

DALL'OSSERVAZIONE NIVOLOGICA AGLI
ALGORITMI DI APPRENDIMENTO AUTOMATICO

PREVEDERE LE VALANGHE con il MACHINE LEARNING

Christian Brida: DICAM – Dipartimento di Ingegneria Civile, Ambientale e Meccanica, Università di Trento, Trento (TN); Pejo Funivie, Pejo (TN). Contatto: bridachristian@gmail.com

Carlo Bee: ARPAV – Centro Valanghe Arabba, Livinallongo del Col di Lana (BL); DICAM – Dipartimento di Ingegneria Civile, Ambientale e Meccanica, Università di Trento, Trento (TN)

Giorgio Rosatti: DICAM – Dipartimento di Ingegneria Civile, Ambientale e Meccanica, Università di Trento, Trento (TN)

DOI: 10.82089/NEV992026_3

UN SUPPORTO DECISIONALE AL RISCHIO VALANGHE NEL COMPRESORIO DI PEJO

Local-scale avalanche forecasting is a complex task that requires the integration of snowpack observations, meteorological data, and forecaster expertise. This study investigates the use of machine learning and Explainable Artificial Intelligence (XAI) techniques as operational decision-support tools in the Pejo ski area (Trentino, Italy). Using snow and weather data collected at the Pejo Tarlenta snow field together with a historical avalanche database, a classification model based on a Support Vector Machine (SVM) was developed to estimate the probability of natural avalanche activity on a given day. The results on the test dataset show a good ability to identify avalanche days, highlighting the potential of the model as a support tool for forecasting. The application of SHAP values enabled the identification of the most influential snow and meteorological variables, improving the transparency and interpretability of the model's decision-making process. Overall, the study demonstrates how artificial intelligence can support avalanche forecasters by enhancing objectivity, transparency, and the use of historical datasets, while complementing rather than replacing professional expertise and judgment.

La previsione del pericolo valanghe a scala locale richiede l'integrazione di dati nivo-meteorologici, osservazioni sul manto nevoso ed esperienza del previsore. Questo studio valuta l'impiego di tecniche di machine learning e Explainable Artificial Intelligence (XAI) come supporto operativo nel comprensorio sciistico di Pejo (Trentino).

Utilizzando dati raccolti presso il campo neve di Pejo Tarlenta e uno storico di eventi valanghivi, è stato sviluppato un modello di classificazione basato su Support Vector Machine (SVM), capace di stimare la probabilità di attività valanghiva naturale giornaliera.

I risultati ottenuti sui dati di test mostrano una buona capacità del modello di identificare le giornate valanghive, confermando il potenziale dello strumento come supporto alle decisioni del previsore. L'applicazione degli SHAP values ha permesso di individuare le variabili più influenti nella stima del rischio, rendendo trasparente il processo decisionale del modello. Lo studio evidenzia come l'intelligenza artificiale possa affiancare il previsore, migliorando oggettività, trasparenza e valorizzazione delle serie storiche, senza sostituirne esperienza e giudizio professionale.



VALANGHE

PERCHÉ LA PREVISIONE LOCALE DELLE VALANGHE È ANCORA UNA SFIDA

La previsione del rischio valanghe rappresenta una delle attività più complesse nell'ambito della sicurezza in montagna. Ogni giorno il previsore è chiamato a integrare informazioni provenienti da fonti diverse, quali dati meteorologici, osservazioni nivologiche, rilievi sul campo e conoscenza del territorio, per valutare la

probabilità di distacchi valanghivi e supportare le decisioni operative (Schweizer et al., 2003; McClung, 2023).

Sebbene i bollettini valanghe regionali forniscano un quadro fondamentale delle condizioni di stabilità del manto nevoso (European Avalanche Warning Services, 2018), la gestione del rischio richiede spesso valutazioni a una scala molto più dettagliata. Nei comprensori sciistici, lungo le infrastrutture di trasporto o in aree particolarmente esposte, è infatti necessario tradurre le indicazioni regionali in decisioni locali riguardanti l'apertura di piste e

impianti, la pianificazione di interventi di bonifica o l'adozione di specifiche misure di sicurezza.

Queste valutazioni dipendono fortemente dall'esperienza del previsore e dalla sua capacità di interpretare l'evoluzione delle condizioni nivometeorologiche (Schweizer et al., 2003). Tuttavia, la crescente disponibilità di dati storici raccolti da stazioni automatiche e campi neve, nonché da archivi di eventi valanghivi, apre nuove opportunità per sviluppare strumenti quantitativi in grado di supportare il processo decisionale.

Negli ultimi anni, le tecniche di machine learning hanno trovato applicazione in numerosi settori delle scienze ambientali (Bellaire et al., 2017; Viallon-Galinier, 2022) grazie alla loro capacità di individuare relazioni complesse tra le variabili di fenomeni naturali, a partire da grandi quantità di dati. Anche nel campo della previsione valanghe tali approcci stanno suscitando crescente interesse (Pozdnoukhov et al., 2008; Pérez-Guillén et al., 2022; Hendrick et al., 2023), poiché consentono di analizzare simultaneamente molte variabili e di riconoscere configurazioni favorevoli all'attività valanghiva che potrebbero non essere immediatamente evidenti neanche all'occhio di un esperto.

L'obiettivo di questo lavoro è valutare il potenziale di un sistema, composto da un modello di previsione basato sul machine learning e da un metodo di interpretazione delle previsioni stesse, come ausilio all'individuazione di giornate con attività valanghiva nel comprensorio sciistico di Pejo. L'intento non è tuttavia quello di sostituire l'esperienza del previsore, ma di affiancarlo con uno strumento aggiuntivo a supporto delle valutazioni operative (Brida et al., 2025).

Il caso studio di Pejo è particolarmente adatto per testare approcci basati sui dati, poiché combina una lunga esperienza operativa sul territorio con una base dati sufficientemente estesa per l'addestramento e la valutazione di modelli di machine learning. Ciò consente di esplorare concretamente il potenziale di questi strumenti come supporto alla previsione locale del rischio valanghe.






Figura 1. Area di studio del comprensorio sciistico di Pejo. Sono riportati gli impianti di risalita, le piste da sci, le principali stazioni di monitoraggio nivometeorologico e le aree soggette a pericolo valanghe.

IL CASO STUDIO DEL COMPRESORIO SCIISTICO DI PEJO

Il comprensorio sciistico di Pejo, nel Trentino occidentale, rappresenta un contesto particolarmente interessante per lo studio della previsione valanghiva a scala locale. Situato nel gruppo Ortles-Cevedale, è caratterizzato da una marcata variabilità topografica e nivologica.

La forte variabilità topografica dell'area, con versanti ripidi, diverse esposizioni e un gradiente altitudinale marcato, dai 1400 m di Pejo Fonti fino ai 3600 m della cima Taviela e del Monte Vioz, crea condizioni favorevoli a diversi meccanismi di innesco: dalla formazione di lastroni da vento agli strati deboli persistenti, fino alle valanghe di neve fresca e di neve umida tipiche delle fasi di rialzo termico (Schweizer et al., 2003; McClung, 2023).

All'interno di questo comprensorio, la Val della Mite costituisce uno dei settori più rilevanti dal punto di vista nivologico e operativo. La presenza di piste da sci, infrastrutture e aree soggette a distacchi frequenti rende questo settore particolarmente significativo dal punto di vista della gestione operativa del rischio.

Per questo motivo, nel corso degli anni è stato sviluppato un sistema di osservazione locale basato su misure nivometeorologiche continue e rilievi sul campo. Il campo neve di Pejo Tarlenta costituisce una delle principali fonti di dati per la valutazione delle condizioni del manto nevoso. Dal 1980 vengono raccolte in maniera continuativa informazioni relative alle precipitazioni nevose, alla temperatura dell'aria e della neve e alle caratteristiche del manto nevoso, fornendo una serie storica di grande valore per l'analisi e la previsione dell'attività valanghiva nel comprensorio. A questi dati si affianca un archivio storico di eventi valanghivi osservati nell'area, costruito nel corso di più stagioni invernali attraverso l'attività del servizio di prevenzione locale. Presso il campo neve di Pejo Tarlenta, dal 1980 le valanghe vengono registrate secondo il Modello 1 AINEVA (Associazione Interregionale NEve e VALanghe, 2013), mentre dai primi anni 2000 è disponibile un database più dettagliato che ne documenta posizione, tipologia e principali caratteristiche. Questi archivi rappresentano una risorsa fondamentale per lo sviluppo di modelli in grado di supportare la previsione dell'attività valanghiva, poiché consentono di associare

specifiche condizioni nivo-meteorologiche alla presenza o all'assenza di attività valanghiva naturale.

Dal punto di vista operativo, il comprensorio di Pejo rappresenta un esempio tipico di ambiente alpino in cui le decisioni devono essere prese su scala molto locale e con tempi ridotti. La variabilità delle condizioni meteorologiche e la complessità del terreno rendono infatti difficile una semplice trasposizione delle informazioni provenienti dai bollettini regionali (European Avalanche Warning Services, 2018), richiedendo invece una valutazione continua e contestualizzata del rischio.

DAL DATO ALLA PREVISIONE

Come già osservato, negli ultimi anni la crescente disponibilità di dati nivo-meteorologici raccolti nei comprensori sciistici ha aperto nuove possibilità per lo sviluppo di strumenti di supporto alla previsione del pericolo valanghe. Tuttavia, trasformare grandi quantità di osservazioni in informazioni utili per il processo decisionale non è immediato, poiché le relazioni tra condizioni meteorologiche, evoluzione del manto nevoso e attività valanghiva sono spesso complesse e difficili da interpretare.




Figura 2. Schema del processo di sviluppo di un modello di machine learning: dalla raccolta dei dati nivo-meteorologici alla scelta, costruzione, valutazione e applicazione operativa del modello.

Il ruolo del machine learning e il processo di costruzione del modello

In questo contesto si inserisce il machine learning, un insieme di metodi che consente di apprendere automaticamente a partire dai dati. L'idea di base è che, invece di descrivere in modo esplicito i processi fisici che portano all'instabilità del manto nevoso, il modello analizzi esempi del passato per riconoscere situazioni simili tra loro e associare determinate condizioni alla presenza o assenza di attività valanghiva. Nel caso di questo studio, ogni giornata è descritta attraverso un insieme di informa-

zioni relative alle condizioni nivo-meteorologiche, come temperatura, precipitazioni e caratteristiche del manto nevoso e, informazione chiave, la presenza o l'assenza di attività valanghiva. Il modello associa le informazioni nivo-meteorologiche alla possibile attività valanghiva ed "impara" a distinguere quali condizioni tendono a generare giornate valanghive e quali condizioni invece non portano ad attività significativa.

Il processo di costruzione del modello può essere descritto attraverso alcune fasi fondamentali (si veda anche la Figura 2):

1. Raccolta dei dati: vengono raccolte le osservazioni disponibili e ne viene verificata la coerenza nel tempo.
2. Costruzione del dataset: i dati vengono organizzati in modo da descrivere nel modo più completo possibile le condizioni della neve e dell'atmosfera. In questa fase vengono inoltre introdotte informazioni aggiuntive che permettono di tenere conto anche dell'evoluzione delle condizioni nei giorni precedenti.
3. Scelta del modello di machine learning più opportuno: vengono confrontati diversi algoritmi e configurazioni per selezionare il modello più efficace.
4. Addestramento del modello: una parte dei dati viene utilizzata per permettere al modello di individuare le relazioni tra condizioni nivo-meteorologiche e presenza o assenza di attività valanghiva.
5. Verifica delle prestazioni: il modello viene testato su dati mai utilizzati in precedenza, per valutarne la capacità di affrontare situazioni nuove.
6. Applicazione del modello: una volta completato il processo di addestramento e valutazione, il modello può essere utilizzato per stimare la probabilità giornaliera di attività valanghiva.

Raccolta dati e costruzione del dataset

La base dati utilizzata integra le osservazioni nivo-meteorologiche raccolte presso il campo neve di Pejo Tarlenta con l'archivio storico delle valanghe registrate secondo il Modello 1 AINEVA. Il periodo analizzato copre 44 stagioni invernali, dalla stagione

1980–81 alla stagione 2023–24.

Per descrivere le condizioni giornaliere della neve e dell'atmosfera sono state considerate numerose informazioni meteorologiche e nivologiche, tra cui temperatura dell'aria, precipitazioni e altezza del manto nevoso. In totale sono stati inizialmente considerati 56 indicatori, successivamente ridotti a un insieme di 20 variabili ritenute a priori più significative per la previsione dell'attività valanghiva. Ad ogni giornata è stata poi associata la presenza o l'assenza di attività valanghiva naturale.

Ai fini dell'analisi sono state considerate esclusivamente valanghe di neve fresca e di neve umida di media e grande dimensione, cioè eventi potenzialmente rilevanti per la sicurezza delle piste. Sono stati invece esclusi eventi di piccola dimensione e valanghe a lastroni da vento, poiché fortemente legati a condizioni locali molto specifiche e difficilmente generalizzabili su scala giornaliera (Schweizer, 2003; McClung, 2023).

Nel periodo analizzato, sono risultate disponibili 5038 giornate di osservazioni, delle quali 668 associate ad almeno un evento valanghivo. Dopo una selezione basata sulla qualità e sulla completezza dei dati, sono state considerate 175 giornate effettivamente rappresentative di situazioni con attività valanghiva. A queste sono state affiancate 175 giornate senza attività, per permettere al modello di discriminare tra le due situazioni. In questo modo si è realizzato un insieme di dati "bilanciato", necessario per un buon addestramento del modello.

La scelta della Support Vector Machine

Tra i diversi metodi di machine learning disponibili, in questo lavoro è stata scelta una Support Vector Machine (SVM) (Cortes & Vapnik, 1995), una tecnica particolarmente adatta a problemi in cui è necessario distinguere tra due situazioni mutuamente esclusive.

La scelta è stata guidata da due caratteristiche principali: la capacità di lavorare efficacemente anche con dataset di dimensioni limitate, come nel caso delle osservazioni nivo-meteorologiche storiche, e la capa-

COS'È UNA SUPPORT VECTOR MACHINE?

Una Support Vector Machine (SVM) è un metodo di classificazione che impara a distinguere tra due situazioni diverse a partire da esempi osservati in passato.

Nell'esempio riportato in Figura 3, ogni giornata è descritta mediante due sole variabili: la neve fresca cumulata negli ultimi tre giorni e la temperatura massima dell'aria. I punti blu rappresentano le giornate senza attività valanghiva, mentre i punti arancioni rappresentano le giornate in cui si è verificata attività valanghiva naturale. L'obiettivo della SVM è individuare una linea di separazione che distingua nel modo più efficace possibile i due gruppi. Per farlo, il metodo massimizza la distanza tra la linea di separazione e i punti più vicini appartenenti alle due classi. Questa distanza è chiamata margine e rappresenta una misura della robustezza della classificazione. I punti evidenziati in figura sono i cosiddetti "support vector", ovvero le osservazioni che determinano la posizione della linea di separazione. Sono gli esempi più informativi per il modello, poiché si trovano più vicini al confine tra le due classi.

Quando viene analizzata una nuova giornata, il modello verifica da quale lato della linea essa si colloca e la classifica di conseguenza. Nel caso reale utilizzato in questo studio, ogni giornata è descritta da numerose variabili nivo-meteorologiche. La separazione non avviene quindi tramite una semplice linea, ma attraverso una superficie multidimensionale chiamata iperpiano, che consente di distinguere le diverse configurazioni presenti nei dati storici.




Figura 3. Esempio del funzionamento di una Support Vector Machine (SVM) in un caso semplificato. Ogni punto rappresenta una giornata descritta da due sole variabili nivo-meteorologiche (neve fresca degli ultimi 3 giorni e temperatura massima). La linea continua separa le giornate con e senza attività valanghiva; i support vector ne definiscono la posizione, mentre le linee tratteggiate delimitano il margine massimizzato dal modello.

cità di gestire relazioni complesse tra variabili, tipiche di un fenomeno influenzato dall'interazione di numerosi fattori meteorologici e ambientali.

In modo intuitivo, una Support Vector Machine può essere vista come uno strumento che, sulla base delle informazioni disponibili per una determinata giornata, è in grado di distinguere tra condizioni favorevoli e non favorevoli all'attività valanghiva. Questa capacità viene appresa a partire dai dati storici disponibili.

Addestramento e validazione sul dataset

Una volta costruito il dataset finale, le osservazioni sono state suddivise in un insieme di addestramento (75%, pari a 262 osservazioni) e in un insieme di verifica (25%, pari a 88 osservazioni). Questa suddivisione consente di valutare il comportamento del modello su dati non utilizzati nella fase di costruzione.

Il modello viene prima "allenato" utiliz-

zando le osservazioni del primo insieme, in modo da apprendere le relazioni tra condizioni nivo-meteorologiche e attività valanghiva. Questa fase porta alla valutazione dei valori dei parametri del modello. Successivamente, questo viene testato sul secondo insieme, per verificare che tali relazioni non siano valide soltanto sui dati utilizzati per l'addestramento, ma possano essere generalizzate a nuove osservazioni. Per valutare le prestazioni del modello sono stati utilizzati alcuni indicatori di sintesi che permettono di quantificare l'affidabilità delle previsioni e la capacità del sistema di distinguere correttamente tra giornate con e senza attività valanghiva. I risultati mostrano che il modello è in grado di distinguere in modo affidabile tra giornate con e senza attività valanghiva naturale. In termini concreti, su dieci giornate effettivamente valanghiva, il modello ne identifica correttamente circa otto, contenendo al tempo stesso il numero di falsi allarmi.

Su 88 giornate di test, il modello ha segnalato correttamente 31 situazioni valanghiva e ignorato correttamente 42 giornate tranquille. Ha generato 5 falsi allarmi, giornate segnalate come pericolose ma senza eventi osservati, e ha mancato 10 giornate in cui si sono verificate valanghe non previste.

I falsi allarmi, dal punto di vista operativo, possono comunque rappresentare condizioni potenzialmente instabili, nelle quali il distacco non si è verificato oppure non è stato osservato. Più critiche risultano invece le mancate segnalazioni: i 10 casi in cui il modello non ha previsto attività valanghiva effettivamente avvenuta sono spesso associati a configurazioni nivo-meteorologiche complesse o poco rappresentate nei dati storici, suggerendo la necessità di ampliare ulteriormente il dataset per migliorare la capacità del modello di generalizzare a situazioni rare. Nel complesso, i risultati indicano che il modello rappresenta uno strumento so-

Figura 4. Applicazione del modello alla stagione 2024–2025: confronto tra la probabilità stimata dal modello e le valanghe effettivamente osservate (piccole in arancione, medio-grandi in rosso). Le aree azzurre indicano i giorni con probabilità superiore a 0.5. I numeri segnalano alcuni casi particolari: (1) valanghe piccole non rilevate, (2) valanghe medio-grandi non rilevate, (3) periodo con falsi positivi





Figura 5. Variabili che il modello considera più importanti nella previsione dell'attività valanghiva. Le variabili sono ordinate in base alla loro influenza complessiva sulle decisioni del modello; i colori evidenziano valori bassi (blu) ed elevati (rosso) delle diverse grandezze considerate.



stanzialmente affidabile per supportare la valutazione del pericolo valanghe a scala locale, pur mantenendo i limiti tipici dei sistemi basati su apprendimento da dati storici.

La validazione in condizioni operative

Per verificare il comportamento del modello in un contesto più vicino alla realtà,

è stata utilizzata la stagione invernale 2024–2025, non inclusa nella fase di addestramento. Questa operazione consente di osservare come il sistema si comporta quando si trova davanti a una stagione nuova, con condizioni meteo e nivologiche diverse da quelle già viste.

Anche in questo caso (vedi Figura 4) il modello si dimostra stabile e affidabile,

riuscendo a fornire indicazioni coerenti con l'evoluzione delle condizioni osservate sul territorio. Le prestazioni restano quindi buone anche al di fuori del contesto controllato della fase di sviluppo.

Questo risultato è importante perché suggerisce che lo strumento non si limita a funzionare sui dati noti, ma mantiene una buona capacità di adattamento alla variabilità naturale delle stagioni invernali. In prospettiva, questo è un requisito fondamentale per un possibile utilizzo operativo a supporto delle valutazioni previsionali.


APRIRE LA SCATOLA NERA: I VALORI SHAP

Uno dei limiti più frequentemente attribuiti agli algoritmi di machine learning è quello di comportarsi come una sorta di "scatola nera": il sistema fornisce una previsione, ma non sempre è chiaro quali informazioni abbiano portato a quel risultato. Nell'ambito di un sistema di supporto alla decisione, questo rappresenta un grosso limite, perché il previsore ha bisogno non solo di una previsione, ma anche di indicazioni utili a comprendere i fattori che hanno influenzato quella valutazione. Per ovviare a tale limite, è stata utilizzata una metodologia di letteratura, denominata SHAP (SHapley Additive exPlanations) (Lundberg & Lee, 2017). I valori SHAP associati a ciascuna variabile permettono di analizzare sia le singole previsioni, individuando il contributo di ciascuna variabile a una specifica previsione, sia, aggregando i risultati, il comportamento generale del modello, evidenziando quali variabili risultano mediamente più influenti nelle previsioni.

Le variabili più importanti

Per comprendere quali fattori il sistema consideri più rilevanti nella distinzione tra giornate con e senza attività valanghiva naturale, è stata analizzata l'importanza attribuita alle diverse variabili nivometeorologiche nella fase di addestramento utilizzando i SHAP values di ciascuna di esse (Figura 5).

La variabile più importante risulta essere la stagionalità (DayOfSeason), espressa come numero di giorni trascorsi dal 1° dicembre.



Questo parametro riflette indirettamente l'evoluzione delle condizioni meteorologiche e dell'irraggiamento solare nel corso della stagione, particolarmente rilevanti per l'attività valanghiva di neve umida. Tra i fattori più significativi compare anche l'altezza del manto nevoso (HSnum). Un manto più spesso tende infatti a ridurre l'influenza della rugosità del terreno e può favorire il movimento della neve anche in presenza di sovraccarichi relativamente modesti.

Un ruolo importante è attribuito inoltre alle precipitazioni cumulate negli ultimi tre giorni (Precip_3d), che rappresentano un indicatore diretto del carico aggiuntivo imposto al manto nevoso. Anche la penetrazione della sonda battage (PR) risulta tra le variabili più influenti, poiché fornisce informazioni sulla consistenza e sulla resistenza meccanica della neve. È interessante notare che, da un punto di vista della fisica del processo, questi tre fattori sono strettamente collegati ai processi che controllano la stabilità del manto nevoso.

Tra gli altri fattori rilevanti figurano la temperatura della neve nei primi strati superficiali e le variazioni recenti di temperatura e di altezza del manto nevoso. Queste variabili consentono di descrivere non solo lo stato della neve in un determinato momento, ma anche la sua evoluzione nei giorni precedenti.

Le variabili più influenti sono quindi quelle che descrivono l'accumulo di neve, le condizioni termiche e l'evoluzione stagionale.




Figura 6. Due esempi di interpretazione delle previsioni fornite dal modello. I grafici mostrano i fattori che hanno contribuito ad aumentare (rosso) o ridurre (blu) la probabilità di attività valanghiva nelle due giornate analizzate. Il valore base rappresenta la previsione media del modello, mentre $f(x)$ è il risultato finale ottenuto sommando i contributi delle diverse variabili, quantificati tramite i valori SHAP.

Figura 7. Interfaccia del bot Telegram sviluppato per la consultazione operativa del modello, con visualizzazione della probabilità giornaliera di attività valanghiva naturale e relativa interpretazione dei più rilevanti fattori di rischio.

Nel complesso, i risultati appaiono coerenti con quanto riportato dalla letteratura nivologica e con l'esperienza operativa maturata nella previsione valanghe. Episodi di intensa precipitazione, rapide variazioni termiche e condizioni tipiche del periodo primaverile rappresentano infatti alcuni dei principali fattori associati all'innesco di valanghe naturali (Schweizer et al., 2003; McClung, 2023).

Comprendere le decisioni dell'algoritmo

I valori SHAP associati a ciascuna variabile

permettono anche di quantificare il contributo di ogni fattore alla previsione di una specifica giornata. Tale contributo è misurato rispetto a un valore di riferimento, corrispondente alla previsione media del modello calcolata sull'intero insieme di addestramento.

Queste indicazioni rappresentano un elemento particolarmente utile come supporto al processo decisionale del previsor: egli può infatti confrontare le osservazioni effettuate sul terreno e la propria esperienza con i risultati forniti dal modello, per giungere a una decisione più informata.

VALANGHE

L'analisi di casi specifici (vedi Figura 6) ha inoltre mostrato che le giornate classificate come favorevoli all'attività valanghiva sono generalmente caratterizzate dalla presenza simultanea di più fattori predisponenti. Questo risultato conferma come l'innesco delle valanghe naturali dipenda dall'interazione tra diverse componenti meteorologiche e nivologiche, piuttosto che dall'azione di una singola variabile.

Dalla ricerca all'operatività quotidiana

Verificata la potenzialità del modello previsionale e di quello interpretativo, l'ultimo passaggio necessario per trasformare questo strumento in un supporto operativo quotidiano alle decisioni è stato quello di renderlo facilmente accessibile e immediatamente utilizzabile da chi si occupa ogni giorno di valutazione del pericolo nel comprensorio sciistico di Pejo.

È stato quindi sviluppato un sistema automatico di consultazione basato su un bot Telegram (vedi Figura 7). Ogni mattina, dopo la raccolta e il controllo dei dati nivometeorologici provenienti dal campo neve di Pejo Tarlenta e dalle stazioni di monitoraggio, le informazioni vengono archiviate e utilizzate dal modello per elaborare una nuova previsione. Nel giro di pochi secondi, il sistema elabora automaticamente i dati disponibili e produce una previsione gior-



naliera. Il risultato viene restituito sul telefono dell'operatore sotto forma di rappresentazione grafica (Figura 7), che mostra i principali fattori che hanno influenzato la previsione e l'intensità del loro contributo: in rosso le variabili che hanno spinto verso un maggior rischio, in blu quelle che hanno spinto verso un rischio minore.

UN NUOVO ALLEATO PER IL PREVISORE

Negli ultimi decenni la previsione valanghe ha beneficiato di un progressivo aumento delle conoscenze scientifiche, della diffusione di reti di monitoraggio sempre più capillari e della disponibilità di archivi storici di dati nivo-meteorologici (Schweizer et al., 2003; McClung, 2023). Parallelamente, l'evoluzione delle tecniche di analisi dei dati ha aperto nuove opportunità per trasformare questo patrimonio informativo in strumenti di supporto alle decisioni (Pozdnoukhov et al., 2008; Viallon-Galinier et al., 2023).

Il caso studio sviluppato nel comprensorio sciistico di Pejo mostra come un approccio basato sul machine learning possa contribuire alla previsione locale del pericolo valanghe, fornendo valutazioni coerenti con le conoscenze nivologiche e sufficientemente accurate da risultare utili in un contesto operativo. Le prestazioni ottenute hanno dimostrato infatti che i dati raccolti nel corso di decenni di osservazioni possono essere utilizzati per individuare pattern ricorrenti significativi tra le condizioni nivo-meteorologiche e l'attività valanghiva naturale.

L'impiego degli SHAP values ha permesso inoltre di trasformare il modello da semplice strumento predittivo a sistema di supporto alla decisione trasparente e verificabile per il previsore. I risultati ottenuti non devono tuttavia essere interpretati come un tentativo di automatizzare la previsione valanghe. L'attività valanghiva è il risultato dell'interazione di processi meteorologici, nivologici e topografici estremamente complessi, che non possono essere descritti completamente da una singola base dati. L'esperienza del

previsore, la conoscenza del territorio e l'osservazione diretta delle condizioni del manto nevoso rimangono quindi elementi centrali e insostituibili del processo decisionale (LaChapelle, 1980; McClung, 2023). In questo contesto, i modelli di machine learning possono rappresentare un ulteriore livello di analisi, capace di affiancare il giudizio umano con informazioni oggettive, riproducibili e basate sull'analisi sistematica delle osservazioni storiche. L'esperienza maturata a Pejo suggerisce come l'integrazione tra competenze nivologiche e strumenti di intelligenza artificiale possa costituire un ambito di ulteriore sviluppo per la gestione del rischio valanghe. In definitiva, il machine learning non so-

stituisce il previsore: può però diventare un nuovo alleato, capace di trasformare i dati raccolti sul territorio in conoscenza utile e di supportare decisioni sempre più consapevoli nella gestione della sicurezza in ambiente innevato.

RINGRAZIAMENTI

Gli autori desiderano ringraziare l'ing. Marco Salucci per la consulenza fornita nello sviluppo del modello e per il prezioso contributo tecnico all'analisi dei dati e all'implementazione dell'approccio di machine learning durante il lavoro di tesi.

Si ringrazia inoltre Giacomo Podetti per aver gentilmente messo a disposizione l'immagine aerea della Val de la Mite.

BIBLIOGRAFIA

- Associazione Interregionale NEve e VALanghe, 2013: Codice Nivometeorologico per il rilievo giornaliero. Tech. Rep
- Bellaire, S., A. van Herwijnen, C. Mitterer, and J. Schweizer, 2017: On forecasting wet-snow avalanche activity using simulated snow cover data. *Cold Regions Science and Technology*, 144, 28–38.
- Brida, C., Rosatti, G., Bee, C., & Salucci, M., 2025. Avalanche Forecasting in the Pejo Ski Area: A Data-Driven Approach Using Support Vector Machines.
- Cortes, C., and V. Vapnik, 1995: Support-Vector Networks. *Machine Learning*, 20 (1), 273–297.
- European Avalanche Warning Services, 2018: European Avalanche Danger Scale. Tech. rep.
- Hendrick, M., F. Techel, M. Volpi, T. Olevski, C. Pérez-Guillén, A. V. Herwijnen, and J. Schweizer, 2023: Automated prediction of wet-snow avalanche activity in the Swiss Alps. *Journal of Glaciology*, 50 (1), 1–14.
- LaChapelle, E. R., 1980: The fundamental processes in conventional avalanche forecasting. *Journal of Glaciology*, 26 (94), 75–84.
- Lundberg, S. M., and S. I. Lee, 2017: A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 2017-Decem (Section 2), 4766–4775.
- McClung, D., 2023: The Avalanche Handbook. 4th ed., 368 pp.
- Pérez-Guillén, C., and Coauthors, 2022: Data-driven automated predictions of the avalanche danger level for dry-snow conditions in Switzerland. *Natural Hazards and Earth System Sciences*, 22 (6), 2031–2056.
- Pozdnoukhov, A., R. S. Purves, and M. Kanevski, 2008: Applying machine learning methods to avalanche forecasting. *Annals of Glaciology*, 49, 107–113.
- Schweizer, J., J. B. Jamieson, and M. Schneebeli, 2003: Snow avalanche formation. *Reviews of Geophysics*, 41 (4).
- Viallon-Galinier, L., 2022: Combining physical modeling and machine learning to improve avalanche hazard forecasting