



UN ESEMPIO DI MANUTENZIONE PREDITTIVA

L'impiego di machine learning e chemiometria nella manutenzione predittiva ottimizza il monitoraggio dei processi, rilevando precocemente anomalie per la riduzione di guasti, costi e tempi di fermo. Analizzando dati storici dai PLC con modelli multivariati, è possibile prevedere malfunzionamenti, migliorando l'efficienza operativa e garantendo maggiore affidabilità nei processi industriali.

L'Industria 4.0 e 5.0 ha rivoluzionato l'uso dei dati nei processi produttivi, grazie all'integrazione di sensori intelligenti, automazione avanzata e analisi in tempo reale, consentendo un monitoraggio più preciso e un'ottimizzazione delle operazioni [1]. Uno degli ambiti più promettenti è la manutenzione predittiva, che permette di anticipare i guasti e ottimizzare le risorse, riducendo costi e tempi di inattività. A differenza delle strategie tradizionali, basate su interventi programmati o correttivi, la manutenzione predittiva utilizza modelli di machine learning e chemiometria per individuare segnali di deterioramento prima di un malfunzionamento [2]. Analizzando dati storici e in tempo reale, questi modelli permettono previsioni accurate e interventi tempestivi [3].

L'Industria 4.0 punta su digitalizzazione e automazione attraverso Internet-of-Things (IoT), intelligenza artificiale (AI) e cloud computing, migliorando efficienza e riducendo costi; l'Industria 5.0 enfatizza la collaborazione uomo-macchina, con robot collaborativi (*cobot*) al fine di migliorare sicurezza e qualità del lavoro, oltre a promuovere la sostenibilità ambientale e sociale, favorendo l'uso di energie rinnovabili ed economia circolare [4-6]. L'adozione di strategie basate sui dati ha di fatto trasformato l'industria, passando da una manutenzione reattiva a un approccio predittivo e preventivo, grazie alla crescente disponibilità dei dati stessi e all'evoluzione delle tecnologie di analisi avanzata. La capacità di prevedere anomalie ha così migliorato la gestione degli impianti, ridu-

cendo fermi macchina e costi di manutenzione. A differenza della manutenzione correttiva, che interviene solo dopo un guasto, e della manutenzione preventiva, basata su interventi programmati, la manutenzione predittiva consente di monitorare costantemente le condizioni operative, identificando segnali precoci per un intervento tempestivo e mirato [7].

Gli strumenti utilizzati per implementare un sistema di manutenzione predittiva comprendono:

- i) sensori avanzati in grado di rilevare parametri e variabili quali temperatura, vibrazioni, pressione e consumo energetico, ma anche dati binari o variabili categoriche;
- ii) PLC (*Programmable Logic Controller*) che raccolgono e storicizzano i dati in tempo reale;
- iii) algoritmi che hanno l'obiettivo di analizzare grandi quantità di informazioni per individuare schemi e tendenze (*trend*) non facilmente riscontrabili, similitudini tra record in esame e, eventualmente, anomalie [8].

Uno degli esempi di applicazione della manutenzione predittiva è il progetto DOLPHINS, sviluppato dal gruppo del Dipartimento di Chimica dell'Università di Torino (Marcello Baricco, Marco Vincenti, Eugenio Alladio) in collaborazione con IVECO Group (Paolo Foglio, Fabio Pozzi, Fabio Oglietti) e RADA Srl (Renato Pagliari, Vincenzo Leogrande). Il progetto (Fig. 1), nel caso specifico, è nato con l'obiettivo di ottimizzare il monitoraggio delle macchine industriali attraverso l'utilizzo di algoritmi avanzati. DOLPHINS, in particolare, ha dimostrato

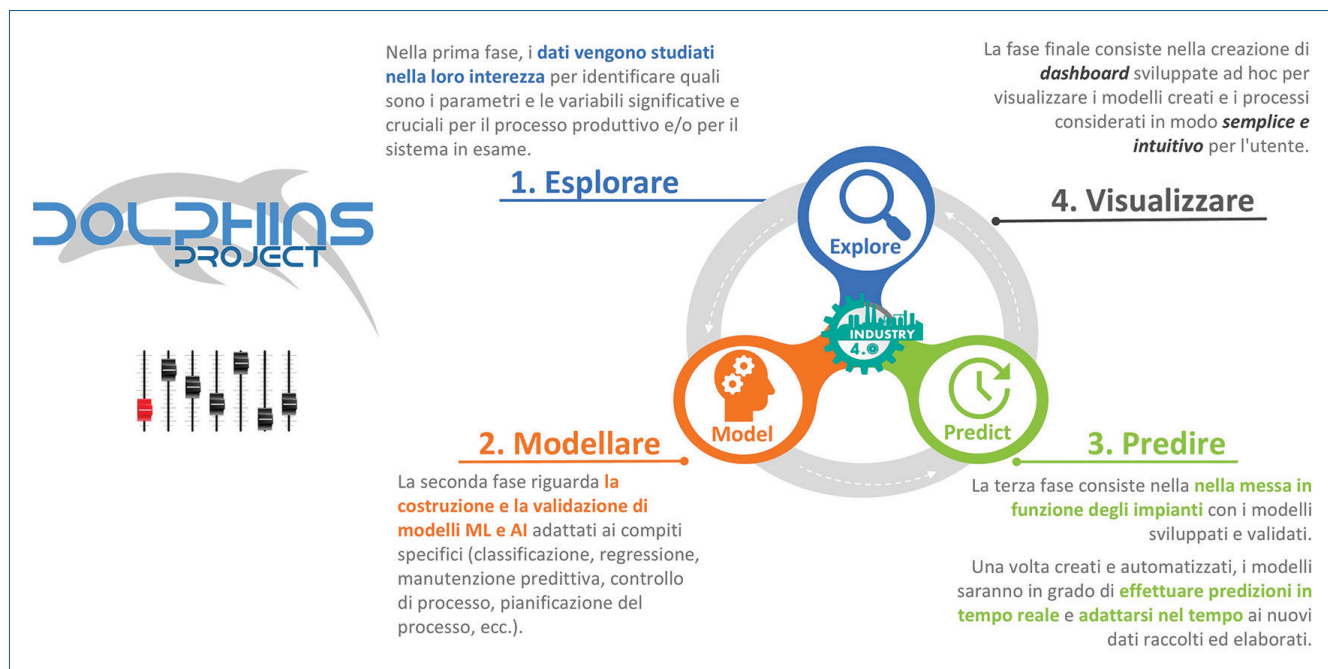


Fig. 1 - Schema del processo di manutenzione predittiva, basato su un approccio in quattro fasi

come, grazie all'analisi combinata dei dati storici e in tempo reale, sia possibile identificare anomalie nei processi produttivi, permettendo di prevedere guasti con largo anticipo e di ridurre significativamente il rischio di fermo macchina rappresentando i risultati attraverso dashboard intuitive (Fig. 1).

L'approccio impiegato nel progetto di manutenzione predittiva riportato si basa sull'uso di tecniche chemiometriche per estrarre informazioni dai dati raccolti [9]. L'analisi chemiometrica svolge infatti un ruolo centrale in questo contesto, consentendo di identificare tendenze e relazioni nascoste all'interno dei dati e cercando di massimizzare la capacità di previsione dei modelli messi a punto. In particolare, la chemiometria è una disciplina che applica metodi matematici, statistici (e informatici) all'analisi di dati chimici, con l'obiettivo di estrarre informazioni significative e migliorare l'interpretazione dei processi complessi. Sebbene le sue radici risalgano alla metà degli anni Sessanta, il termine "chemometrics" fu coniato da Svante Wold nel 1971; nel 1972, lo stesso Wold pubblicò il primo articolo scientifico contenente questo termine, mentre nel 1974, insieme a Bruce R. Kowalski, fondò l'International Chemometrics Society, formalizzando l'esistenza della disciplina come un settore autonomo di ricerca. Nonostante Wold e

Kowalski siano riconosciuti come i fondatori della chemiometria, molti altri ricercatori avevano già iniziato a sviluppare approcci computazionali all'analisi chimica. Tra questi, Edmund R. Malinowski, Peter C. Jurs e Désiré L. Massart furono tra i primi a pubblicare studi che oggi vengono considerati fondamentali per la chemiometria [10]. Lo sviluppo della chemiometria è stato guidato dall'evoluzione del calcolo scientifico e della strumentazione computerizzata, permettendo l'analisi rapida di grandi quantità di dati. Oggi la chemiometria è una disciplina consolidata, essenziale nella formazione di chimici analitici e *data scientist*. Il suo impiego si estende oltre alla chimica analitica, includendo la biotecnologia, la chimica clinica, la scienza dei materiali e l'industria chimica, dove si integra con il machine learning per migliorare affidabilità ed efficienza operativa. Tra i modelli più utilizzati figurano la Principal Component Analysis (PCA), la Partial Least Squares Discriminant Analysis (PLS-DA) e la Soft Independent Modeling of Class Analogy (SIMCA). La combinazione di PCA e SIMCA, come dimostrato nel progetto DOLPHINS, si è rivelata particolarmente efficace, poiché garantisce sensibilità e specificità elevate, consentendo di distinguere con precisione tra stati operativi normali e anomalie [9].



Il processo di analisi inizia con la raccolta dei dati dai PLC, che registrano i dati (*record*) del processo. I dati vengono poi pretrattati (*preprocessing*) attraverso filtraggio per rimuovere il rumore, quindi normalizzati per renderli comparabili e sottoposti a interpolazione o imputazione per la gestione dei dati mancanti. Una volta pretrattati, i dati vengono analizzati mediante PCA, una tecnica esplorativa non supervisionata (*unsupervised*) che permette di individuare le variabili più influenti nel determinare lo stato del sistema. La PCA consente infatti di trasformare i dati in un nuovo sistema di coordinate, riducendo la complessità e migliorando l'interpretabilità dei risultati [11]. Questo passaggio è fondamentale nella manutenzione predittiva, poiché permette di estrarre informazioni significative riducendo il rischio di *underfitting* e *overfitting* nei modelli predittivi successivi.

Per la classificazione delle condizioni operative del sistema vengono spesso impiegati modelli supervisionati (*supervised*) come, ad esempio, PLS-DA. Quest'ultima è una tecnica che combina regressione lineare e analisi discriminante, ottimizzando la separazione, nello specifico, tra le diverse classi di funzionamento dell'impianto. Questo modello è particolarmente utile quando i dati presentano forte correlazione tra le variabili indipendenti, come spesso accade nei sistemi industriali complessi [12].

Un ruolo fondamentale è stato svolto da SIMCA, approccio supervisionato di modellamento di classe (*class modelling*) che viene utilizzato per modellare separatamente ciascuna classe operativa. Nel contesto della manutenzione predittiva, SIMCA permette di definire regioni di accettabilità per le normali condizioni operative di un impianto e di identificare deviazioni dal comportamento atteso. Se un nuovo dato si discosta significativamente dal modello costruito, il sistema è in grado di segnalare una possibile anomalia, fornendo un'indicazione precoce di un potenziale guasto imminente [13].

Un aspetto essenziale nella costruzione di modelli affidabili è la fase di validazione e cross-validazione, necessaria per testare la robustezza delle previsioni. Vengono applicate tecniche di cross-validazione come *k-fold*, ad esempio, in cui il dataset viene suddiviso in più sottoinsiemi (pari ad un numero uguale a *k*) per garantire che il modello sia testato su set di dati di volta in volta differenti; si riduce così il rischio di *overfitting* e si migliora la generalizzazione del modello.

Nel caso del progetto DOLPHINS, l'integrazione di questi modelli ha portato a un miglioramento significativo nella capacità di previsione di guasti. Grazie a un approccio basato su PCA e SIMCA (Fig. 2), il sistema è stato in grado di identificare anomalie con una precisione superiore al 90%, riducendo

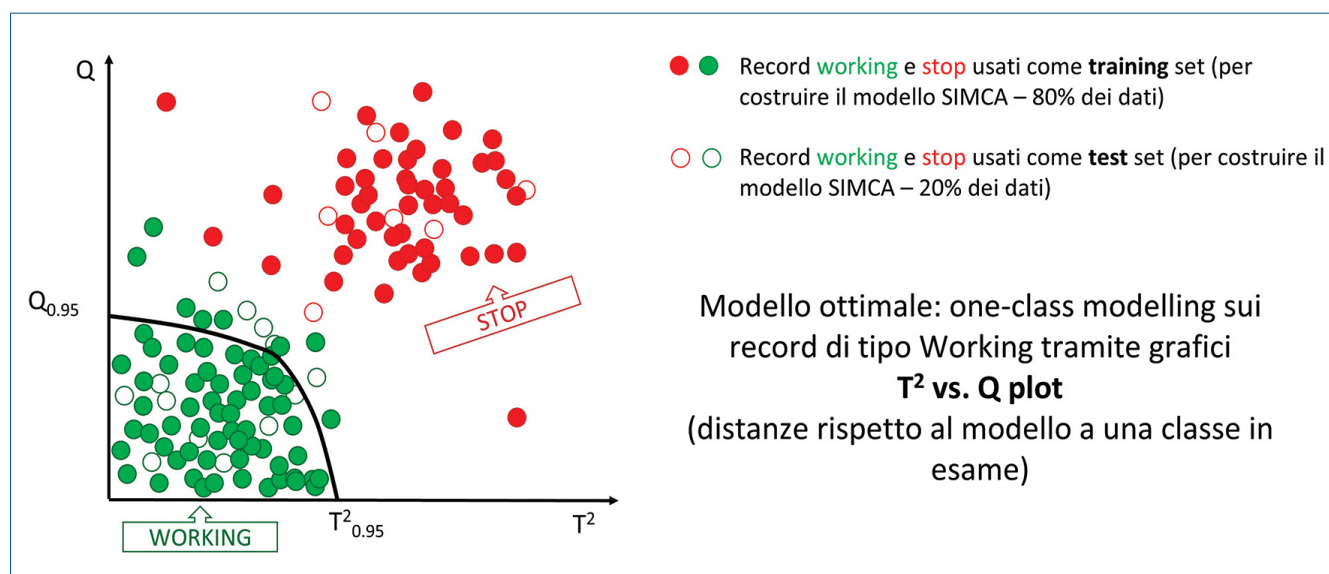


Fig. 2 - Grafico del modello messo a punto per la manutenzione predittiva. I punti verdi rappresentano lo stato di funzionamento normale (*working*), mentre i punti rossi indicano situazioni di anomalia o guasto (*stop*)

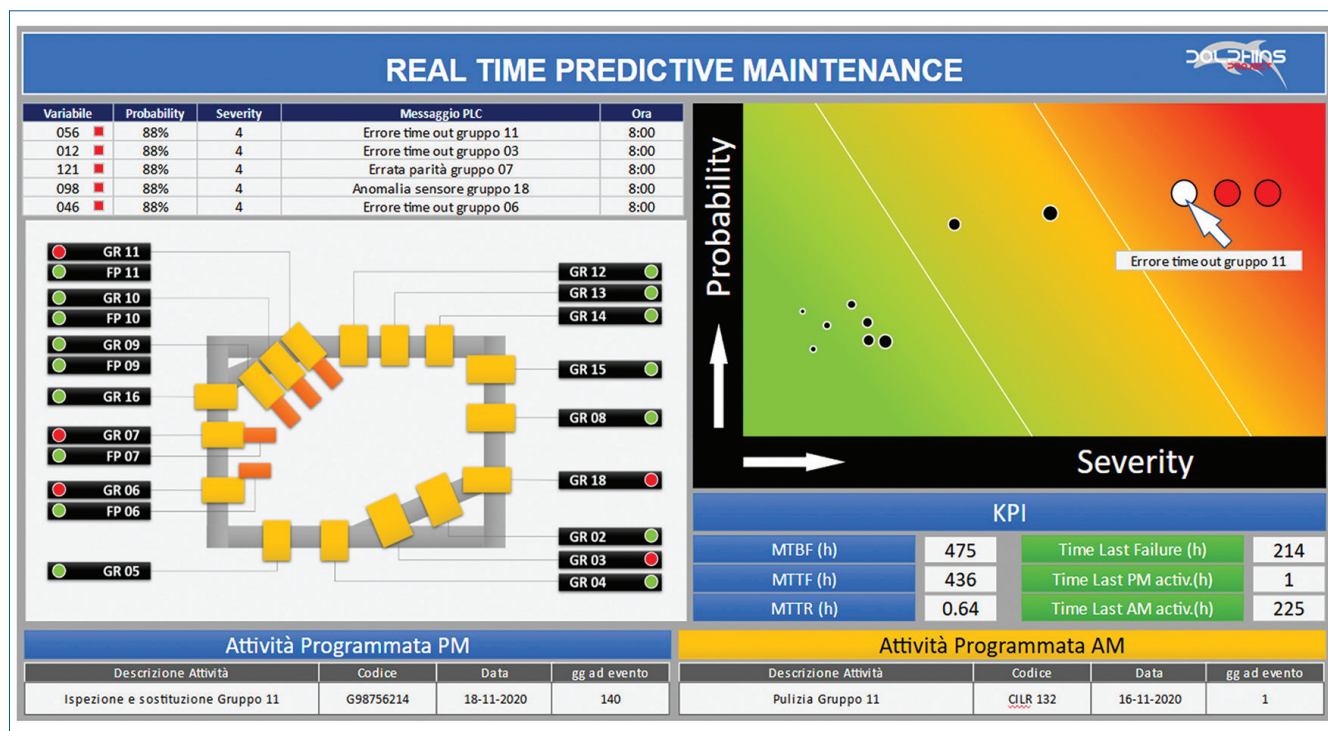



Fig. 3 - Dashboard di manutenzione predittiva in tempo reale del progetto DOLPHINS, che mostra lo stato degli impianti e le probabilità di guasto per diverse variabili di sistema. La tabella in alto riporta gli errori rilevati con le relative probabilità e severità. A sinistra, la mappa grafica degli impianti evidenzia lo stato operativo dei gruppi (verde: funzionante, rosso: errore). A destra, un grafico di probabilità e severità visualizza il rischio di guasti imminenti, con un'interfaccia interattiva per l'analisi dettagliata

drasticamente il numero di guasti imprevisti. Le prestazioni del sistema migliorano costantemente grazie all'aggiornamento continuo dei dati raccolti quotidianamente e, inoltre, le indicazioni sugli interventi da eseguire vengono fornite con un anticipo compreso tra 30 minuti e 3 ore prima che si verifichi un guasto, permettendo azioni tempestive ed efficaci.

Il cuore del progetto DOLPHINS è l'integrazione di modelli predittivi avanzati con sistemi di acquisizione dati già presenti negli impianti industriali, evitando la necessità di installare nuovi sensori e riducendo così i costi di implementazione. L'approccio sfrutta modelli statistici multivariati e chemiometrici per identificare deviazioni dalle condizioni operative normali e fornire indicazioni precise sugli interventi manutentivi da eseguire. Grazie a questa metodologia, infatti, è risultato possibile non solo prevenire guasti, ma anche ottimizzare la gestione dei ricambi e ridurre al minimo gli sprechi di risorse. Nel dettaglio, il progetto ha portato a risultati concreti e misurabili: l'introduzione della manu-

tenzione predittiva basata su DOLPHINS ha infatti ridotto il numero di guasti imprevisti, aumentando al contempo la produttività e riducendo i tempi di fermo macchina (Fig. 3).

Oltre alla riduzione dei tempi di inattività, il sistema sviluppato dal progetto DOLPHINS consente di migliorare la sicurezza degli impianti, riducendo il rischio di incidenti dovuti a guasti improvvisi. Inoltre, l'ottimizzazione dei processi produttivi porta a una riduzione del consumo energetico e a un impatto ambientale minore, in linea con le attuali esigenze di sostenibilità dell'industria moderna. Grazie all'elevata scalabilità del sistema, l'approccio DOLPHINS può essere applicato a una vasta gamma di settori industriali, tra cui industria chimica, manifatturiera, automobilistica e farmaceutica, rappresentando un esempio concreto di come la manutenzione predittiva possa migliorare l'efficienza e la sostenibilità dei processi produttivi. Questo tipo di approccio, vincitore del premio Manufacturing Leadership Award 2021 nella categoria Artificial Intelligence and Data Analytics, evidenzia



il ruolo chiave della ricerca accademica nell'innovazione industriale, dimostrando come la collaborazione tra università e aziende possa portare allo sviluppo di soluzioni tecnologiche avanzate con un impatto diretto sul miglioramento dell'operatività industriale.

La manutenzione predittiva basata su machine learning e chemiometria sta rivoluzionando la gestione degli impianti industriali, riducendo i costi operativi, migliorando l'affidabilità dei processi e aumentando la sicurezza. L'integrazione con deep learning permetterà analisi più avanzate, rendendo questi sistemi ancora più precisi e adattivi [14].

Questo approccio trova applicazione in diversi settori, tra cui automotive, industria chimica, manifatturiero e farmaceutico. Nel settore chimico, ad esempio, il monitoraggio predittivo di reattori e pompe migliora la stabilità dei processi e riduce il rischio di anomalie. Nel manifatturiero, consente di anticipare malfunzionamenti e ottimizzare la produzione, mentre in ambito farmaceutico aiuta a mantenere elevati standard di qualità minimizzando deviazioni nei parametri produttivi.

Un'innovazione chiave è rappresentata dai *Digital Twin*, repliche virtuali degli impianti che simulano il loro comportamento in condizioni operative reali. L'integrazione con la manutenzione predittiva consente di analizzare scenari ipotetici, migliorare la pianificazione degli interventi e ridurre costi e tempi di fermo. L'adozione di queste tecnologie segna un passo verso un'industria più affidabile, efficiente e sostenibile. Le ricerche attuali mirano a perfezionare l'integrazione tra modelli predittivi e Digital Twin, creando ambienti virtuali realistici per testare strategie di manutenzione prima della loro applicazione [15, 16].

Con l'avanzare dell'AI e la diffusione dell'IoT, la manutenzione predittiva diventerà sempre più autonoma, permettendo ai sistemi produttivi di adattarsi dinamicamente alle variazioni operative, migliorando efficienza, automazione e sostenibilità.

Bibliografia

- [1] C. Enyoghasi, F. Badurdeen, *Resour. Conserv. Recycl.*, 2021, **166**, 105362.
- [2] S. Sajid, A. Haleem, S. Bahl *et al.*, *Mater. Today Proc.*, 2021, **45**, 4898.
- [3] G. M. Sang, L. Xu *et al.*, *Front. Big Data*, 2021, **4**, 663466.
- [4] A. Samuels, *Front. Artif. Intell.*, 2024, **7**, 1477044.
- [5] A.K. Tyagi, S. Dananjayan *et al.*, *Sensors*, 2023, **23**, 947.
- [6] S. Grabowska, S. Saniuk *et al.*, *Scientometrics*, 2022, **127**, 3117.
- [7] Z. Li, C. Jana, *et al.*, *Alexandria Eng. J.*, 2025, **120**, 561.
- [8] N.H. Abd Wahab, K. Hasikin *et al.*, *PeerJ Comput. Sci.*, 2024, **10**, e1943.
- [9] E. Alladio, M. Baricco *et al.*, *Front. Chem.*, 2021, **9**, 734132.
- [10] R.G. Brereton, *J. Chemom.*, 2014, **28**, 749.
- [11] R. Bro, A.K. Smilde, *Anal. Methods*, 2014, **6**, 2812.
- [12] D. Ballabio, V. Consonni, *Anal. Methods*, 2013, **5**, 3790.
- [13] R. Vitale, M. Cocchi *et al.*, *Anal. Chim. Acta*, 2023, **1270**, 341304.
- [14] M. Elsisì, M.Q. Tran *et al.*, *Sensors*, 2021, **21**, 1038.
- [15] M. Iqbal, S. Suhail *et al.*, *Internet of Things*, 2025, **30**, 101514.
- [16] E. Dong, X. Zhan *et al.*, *Comput. Ind. Eng.*, 2025, **201**, 110868.

A Predictive Maintenance Example

The application of machine learning and chemometrics in predictive maintenance enhances process monitoring by identifying early signs of equipment failure, reducing operational costs and unexpected downtime. This approach relies on historical data collected from PLCs and the use of advanced multivariate models to analyze system performance trends, detect anomalies, and predict potential failures with high accuracy. By implementing predictive maintenance strategies, industries can improve efficiency, extend the lifespan of critical machinery, and optimize maintenance scheduling. The integration of AI-driven models in process control ensures more reliable operations, minimizing disruptions and maximizing productivity.