

# Machine Learning per la Manutenzione Predittiva

Francesco Cordoni, Luca di Persio, Riccardo Muradore

Università degli Studi di Verona, Dipartimento di informatica

francescogiuseppe.cordoni@univr.it, luca.dipersio@univr.it, riccardo.muradore@univr.it

## 1 Introduzione

Ogni processo industriale avanzato necessita di un monitoraggio costante e attento al fine di identificare, nella maniera più accurata e rapida possibile, possibili malfunzionamenti o segnali di malfunzionamenti. Effettuare in maniera robusta e precisa tale monitoraggio permette una drastica riduzione dei costi (e.g., diminuendo gli sprechi dovuti a produzioni di bassa qualità) intervenendo in maniera preventiva su macchinari prima che questi si guastino. In questo senso la manutenzione predittiva è emersa come strumento di analisi avanzato di sistemi industriali e manifatturieri complessi al fine di aumentarne la produttività e l'efficienza.

Con manutenzione predittiva si intendono le tecniche di determinazione dello stato di un sistema al fine di predirne la funzionalità e stimarne il tempo di vita rimasto per poter intervenire prima che un guasto avvenga. Il successo di un processo di manutenzione predittiva dipende principalmente da due fattori: (1) la disponibilità di dati adeguati e (2) la necessità di modelli adeguati che riescano a predire il comportamento (normale a anomalo) del sistema, [Qin, 2012].

Il recente sviluppo tecnologico ha portato ad un incremento smisurato dei dati a disposizione delle aziende, sancendo l'ingresso nell'era dei *big data*. Se da un lato questa pressoché infinita disponibilità di dati è sicuramente utile, dall'altro è emersa l'inadeguatezza dei classici metodi statistici nella gestione di una tale mole di dati. Infatti, la difficoltà di modellizzare sistemi troppo complessi, come spesso succede nella maggior parte delle realtà industriali, tramite le leggi fisiche che li governano e l'incapacità dei modelli statistici classici di gestione di grandi quantità di dati ha portato allo sviluppo di tecniche di analisi statistiche moderne note come *machine learning* (ML). Recentemente c'è stato un costante sviluppo delle tecniche ML, con performance nell'identificazione di guasti e malfunzionamenti mai raggiunte prima. Tali risultati hanno chiaramente evidenziato a svariate realtà manifatturiere e industriali le potenzialità di un efficiente processo di manutenzione predittiva automatico, [Martinez *et al.*, ]. In particolare svariate realtà possono usufruire dei vantaggi derivanti da una corretta manutenzione predittiva, dall'identificazione di frodi fiscali, [Kilundu *et al.*, 2011], all'analisi delle vibrazioni, o ancora l'identificazione di macchinari difettosi, [Cordoni *et al.*, 2018].

## 1.1 Progetti e Finanziamenti

L'attività di questa ricerca è finanziata dal POR/FESR della regione Veneto sul progetto "PreMANI – Manifattura Predittiva: progettazione, sviluppo e implementazione di soluzioni di Digital Manufacturing per la previsione della Qualità e la Manutenzione Intelligente" 2014-2020.

Il dipartimento di Informatica è stato inoltre valutato eccellente sul progetto "Informatica per Industria 4.0", che ha ricevuto un sostegno finanziario di 8 milioni di euro. Una delle azioni riguarda la realizzazione di un laboratorio per l'Industria 4.0 in cui le tecniche di manutenzione predittiva possono essere implementate.

## 2 Il machine learning per la manutenzione predittiva

Esistono diversi approcci ML per affrontare il problema della manutenzione predittiva, principalmente legati all'obiettivo finale che uno si pone, divisi in due macro-settori: problemi di classificazione dove il metodo ML restituisce una risposta booleana se il sistema sta avendo e (o con quale probabilità avrà in futuro) un comportamento anomalo e problemi di regressione nel quale il metodo restituisce la durata di vita stimata di un dato macchinario.

Diversi tipi di metodi ML sono solitamente usati in relazione alla quantità e alla qualità di dati a disposizione, classificati principalmente in due categorie: *supervised* e *unsupervised learning*. I primi, applicano a dati nuovi quanto imparato dall'esperienza tramite esempi forniti dall'utente in cui viene esplicitamente specificato lo stato del sistema. Partendo dunque da dati strutturati, con indicazioni relative allo stato di salute del sistema, i metodi ML *supervised* ricavano le predizioni circa lo stato futuro del sistema; tra i principali metodi *supervised* usati vi sono alberi decisionali, support vector machines e reti neurali [Friedman *et al.*, 2001].

In [Cordoni *et al.*, 2018], un'avanzata procedura per il test di apparecchi ad uso domestico è stata testata, identificando, tramite diversi metodi ML *supervised*, quali apparecchi presentino comportamenti anomali, che possano segnalare difetti o possibili malfunzionamenti, a partire da dati di potenza, corrente e temperatura. In Figura 1 viene riportato il confronto tra i dati reali appartenenti alle apparecchiature domestiche testate e la predizione dello stato degli stessi apparecchi tramite un metodo *supervised* di regressione ad albero.




Figura 1: Confronto tra stato reale del sistema e predizione tramite metodo supervised di regressione ad albero

Al contrario, qualora non si abbiano a disposizione indicazioni precise circa lo stato reale del sistema, i metodi ML *unsupervised* identificano similitudini nei dati in modo da raggrupparli in funzione della presenza o meno di caratteristiche specifiche. La forza dei metodi *unsupervised* sta nell'informazione minimale necessaria ad ottenere risultati accurati; infatti, per la natura stessa del problema, risulta spesso difficile avere a disposizione indicazioni precise sulla natura del sistema o anche un numero sufficientemente ampio di esempi di malfunzionamenti o rotture. I più noti metodi *unsupervised* comprendono *k*-means clustering, clustering gerarchico e Gaussian mixture models [Friedman *et al.*, 2001]. Recentemente un particolare metodo *unsupervised*, la rete neurale *autoencoder*, ha raggiunto performance particolarmente elevate nell'identificare nei dati comportamenti ritenuti anomali, trovando dunque numerose applicazioni nella manutenzione predittiva [Chopra e Yadav, 2015].

In [Cordoni *et al.*, 2018], oltre a vari metodi *supervised*, anche i principali metodi *unsupervised* sono stati applicati a dati provenienti da una catena di test di apparecchiature per uso domestico. In particolare, in Figura 2, viene riportato il confronto tra la rappresentazione reale dei dati e la rappresentazione imparata tramite rete *autoencoder*; risulta evidente come la nuova rappresentazione permetta di separare graficamente i componenti difettosi da quelli funzionanti correttamente.

### 3 Sviluppi futuri

Recentemente, le problematiche principali delle applicazioni industriali della manutenzione predittiva, ovvero la difficoltà di reperire dati strutturati con identificazioni precise dello stato del sistema e la scarsa numerosità di dati provenienti da guasti, hanno portato allo sviluppo di opportuni metodi ML applicabili a situazioni a metà strada tra la classe *supervised* e la classe *unsupervised*. In particolare, sono stati sviluppati metodi ML *semi-supervised* che trattano dati che sono per la maggior parte non classificati, e quindi appartenenti ai metodi *unsupervised*, mentre una piccola parte presenta indicazioni precise circa lo stato del sistema, [Zhu, 2005]. Altri meto-

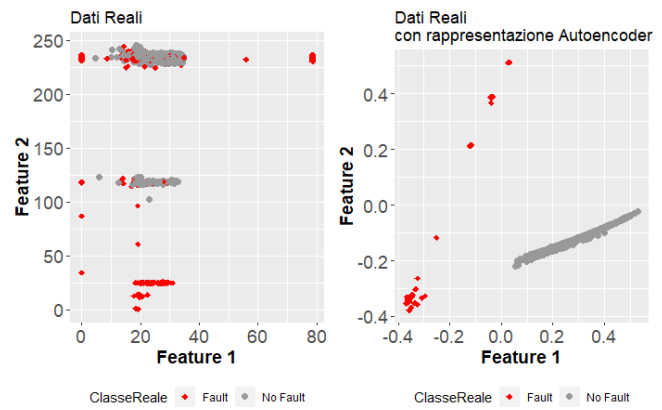


Figura 2: Confronto tra rappresentazione reale dei dati e rappresentazione imparata tramite rete Autoencoder

di possano essere addestrati su determinati problemi per poi trasferire le conoscenze acquisite a nuovi dati, appartenenti a sistemi simili ma non identici; tali metodi vengono quindi chiamati *transfer learning*, [West *et al.*, 2007].

### Riferimenti bibliografici

- [Chopra e Yadav, 2015] Praveen Chopra e Sandeep Kumar Yadav. Fault detection and classification by unsupervised feature extraction and dimensionality reduction. *Complex & Intelligent Systems*, 1(1-4):25–33, 2015.
- [Cordoni *et al.*, 2018] Francesco Cordoni, Gianluca Bacchiega, Giulio Bondani, Robert Radu, e Riccardo Muradore. A machine learning approach for fault detection and fault diagnosis in household appliances (submitted). 2018.
- [Friedman *et al.*, 2001] Jerome Friedman, Trevor Hastie, e Robert Tibshirani. *The elements of statistical learning*, volume 1. Springer series in statistics New York, 2001.
- [Kilundu *et al.*, 2011] Bovic Kilundu, Pierre Dehombreux, e Xavier Chimentin. Tool wear monitoring by machine learning techniques and singular spectrum analysis. *Mechanical Systems and Signal Processing*, 25(1):400–415, 2011.
- [Martinez *et al.*, ] Julio Martinez, Christianne Dennison, e Zhengyi Lian. Machine learning for predictive maintenance.
- [Qin, 2012] S Joe Qin. Survey on data-driven industrial process monitoring and diagnosis. *Annual reviews in control*, 36(2):220–234, 2012.
- [West *et al.*, 2007] Jeremy West, Dan Ventura, e Sean Warnick. Spring research presentation: A theoretical foundation for inductive transfer. *Brigham Young University, College of Physical and Mathematical Sciences*, 1:32, 2007.
- [Zhu, 2005] Xiaojin Jerry Zhu. Semi-supervised learning literature survey. Technical report, University of Wisconsin-Madison Department of Computer Sciences, 2005.