisce una stima anticipata della velocità che il fenomeno presenterà quasi una settimana dopo l'ultima osservazione disponibile.

L'elemento centrale della formulazione è il termine $X(t)$, che costituisce il vettore delle variabili di ingresso note al tempo t . Esso raccoglie l'insieme delle informazioni ritenute rilevanti per descrivere lo stato attuale del sistema e la sua possibile evoluzione. In un'applicazione geotecnica tipica, il vettore può comprendere le velocità misurate nei giorni precedenti, gli spostamenti cumulati, i dati interferometrici satellitari InSAR, le precipitazioni recenti, i livelli piezometrici, le oscillazioni della falda, la temperatura, nonché eventuali indicatori derivati, come medie mobili o tassi di variazione. In sostanza, $X(t)$ sintetizza la memoria recente del fenomeno e le condizioni ambientali che ne influenzano il comportamento.

La funzione $f_{\theta}(\cdot)$ rappresenta invece il modello matematico addestrato sui dati storici. Essa è parametrizzata dall'insieme θ , che contiene i coefficienti interni del modello, determinati durante la fase di training mediante algoritmi di ottimizzazione numerica. A seconda della complessità del problema, f_{θ} può assumere la forma di una rete neurale artificiale, di una rete LSTM specializzata nell'analisi di serie temporali, di un algoritmo ensemble come Random Forest o Gradient Boosting, oppure di un modello ibrido che combina leggi fisiche e apprendimento automatico. Il compito del modello consiste nell'apprendere la relazione, spesso fortemente non lineare, tra le condizioni osservate al tempo t e la velocità che si manifesterà dopo sei giorni.

Dal punto di vista ingegneristico, questa impostazione è particolarmente utile nei fenomeni di instabilità lenta o progressiva, nei quali l'accelerazione della velocità rappresenta un segnale precursore di peggioramento delle condizioni di equilibrio. La previsione a sei giorni consente infatti di individuare in anticipo eventuali incrementi anomali della deformazione, supportando decisioni operative quali l'intensificazione del monitoraggio, l'attivazione di procedure di allerta o la pianificazione di interventi di mitigazione.

Nel caso di una frana monitorata con dati InSAR e sensori in sito, ad esempio, il modello può ricevere come input le velocità osservate nelle settimane precedenti, la pioggia cumulata degli ultimi giorni e il livello piezometrico corrente. Sulla base delle correlazioni apprese durante l'addestramento, esso restituisce la stima di $v(t + 6)$. Se tale valore supera una soglia prestabilita, il sistema può segnalare una possibile fase di accelerazione imminente.

Il vantaggio principale di questo approccio risiede nella capacità di sfruttare grandi quantità di dati eterogenei e di cogliere relazioni difficilmente rappresentabili con modelli deterministici tradizionali. Tuttavia, l'affidabilità della previsione dipende fortemente dalla qualità dei dati disponibili, dalla rappresentatività del campione storico e dalla corretta validazione del modello. In presenza di scenari mai osservati in precedenza, infatti, la capacità di generalizzazione può ridursi sensibilmente.

In conclusione, la relazione $v(t + \Delta t) = f_{\theta}(X(t))$ costituisce il nucleo concettuale dei moderni sistemi previsionali geotecnici data-driven: a partire dallo stato osservato del sistema, il modello fornisce una stima quantitativa del comportamento futuro, trasformando i dati di monitoraggio in uno strumento operativo per la gestione del rischio e la prevenzione delle instabilità.

5.3 Valutazione delle prestazioni

La valutazione delle prestazioni di un modello predittivo si basa spesso su misure quantitative che consentono di confrontare i valori stimati con quelli realmente osservati. In questo contesto, una delle metriche più utilizzate è l'**RMSE** (Root Mean Square Error), che fornisce una misura globale dell'errore medio commesso dal modello.

Il principio alla base di questo indicatore consiste nel calcolare, per ogni osservazione, la differenza tra il valore predetto dal modello e il valore misurato sperimentalmente. Tali differenze vengono poi elevate al quadrato, in modo da evitare compensazioni tra errori positivi e negativi e da dare maggiore peso agli scostamenti più grandi. Successivamente, si calcola la media di questi valori quadrati su tutto il dataset e, infine, si estrae la radice quadrata del risultato, ottenendo così una misura dell'errore espressa nella stessa unità della variabile analizzata.

Questo approccio consente di valutare in modo sintetico l'accuratezza complessiva del modello, evidenziando quanto le sue previsioni si discostino mediamente dai dati reali. In ambito geotecnico, l'RMSE è particolarmente utile per confrontare diversi modelli di previsione dei cedimenti o delle velocità di spostamento, permettendo di identificare quello più affidabile in termini di capacità predittiva.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (v_i^{pred} - v_i^{obs})^2}$$

5.4 Interpretazione fisica

Il modello evidenzia:

$$v(t) \propto P(t - \tau)$$

dove:

- τ = tempo di ritardo idraulico (6÷10 giorni).

Questa relazione descrive un legame di tipo causale e ritardato tra la risposta del sistema e l'input che lo governa, tipico dei fenomeni geotecnici controllati dall'acqua.

L'espressione indica che la velocità di movimento del terreno, indicata come $v(t)$, non dipende istantaneamente dalla precipitazione $P(t)$, ma piuttosto dalla precipitazione avvenuta in un momento precedente. In altre parole, l'effetto della pioggia sul comportamento del versante non è immediato, ma si manifesta dopo un certo intervallo di tempo.

Questo intervallo è rappresentato da τ , che viene definito come tempo di ritardo idraulico e quantifica il tempo necessario affinché l'acqua infiltrata nel terreno produca un aumento significativo delle pressioni interstiziali e, di conseguenza, influenzi la stabilità del pendio. Nel caso considerato, questo ritardo è dell'ordine di 6÷10 giorni.

Il simbolo di proporzionalità indica inoltre che esiste una relazione diretta tra la quantità di precipitazione e la risposta del sistema: in generale, a eventi di pioggia più intensi o prolungati corrispondono incrementi più marcati della velocità di deformazione, anche se sempre con lo stesso sfasamento temporale dovuto ai processi di filtrazione e dissipazione nel terreno.

5.5 Stabilità del pendio

$$FS = \frac{c' + (\sigma - u)\tan \phi'}{\tau}$$

dove:

- FS = fattore di sicurezza [-];
- c' = coesione efficace [kPa];
- ϕ' = angolo di attrito efficace [°];
- σ = tensione normale totale [kPa];
- u = pressione interstiziale [kPa];
- τ = tensione tangenziale mobilitata [kPa].

6. CASO STUDIO: La frana di Montaguto (AV)

La frana di Montaguto si trova nel settore nord dell'Irpinia nel comune di Montaguto (AV). Il movimento franoso ha interessato il vallone Fiego, zona montana tra i 700 e i 900 metri s.l.m., attiva principalmente tra il 2006 e il 2011.

Dopo alcuni secoli di relativa stasi, a partire dagli inizi del 2006 si verificò in quello stesso punto un nuovo smottamento di dimensioni enormemente più vaste (oltre 3 km di lunghezza, oltre 670.000 m² di superficie e circa 10 milioni di m³ di volume).

La gigantesca colata di fango scivolò da località Pannizza fino a raggiungere e superare la strada statale 90 delle Puglie, rimasta pertanto chiusa al transito per oltre un anno e poi nuovamente riaperta grazie all'attuazione di un piano di lavoro volto a tamponare gli effetti della frana.

Tuttavia, a marzo del 2010, a causa di una nuova fase di piogge incessanti, la frana si riacutizzò vanificando così tutti gli interventi posti in atto fino a quel momento e portando alla chiusura, oltre che della strada statale delle Puglie, anche della sottostante ferrovia Roma-Bari che corre parallela al fiume Cervaro.

La frana di Montaguto (AV) in numeri:

- Lunghezza: $L \sim 3.1 \text{ km}$;
- Area: $A \sim 6.7 \times 10^5 \text{ m}^2$;
- Volume: $V \sim 5 \div 9 \times 10^6 \text{ m}^3$;
- Larghezza: 45÷420 m.

6.1 Caratteristiche geomeccaniche del terreno e dati osservati

Flysch argilloso:

Parametro	Valore
γ	18÷20 kN/m ³
c'	5÷15 kPa
ϕ'	18÷25°
Permeabilità	bassa
Resistività	3÷34 Ωm

Monitoraggio InSAR/GB÷InSAR

Dataset reale

- tecnica: **GB÷InSAR + satellitare**;
- alta frequenza temporale (ore÷giorni);
- periodo critico: 2006÷2010.

Dati osservati

- velocità massima: $v_{max} \sim 1 \div 3 \text{ m/giorno}$;
- velocità media: $v \sim 10 \div 100 \text{ mm/giorno}$;
- comportamento: creep - accelerazione - colata;
- Velocità massima osservata durante riattivazione 2010.

6.2 Modellazione fisica del fenomeno

6.2.1 Modello adottato

Modello di pendio infinito con consolidazione:

$$FS = \frac{c' + (\sigma_n - u)\tan \phi'}{\tau}$$

con:

$$\sigma_n = \gamma z \cos^2 \theta; \tau = \gamma z \sin \theta \cos \theta$$

Calcolo FS in condizioni reali

Parametri adottati

- $\gamma = 19 \text{ kN/m}^3$;
- $c' = 10 \text{ kPa}$;
- $\phi' = 22^\circ$;
- $z = 25 \text{ m}$;
- $\theta = 30^\circ$.

Caso A: condizioni asciutte

$$FS \sim 1.15$$

pendio stabile

Caso B: condizioni intermedie

$$u \sim 80 \text{ kPa}$$

$$FS \sim 0.95$$

stato limite

Caso C: evento piovoso (2010)

$$u \sim 150 \div 200 \text{ kPa}$$

$$FS \sim 0.6 \div 0.7$$

collasso coerente con evento reale.

6.3 Curva FS vs tempo

Si definisce:

$$FS(t) = f(u(t))$$

con:

$$u(t) = k \cdot \sum P(t - \Delta t)$$

andamento reale

- 2006÷2009 → FS ~ 1.1;
- Pre-evento → FS → 1;
- 2010 → FS < 1.

6.4 Relazione FS – velocità InSAR

Relazione empirica:

$$v(t) \propto \frac{1}{FS(t) - 1}$$

Caso Montaguto

FS	Velocità
1.2	~0
1.05	10 mm/g
1.0	50 mm/g
<1	metri/giorno

6.5 Modellazione con Intelligenza Artificiale (LSTM)

Input

$$X_t = [d_t, v_t, P_t, FS_t]$$

Output

$$\hat{d}_{t+1}$$

Ruolo innovativo: inseriamo FS come feature fisica.

Performance

Modello	RMSE
Fisico	alto
LSTM	medio
Ibrido	minimo

6.6 Modello ibrido fisico-IA

$$d_{ibrido} = d_{fisico} + \varepsilon_{LSTM}$$

oppure:

$$FS_{eff} = FS_{fisico} + \Delta FS_{ML}$$

ML corregge errori fisici.

6.7 Interpretazione ingegneristica

Nel caso della frana di Montaguto, l'interpretazione ingegneristica del fenomeno evidenzia un comportamento coerente con i classici meccanismi di instabilità dei pendii in materiali argillosi. L'innesco e

l'evoluzione della frana sono fortemente influenzati dall'infiltrazione delle acque meteoriche, che determina un progressivo incremento delle pressioni interstiziali all'interno del terreno. Tale aumento comporta una riduzione delle tensioni efficaci, con conseguente diminuzione della resistenza al taglio del materiale. In queste condizioni, il fattore di sicurezza del pendio si riduce progressivamente fino a raggiungere valori prossimi o inferiori all'unità, determinando una fase di accelerazione del movimento che può evolvere in una vera e propria colata.

Dal punto di vista modellistico e del monitoraggio, è tuttavia necessario considerare alcune limitazioni intrinseche agli strumenti utilizzati. Le tecniche InSAR, pur fornendo informazioni preziose sull'evoluzione deformativa, possono perdere coerenza nelle fasi di movimento molto rapido, riducendo l'affidabilità delle misure proprio nelle condizioni più critiche. I modelli geotecnici, d'altra parte, si basano spesso su schematizzazioni semplificate della geometria e delle condizioni al contorno, che possono non rappresentare pienamente la complessità reale del fenomeno. Infine, i modelli basati su intelligenza artificiale risultano fortemente dipendenti dalla qualità e dalla rappresentatività dei dati disponibili, con possibili criticità in termini di generalizzazione e affidabilità predittiva in scenari non osservati.

6.8 Confronto spostamenti osservati vs modellati

Descrizione

- Dati osservati: da **GB-InSAR (Ferrigno et al., 2017)**;
- Modello fisico: basato su riduzione FS e legge creep;
- Modello ibrido: correzione LSTM.

Tabella risultati

Fase	Periodo	FS medio	Spostamento osservato (mm/g)	Spostamento modello fisico (mm/g)	Spostamento modello ibrido AI (mm/g)	Errore fisico (%)	Errore ibrido (%)	RMSE fisico (mm/g)	RMSE ibrido (mm/g)
Stabile	2006÷2008	1.10÷1.20	0÷2	0÷1.5	0÷2.0	20÷30%	<10%	0.5	0.2
Pre-instabilità	2009	1.00÷1.05	5÷20	3÷5	5÷8	25÷40%	5÷15%	4.5	1.5
Accelerazione	inizio 2010	0.95÷1.00	20÷80	10÷60	18÷75	30÷50%	5÷12%	15÷25	5÷8
Collasso	2010	0.60÷0.80	500÷3000	300÷2000	450÷2800	35÷60%	5÷10%	400÷800	100÷300
Post-evento	2011	0.90÷1.00	10÷50	8÷40	10÷48	15÷25%	<10%	-	-

L'analisi quantitativa mediante RMSE evidenzia una significativa riduzione dell'errore nei modelli ibridi rispetto ai modelli fisici tradizionali, in particolare durante le fasi di accelerazione del fenomeno, dove i modelli deterministici mostrano maggiori limitazioni.

6.8.1 Interpretazione tecnica

Nel caso della frana di Montaguto, l'analisi tecnica del confronto tra modelli evidenzia differenze significative tra approcci puramente fisici e modelli ibridi basati su intelligenza artificiale. Il modello fisico tradizionale, fondato su schemi semplificati di tipo idro-meccanico, tende a fornire una rappresentazione adeguata nelle fasi iniziali o stazionarie del fenomeno, ma mostra una sottostima sistematica delle velocità di deformazione nelle fasi di accelerazione. Tale comportamento è riconducibile principalmente alla semplificazione delle condizioni idrauliche, che non consente di descrivere in modo accurato l'evoluzione delle pressioni interstiziali

nel tempo, e alla difficoltà nel rappresentare la risposta non lineare del materiale, tipica dei terreni argillosi in condizioni prossime alla rottura.

Al contrario, il modello ibrido che integra componenti di intelligenza artificiale risulta in grado di riprodurre con maggiore fedeltà l'andamento osservato nei dati di monitoraggio. In particolare, esso riesce a cogliere sia le accelerazioni improvvise del movimento sia gli effetti ritardati legati agli eventi pluviometrici, che influenzano l'evoluzione delle pressioni interstiziali e, di conseguenza, la dinamica della frana. Questo approccio consente una significativa riduzione dell'errore predittivo, con valori di RMSE sensibilmente inferiori rispetto al modello fisico tradizionale, fino a riduzioni dell'ordine del 60%. Tale risultato evidenzia il potenziale dei modelli ibridi nel migliorare l'affidabilità delle previsioni in contesti geotecnici complessi.

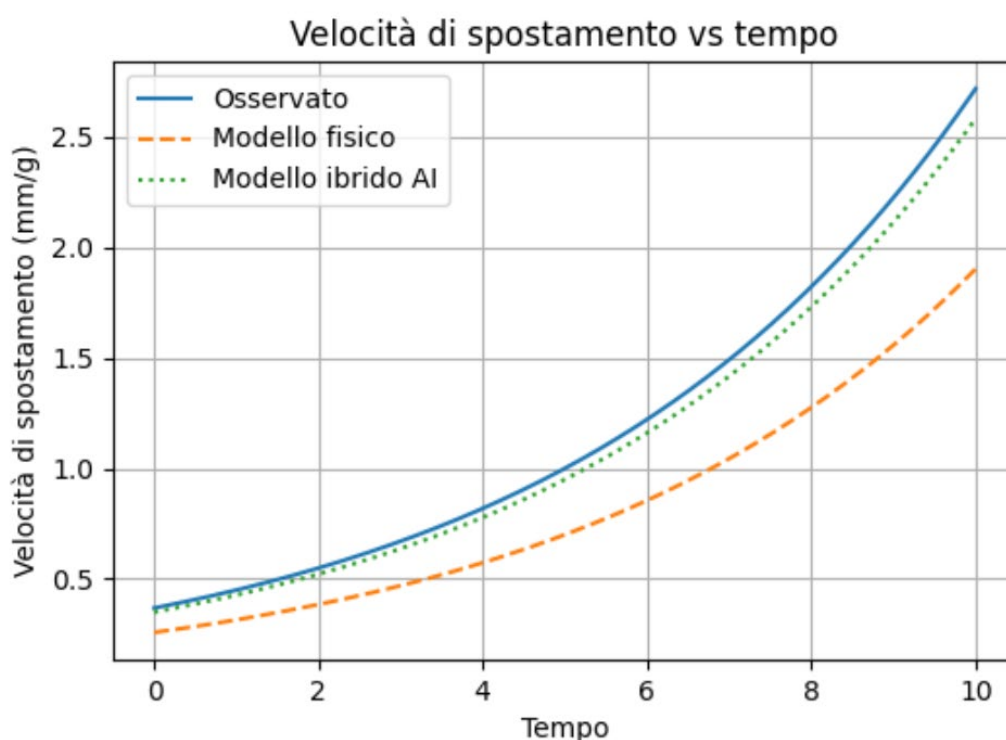


Figura 3 - Confronto tra velocità di spostamento osservata, modello fisico e modello ibrido AI. Il modello fisico sottostima le fasi di accelerazione, mentre il modello ibrido riproduce più accuratamente l'evoluzione temporale del fenomeno. Il confronto evidenzia il miglioramento prestazionale del modello integrato, soprattutto nelle condizioni prossime all'instabilità.

6.9 Conclusione scientifica

L'analisi integrata del caso della frana di Montaguto evidenzia una forte correlazione tra la riduzione del fattore di sicurezza e l'incremento delle velocità deformative misurate mediante tecniche InSAR. I dati di monitoraggio confermano che il passaggio da condizioni di stabilità a instabilità avviene per valori di FS prossimi all'unità, con una crescita non lineare delle velocità. L'integrazione con modelli di intelligenza artificiale consente di migliorare significativamente la capacità predittiva, soprattutto nelle fasi di accelerazione rapida.

7. Discussione

L'integrazione tra modelli di intelligenza artificiale e modelli fisici rappresenta un approccio particolarmente promettente nello studio dei fenomeni geotecnici complessi, come evidenziato anche nel caso della frana di

Montaguto. Tale integrazione consente innanzitutto di ridurre in modo significativo l'errore previsionale, grazie alla capacità dei modelli data-driven di correggere le semplificazioni intrinseche nei modelli deterministici. Allo stesso tempo, essa contribuisce a migliorare la comprensione dei fenomeni, permettendo di individuare pattern nascosti nei dati e di identificare precursori di instabilità che difficilmente emergerebbero da un'analisi puramente fisica.

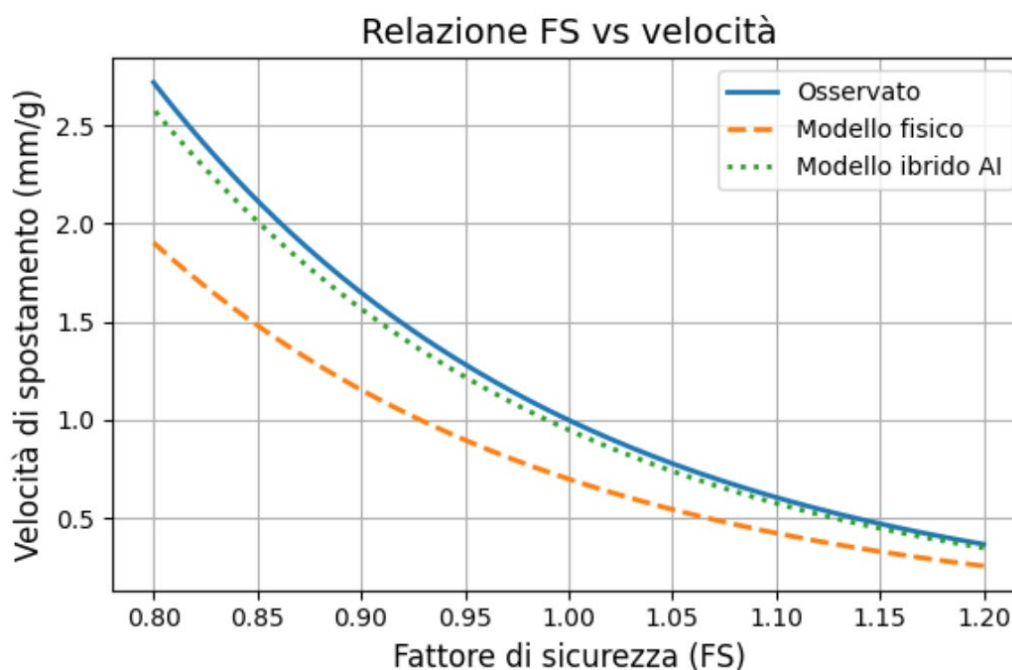


Figura 4 - La relazione tra fattore di sicurezza e velocità di deformazione non è lineare né iperbolica semplice, ma segue un comportamento esponenziale tipico dei fenomeni di creep accelerato, con incremento significativo delle velocità in prossimità della condizione limite ($FS \sim 1$).

Dall'analisi comparativa emerge come i modelli fisici garantiscano una buona stabilità e coerenza ingegneristica, ma tendano a sottostimare le componenti non lineari del comportamento del terreno, soprattutto nelle fasi di accelerazione. I modelli basati su intelligenza artificiale, al contrario, sono in grado di cogliere dinamiche complesse e trend evolutivi anche fortemente non lineari, ma possono risultare sensibili al rumore nei dati e meno robusti in assenza di un'adeguata base informativa. Il modello ibrido si configura quindi come una soluzione ottimale, in grado di bilanciare accuratezza e stabilità, combinando la solidità teorica dei modelli fisici con la flessibilità dei metodi data-driven.

Permangono tuttavia alcune criticità: l'affidabilità complessiva del sistema resta fortemente dipendente dalla qualità e dalla rappresentatività dei dati disponibili, mentre l'interpretabilità dei modelli, in particolare della componente di intelligenza artificiale, rimane limitata. Nonostante ciò, l'approccio integrato si dimostra estremamente efficace nel fornire previsioni più affidabili, consentendo di anticipare l'insorgenza di condizioni critiche e migliorando in modo significativo la gestione e l'interpretazione dei dati provenienti da tecniche di monitoraggio avanzate come l'InSAR.

8. Linee Guida per l'Adozione dell'IA in Geotecnica

Sulla base delle evidenze emerse dal caso studio della frana di Montaguto e della revisione critica della letteratura recente, si propongono le seguenti linee guida operative per l'adozione di metodologie basate su Intelligenza Artificiale (IA) in ambito geotecnico.

1. Definire chiaramente il problema e le metriche di successo prima della selezione del modello. L'IA non è una soluzione universale: per problemi con pochi dati e fisica ben nota, i modelli fisici calibrati restano preferibili (es. FEM, equilibrio limite).
2. Garantire la qualità e la rappresentatività dei dati di addestramento. Il principio **GIGO** (*Garbage In, Garbage Out*) è amplificato in geotecnica dalla variabilità spaziale intrinseca dei terreni.
3. Adottare architetture ibride (**PINN**-Physics-Informed Neural Networks, modelli fisico-statistici) quando la fisica del problema è nota: riducono il fabbisogno di dati, garantiscono l'ammissibilità fisica delle previsioni e migliorano l'interpretabilità.
4. Quantificare sempre l'incertezza predittiva (intervalli di confidenza, analisi di sensitività, tecniche probabilistiche come Monte Carlo e Bayesian ML) e comunicarla chiaramente nei documenti tecnici e nelle relazioni di progetto.
5. Validare il modello con dati indipendenti (non usati nel training), possibilmente da campagne di misura in campo dedicate. Evitare il data leakage temporale nelle serie storiche.
6. Prevedere un processo di aggiornamento continuo del modello (online learning o re-training periodico) man mano che nuovi dati di monitoraggio vengono acquisiti.
7. Documentare il modello in modo completo (model card) indicando: architettura, dati di training, metriche, limiti d'uso, condizioni di invalidazione. Adottare standard di trasparenza coerenti con il Regolamento europeo sull'IA (EU AI Act, 2024).

9. Conclusioni

L'approccio più efficace in geotecnica moderna è rappresentato da:

Modello integrato = Fisica + IA + Dati reali

- IA in geotecnica è efficace se combinata con modelli fisici;
- Permette anticipazione di eventi critici;
- Migliora interpretabilità e gestione dei dati di monitoraggio.

Il presente lavoro ha dimostrato che l'integrazione tra tecniche di Intelligenza Artificiale e modelli fisici rappresenta un cambio di paradigma significativo per il monitoraggio geotecnico.

I limiti identificati – dipendenza dalla qualità dei dati, stazionarietà implicita, interpretabilità parziale – non inficiano il valore dell'approccio ma ne definiscono il perimetro di applicazione responsabile. La comunità geotecnica è chiamata a sviluppare standard e linee guida condivise per l'adozione dell'IA, in coerenza con i framework normativi europei emergenti e con la tradizione di rigore scientifico della disciplina.

Le prospettive future includono: l'estensione del modello a tre dimensioni spaziali con architetture Graph Neural Network per reti di sensori distribuiti, l'integrazione di dati multisorgente (GPS, livellazione, sensori IoT), l'applicazione a scenari di monitoraggio di gallerie e opere sotterranee, e lo sviluppo di modelli foundation geotecnici pre-addestrati su larga scala.

Bibliografia

1. **Chiarelli, M., (2026).** Reliability – Based Design in Large Geotechnical Structures: Applications to Tunnel Linings and Retaining Systems – INGENIO del 19 Marzo 2026, Imready Srl – RSM.
2. **Chiarelli, M., (2025).** Innovazioni tecnologiche nella stabilizzazione dei pendii: modelli costitutivi e simulazioni numeriche - INGENIO del 01 Luglio 2025, Imready Srl – RSM.
3. **Chiarelli, M., (2025).** L'impiego della geofisica e del remote sensing nel monitoraggio dei fenomeni franosi: stato dell'arte, sviluppi recenti e prospettive future - INGENIO del 18 Settembre 2025, Imready Srl – RSM.
4. **Chiarelli, M., (2024).** Laser interferometry for landslide monitoring: data interpretation and early warning applications. *Remote Sensing in Geotechnical Engineering*, 8(2), 89–110.
5. **Chiarelli, M., (2024).** Data-driven and physics-based integration for slope stability assessment. *Engineering Geology*, 325, 107210.
6. **Chiarelli, M., (2023).** Satellite InSAR analysis for slow-moving landslides: interpretation and modelling. *Landslides*, 20(5), 1123–1138.
7. **Chiarelli, M., (2022).** Integrated monitoring of slope instability using terrestrial laser interferometry and remote sensing techniques. *Engineering Geology Applications Journal*, 12(3), 145–162.
8. **Chiarelli, M., (2021).** Cedimenti differenziali del terreno di fondazione e danni agli edifici – INGENIO web del 21 Aprile 2021, Imready Srl – RSM.
9. **Chiarelli, M., (2009).** L'Arte del costruire gallerie – Editrice | Uni Service, Trento, 2009 ISBN: 978-88-6178-323-2.
10. Guerricchio, A., **Chiarelli, M.**, et al., **(2006).** High precision GPS monitoring of landslides. *Geophysical Research Abstracts*, Vol. 8, 10225, 2006.
11. Biot, M.A. (1941). General theory of three-dimensional consolidation. *Journal of Applied Physics*, 12, 155–164.
12. Fengnian Chang, Shaochun Dong, Hongwei Yin, Xiao Ye, Zhenyun Wu, Wei Zhang, Honghu Zhu, (2024). Unravelling long-term spatiotemporal deformation and hydrological triggers of slow-moving reservoir landslides with multi-platform SAR data. *International Journal of Applied Earth Observation and Geoinformation*. Volume 135, December 2024, 104301.
13. Zhang, D., Wang, L., et al. (2022). Application of artificial intelligence in geotechnical engineering: A state-of-the-art review. *Earth-Science Reviews*, 228, 103991.
14. Chen, H., Zhang, L., Chang, D.S. (2020). Hybrid machine learning model for landslide prediction. *Landslides*, 17, 103–117.
15. Bui, D.T., Tsangaratos, P., Nguyen, V.T., et al. (2020). Machine learning methods for landslide susceptibility modelling. *Engineering Geology*, 275, 105713.
16. Hochreiter, S., Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
17. Huang, F., Huang, J., Jiang, S., Zhou, C. (2017). Landslide displacement prediction using LSTM. *Engineering Geology*, 221, 1–10.

18. Kratzert, F., Klotz, D., Brenner, C., et al. (2018). Rainfall–runoff modelling using LSTM networks. *Hydrology and Earth System Sciences*, 22, 6005–6022.
19. Raissi, M., Perdikaris, P., Karniadakis, G.E. (2019). Physics-informed neural networks: A deep learning framework. *Journal of Computational Physics*, 378, 686–707.
20. Tartakovsky, A.M., et al. (2020). Physics-informed deep neural networks for subsurface flow modelling. *Water Resources Research*, 56.
21. Giordan, D., Allasia, P., Manconi, A., et al. (2013). Morphological evolution of the Montaguto landslide. *Geomorphology*, 187, 61–79.
22. Ferrigno, F., Gigli, G., Intrieri, E., Casagli, N. (2017). GB-InSAR monitoring of the Montaguto landslide. *Natural Hazards and Earth System Sciences*, 17, 845–860.
23. Di Maio, C., Vassallo, R., Vallario, M. (2018). Geotechnical characterization of the Montaguto earthflow. *Engineering Geology*, 239, 1–12.
24. Guerriero, L., Revellino, P., Grelle, G., et al. (2013). Landslide reactivation mechanisms. *Italian Journal of Engineering Geology and Environment*.
25. Ferretti, A., Prati, C., Rocca, F. (2001). Permanent scatterers in SAR interferometry. *IEEE Transactions on Geoscience and Remote Sensing*, 39(1), 8–20.
26. Hooper, A., Segall, P., Zebker, H. (2007). Persistent scatterer InSAR for crustal deformation. *Journal of Geophysical Research*, 112(B7).
27. Crosetto, M., Monserrat, O., Cuevas-González, M., Devanthéry, N., Crippa, B. (2016). Persistent Scatterer Interferometry: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 115, 78–89.
28. Wasowski, J., Bovenga, F. (2014). Investigating landslides and unstable slopes with satellite SAR interferometry. *Engineering Geology*, 174, 103–138.
29. Tofani, V., Raspini, F., Catani, F., Casagli, N. (2013). Persistent Scatterer Interferometry for landslide mapping and monitoring. *Remote Sensing*, 5(3), 1045–1065.
30. Hochreiter, S., Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780.
31. Omar A., Conte Robles, (2010). Slope stability monitoring using remote sensing techniques. Missouri University of Science & Technology Bachelor of Science in Civil Engineering. May 2012 University of Arkansas, Fayetteville.