

Intelligenza Artificiale e Machine Learning nei Sistemi Industriali di Manutenzione

Giuseppe Manco, Ettore Ritacco, Luigi Pontieri, Luciano Caroprese,
Fabrizio Lo Scudo, Francesco Folino.

ICAR - Istituto di Calcolo e Reti ad Alte Prestazioni
{nome.cognome}@icar.cnr.it

Abstract

Tra i temi di spicco nell'ambito della Smart Industry 4.0, mettiamo in risalto gli aspetti relativi alla Process Intelligence, alla Smart Production e alla Workplace Safety. L'idea è quella di definire modelli di supporto ai sistemi industriali sotto svariati aspetti, portando ad un effettivo miglioramento della produzione in sé, di tutti quei processi satelliti che ruotano intorno ad essa, nonché della condizione dei lavoratori. Il lavoro svolto dal team ha evidenziato come l'Intelligenza Artificiale possa rappresentare un potente motore negli ambiti selezionati, tramite la definizione di diverse soluzioni specifiche che possano essere di facile trasferimento tecnologico dal mondo accademico a quello dell'industria.

1 Introduzione

L'attuale mondo dell'industria è soggetto ad una serie di requisiti che nascono dalle leggi e dalle dinamiche di mercato. Ci sono due forti spinte alla base della definizione o aggiornamento dei processi di produzione: da una parte c'è una richiesta di miglioramento costante della competitività nei settori industriali aggrediti, dall'altra la completa ottemperanza della legislatura vigente in materia di sostenibilità, sicurezza e diritto del lavoro. La capacità di definire e realizzare processi automatizzati di controllo ed intervento, il cui obiettivo è soddisfare le due suddette direttrici, rappresenta un challenge per il mondo della ricerca ma al tempo stesso una grande opportunità per l'industria di spingersi oltre gli attuali limiti.

L'ottimizzazione dei processi di produzione e la loro manutenzione sono due delle principali attività che possono portare al miglioramento richiesto. Entrambe mirano a limitare la perdita di risorse, tempo ed energie nella produzione industriale, e vedono nell'Intelligenza Artificiale un potente alleato per la definizione di soluzioni sempre più efficienti.

L'Intelligenza Artificiale è giunta ad un livello di maturità tale da consentirle di penetrare i diversi livelli del processo di produzione industriale. Può, infatti, supportare la produzione in sé, offrendo forti vantaggi in termini di impiego di risorse, personale e tempo, può definire meccanismi di quality management, fornendo accurati sistemi di verifica di qua-

lità dei prodotti, e può entrare in aiuto all'ecosistema della produzione, arrivando persino ai singoli lavoratori.

Infatti, un aspetto che deve caratterizzare ogni realtà aderente ai paradigmi dell'Industria 4.0 è la *sicurezza degli operatori sul posto di lavoro*. I moderni processi produttivi devono mirare alla rilevazione ed alla prevenzione di incidenti, infortuni, situazioni di potenziale pericolo e violazioni alle politiche di sicurezza (safety policy) definite dall'azienda o dal legislatore.

2 Linee di ricerca emergenti

2.1 Workplace safety

La finalità di questa linea di ricerca consiste nello studio di modelli di intelligenza artificiale integrabili nel processo produttivo ed a supporto della sicurezza degli operatori sul posto di lavoro.

Questi modelli sono alimentati da un insieme di sensori installati su dispositivi indossabili e nell'ambiente di lavoro che inviano flussi di dati telemetrici relativi ai principali parametri vitali del soggetto monitorato e ad un insieme di grandezze fisiche.

I dati telemetrici provenienti sono elaborati dai modelli di intelligenza artificiale per derivare informazioni relative a:

- lo stato di salute del soggetto provvisto dei dispositivi indossabili. I sensori dei dispositivi acquisiscono i dati telemetrici relativi ai principali parametri vitali del soggetto monitorato (temperatura corporea, frequenza cardiaca, ecc.) permettendo di rilevarne tempestivamente valori anomali (eventualmente causati da un malessere);
- monitorare l'interazione del soggetto provvisto dei dispositivi indossabili con l'ambiente in cui opera. I dati rilevati dai sensori del dispositivo (giroscopio, bussola, magnetometro, prossimità, luminosità, ecc.) sono processati al fine di rilevare eventi pericolosi per il soggetto: cadute accidentali, traumi da taglio/schiacciamento, movimenti troppo bruschi, svenimenti, tachicardie, ecc.;
- monitoraggio dell'ambiente lavorativo attraverso l'utilizzo di un insieme di sensori IOT che rilevano i dati telemetrici relativi ad un insieme di grandezze fisiche (es. temperatura, pressione, luminosità, umidità, movimento, audio, video, ecc.) allo scopo di rilevare eventi potenzialmente pericolosi per il lavoratore (rottura di parti meccaniche, combustioni, allagamenti, ecc);

- monitoraggio dell'ambiente di lavoro attraverso l'utilizzo di un insieme di sensori IOT allo scopo di assicurare il rispetto delle politiche di sicurezza (safety policy) definite dall'azienda o dal legislatore (indossaggio di caschi protettivi, presenza di un numero minimo/massimo di soggetti in particolari ambienti, ecc.). Un caso particolare è rappresentato dal monitoraggio dei Dispositivi per la Protezione Individuale (DPI).

2.2 Smart Production

I processi produttivi dell'industria moderna possono beneficiare dei risultati dell'Artificial Intelligence (AI) sotto vari aspetti. Già in passato si è affermata la tematica dell'ottimizzazione dei processi produttivi (tematica tuttora viva e dinamica), ma grazie alle nuove tecnologie AI si stanno affacciando nuove possibilità. In particolare, vogliamo porre l'attenzione su tre aree di ricerca che offrono forti spinte di miglioramento nel settore della produzione industriale: *Anomaly Detection*, *Generative Modeling* e *Quality Control via Machine Learning*.

L'Anomaly Detection è quella linea di ricerca il cui scopo è la definizione di modelli di individuazione di anomalie, ovvero eventi o fenomeni inattesi e rari, immersi e nascosti in grandi moli di dati che rappresentano il normale comportamento del comparto di produzione. La scoperta delle anomalie porta con sé un grande vantaggio nei processi industriali, poiché mette in risalto quali siano gli errori o le bad habits nella produzione. In base ai vari contesti e modelli di anomaly detection, si è in grado di rispondere alle seguenti domande:

- Si è verificata un'anomalia?
- Quando si verificherà un'anomalia?
- Quali sono le cause dell'anomalia?
- E quali gli effetti?

Com'è facile intuire, l'utilizzo di una tale soluzione ha una ricaduta immediata nel già citato contesto della manutenzione predittiva, dove un guasto corrisponde ad una anomalia particolare.

Generative Modeling. Ormai è chiaro a tutti che l'esplosione di internet e l'informatizzazione del mondo dell'industria ha portato ad un aumento esponenziale del quantitativo di dati che può essere analizzato dai sistemi di AI. Nonostante ciò, ancora ad oggi, le grandi moli di dati generate sono carenti di semantica, ovvero di quelle informazioni necessarie per risolvere problemi di alto livello.

Ad affrontare il problema interviene il Generative Modeling che ha l'obiettivo di definire modelli di generazione di dati. In base alle diverse soluzioni algoritmiche, un modello generativo consente la creazione di dati sintetici, simili al contesto industriale che si vuole simulare, ai quali è possibile anche associare della semantica. Ciò permette quindi l'uso di dati verosimili e ricchi semanticamente per l'addestramento di modelli di AI, che siano essi supervisionati o no.

Quality Control via Machine Learning. Il controllo di qualità (QC) è una fase fondamentale del processo di produzione, ma spesso viene effettuato in forma manuale, gravando pesantemente sui tempi di produzione e costi di lavorazione.

In questi ultimi tempi, l'AI sta offrendo la possibilità di definire strumenti automatici o semi-automatici per ottimizzare il QC. Alcuni settori specifici del Machine Learning, come ad esempio il Machine Vision, possono supportare o sostituire il lavoro umano attraverso l'introduzione di alcuni moduli software che possono effettuare un diligente controllo di qualità.

2.3 Human-centric process intelligence

La crescente diffusione di sistemi di sensoristica e di tracciatura di azioni/eventi consente ormai alle imprese e filiere del mondo industriale di raccogliere, in modo continuo, una vasta collezione di informazioni sull'esecuzione dei propri processi operativi e organizzativi. Queste "tracce digitali" dei processi potrebbero essere sfruttate per comprenderli, monitorarli e analizzarli e gestirli in modo da ottimizzarne le prestazioni, la qualità, il grado di allineamento agli obiettivi di business e alle norme. A questo scopo si potrebbero sfruttare gli svariati tipi di metodi sviluppati nel campo del "Process Mining"[van der Aalst, 2016], il cui scopo generale è proprio estrarre informazioni e modelli per un processo, a partire da sue tracce digitali. Alcuni importanti consolidate tipi di tecniche di Process Mining riguardano: (a) la scoperta automatica di modelli di processo di facile comprensione (process discovery), (b) l'identificazione, la quantificazione e l'analisi di deviazioni fra il comportamento atteso/prescritto di un processo ed il suo comportamento effettivo (conformance analysis) e (c) la predizione e l'ottimizzazione a run-time del comportamento di istanze di processo in corso di esecuzione (predictive/prescriptive process monitoring).

Tuttavia, due principali ostacoli ancora frenano l'adozione di tali metodi in molti contesti reali: (A) la bassa qualità dei dati disponibili, che spesso corrispondono a tracce digitali eterogenee (corrispondenti a processi o varianti di processo differenti), low-level (gli step di esecuzione non sono esplicitamente associati ad attività/eventi facilmente interpretabili) e/o incomplete (coprono parte dei comportamenti possibili del processo); (B) la pipeline process mining includono solitamente l'applicazione di componenti automatiche black-box che non consentono di interpretare e giustificare i risultati ottenuti né di integrare conoscenza di dominio.

Questa linea di ricerca mira a definire nuovi approcci di process mining per il settore Industria 4.0 che alleviano le problematiche menzionate sopra, sfruttando sia conoscenza a-priori sul comportamento del processo, espressa in modo dichiarativo, per favorire lo scambio di informazioni e la collaborazione fra utenti e componenti automatiche, sia meccanismi per l'interpretazione dei dati e dei risultati ottenuti. A tale scopo, questa linea sfrutta due tipi di descrizioni simboliche delle esecuzioni dei processi: 1) rappresentazioni astratte di ogni traccia digitale, che consentano di interpretare la traccia stessa come sequenza di istanze di tipi predefiniti di attività/eventi di interesse per l'analisi; 2) modelli dichiarativi (es., espressi tramite regole logiche) del comportamento noto del processo o di ipotesi formulate dagli utenti, volte a fornire conoscenza di dominio utile ad incrementare la qualità e la trasparenza dei risultati di process mining.

3 Risultati di ricerca

3.1 Audio-based Anomaly Detection on Edge Devices via Self-Supervision and Spectral Analysis

Il team di ricerca ha sviluppato un modello di Machine Learning capace di individuare la presenza di anomalie nell'ambiente di lavoro analizzando uno stream audio proveniente da microfoni ambientali.

L'idea su cui si basa è quella che un ambiente in una certa fascia oraria è caratterizzato da pattern audio che si ripetono nel tempo (es. un ufficio nel pomeriggio sarà caratterizzato da molti click provenienti da dispositivi di puntamento e da tastiere, dal rumore di stampanti e da qualche conversazione dai toni pacati).

Il modello apprende, con un approccio non supervisionato, questi pattern ed impara a riconoscere nuovi pattern mai rilevati prima (es. un urlo, la rottura di un oggetto, ecc.). Questi ultimi corrispondono a situazioni anomale che vanno notificate al supervisore.

Questo approccio è particolarmente interessante perché è basato su un apprendimento di tipo non supervisionato. Non è dunque necessario disporre di un dataset etichettato (normalmente difficile da reperire). Sarà sufficiente lasciare il modello in ascolto, per un periodo di tempo sufficientemente lungo, nell'ambiente che si desidera monitorare. Lo stream audio rilevato servirà per addestrare il modello. Dopo questa fase, il modello potrà essere utilizzato per rilevare le anomalie.

L'architettura utilizzata sfrutta una rete neurale di tipo Autoencoder. Al fine di ridurre la quantità di dati necessari durante la fase di addestramento è stato eseguito un processo di transfer learning da modelli per la classificazione di eventi audio ben noti in letteratura.

3.2 Tecniche di process mining abstraction-aware per l'analisi di tracce digitali low-level

Il team ha ideato varie soluzioni per supportare analisi di process mining su tracce digitali "low-level" (cioè tracce che consistono di record che non contengono alcun riferimento esplicito ai tipi di eventi/attività che gli esperti tendono naturalmente a considerare nella modellazione e nell'analisi del comportamento del processo).

In particolare, il team ha sviluppato un framework [Fazzinga *et al.*, 2020] per l'individuazione di tracce devianti (security breach), che integra due tipologie di metodi, usati tradizionalmente in modo indipendente e alternativo: (i) metodi di conformance checking model-driven basati sulla specifica di modelli di comportamento dichiarativi, espressi da esperti di dominio in termini di attività di alto livello e (ii) metodi di machine learning capaci di indurre modelli di classificazione da un insieme di tracce digitali annotate manualmente da esperti come esempi di comportamento normali o devianti. Il framework si basa sull'idea di classificare ogni traccia τ come deviante o normale combinando, tramite uno schema di meta-classificazione, sia le predizioni ottenute applicando a τ modelli appresi da esempi di tracce low-level sia le predizioni ottenute applicando i modelli specificati in termini di attività astratte ad un campione rappresentativo delle possibili

interpretazioni di τ come sequenze di attività, generato con una procedura Montecarlo ad hoc.

Al fine di supportare un'analisi esplorativa delle possibili interpretazioni degli step di una traccia low-level come istanze di esecuzione di tipi predefiniti di attività è stato definito un sistema argumentation-based [Fazzinga *et al.*, TO APPEAR] che consente all'analista sia di sottoporre interattivamente vari tipi di "interpretation query" per individuare quali siano le possibili sia di richiedere spiegazioni sul perché una certa interpretazione non sia stata ritenuta valida dal sistema. Al fine di valutare la validità delle interpretazioni, il sistema sfrutta conoscenza esplicita sui tipi di attività (in termini delle cui esecuzioni si vuole interpretare ogni traccia) e sulle dipendenze causali/temporali che sono note esistere fra tali attività. Nella loro forma più semplice, le interpretation query permettono di formulare richieste del tipo "si può interpretare un certo record della traccia come step iniziale di un'istanza di esecuzione di una certa attività A?". Varianti più espressive di query possono essere formulate introducendo costrutti di proiezione e di enumerazione di tutte le interpretazioni valide. Dal punto di vista tecnico, l'interpretazione degli step di una traccia è modellato come una disputa attraverso un Abstract Argumentation Framework (AAF), in modo da trasformare il calcolo delle interpretazioni valide e delle spiegazioni di invalidità in istanze specifiche del problema AAF acceptance (per la cui risoluzione possono essere riutilizzati solver consolidati ed efficienti). Questo approccio AAF-based supporta un paradigma interattivo di analisi di tracce di processo digitali, in cui l'analista e il sistema AI ragionano in modo collaborativo (scambiandosi e valutando argomenti e ipotesi), migliorando progressivamente sia la qualità delle interpretazioni delle tracce sia la completezza della conoscenza di dominio espressa in modo esplicito.

3.3 Anomaly Generation

In real-world scenario, anomalies are rare events, thus they are often not sufficient to define the prediction patterns necessary for any classification technique. Liguori *et al.* (2021b) propose a new methodology, called Adversarial Reconstruction Network (ARN), to identify existing anomalies without the need of having information about them. ARN exploits the idea of the Variational Autoencoders [9] and the Generative Adversarial Networks [8]. Its peculiarity lies in its data generation approach: For each normal sample the model builds its abnormal counterpart, i.e. a realistic outlier that is similar to the normal sample but differs from it for minimal but substantial differences. Thus, the generation of realistic outliers enables the learning of an outlier detector that is able to identify existing anomalies, without the need of being fed with explicit information about them. ARN is evaluated on several real-world datasets by showing that (i) the generated anomalies are realistic, as they resemble the original data, but they exhibit some specific features that the detector (i.e. the discriminator in the adversarial game) can recognize; (ii) the proposed anomaly detector improves the current state-of-art methods, is robust to noise and is easily adaptable to weak supervision.

3.4 Predictive Maintenance

Nell'ambito della manutenzione predittiva, il team ha sviluppato diverse soluzioni specifiche di Machine Learning in contesti non supervisionati. La prima di esse [Manco *et al.*, 2017] sfrutta una semplice assunzione di base: i guasti, nella maggior parte dei settori di produzione e servizi, sono eventi estremamente rari. Ciò implica che i dataset messi a disposizione sono rappresentativi delle diverse modalità di normalità operativa, il che significa che i dati permettono di comprendere ed evidenziare, con buona precisione, il comportamento atteso dei sistemi industriali. Le modalità di normalità non sono altro che cluster che raggruppano diversi eventi simili di lavorazione: la vicinanza di tali eventi al cuore del cluster è inversamente legata alla loro probabilità di essere un guasto. Di conseguenza un guasto è un evento al di fuori di tutti i cluster di normalità o al più risiede nella periferia di uno di essi. Quindi, un guasto può essere individuato tramite un approccio mirato di clustering-based anomaly detection: la soluzione proposta, infatti, è una variante del classico algoritmo di Expectation Maximization. Diversa è la soluzione proposta in [Alfeo *et al.*, 2020], dove viene utilizzata un'architettura Autoencoder. L'idea di base è simile alla precedente, ovvero addestrare il modello a comprendere e replicare le modalità di normalità operativa. In questo caso, l'incapacità di un Autoencoder di replicare correttamente un evento corrisponde ad una segnalazione di guasto. Per sua natura, l'Autoencoder è addestrato a rigenerare il dato fornitogli in input; ciò implica che il modello, se ben appreso, sarà in grado di replicare il database di training che, come già detto, quasi sempre rappresenta il comportamento normale: ciò implica che l'Autoencoder apprende come replicare la normalità. Nel momento in cui l'input corrisponde ad un evento di guasto (un'anomalia), l'Autoencoder, piuttosto che cercare di replicarlo in output, cercherà di trasformarlo in qualcosa simile alla normalità. La divergenza tra l'input e l'output è quindi un indicatore di guasto.

4 Attività Progettuali

4.1 True Detective 4.0

Il progetto ha come obiettivo primario l'implementazione prototipale di una piattaforma in grado di integrare strumenti e servizi intelligenti per il monitoraggio pervasivo e in tempo reale per la Manutenzione Predittiva di apparati, per l'Ottimizzazione dei Processi Produttivi e di Automazione Industriale e per la Gestione della Sicurezza Fisica in Ambito Aziendale.

4.2 Map4Id

Nel progetto Map4Id, il team ha utilizzato le tecniche di Machine Vision per verificare se la realizzazione di quadri elettrici industriali fosse conforme con i relativi schemi tecnici di progettazione. La soluzione prodotta si basa sul confronto tra una foto frontale del pannello elettrico assemblato ed il disegno del blueprint. L'architettura prevede tre componenti:

- una rete neurale dedicata all'Object Detection dei componenti del pannello elettrico;

- un sistema di "traduzione" dell'immagine del pannello (arricchita delle informazioni della precedente rete) e del blueprint in un linguaggio comune
- confronto e verifica (nel linguaggio) tra immagine e blueprint.

4.3 PINPOINT (PRIN 2020)

Il progetto PINPOINT ("exPlaInable kNowledge-aware PrOcess INTElligence") intende sviluppare un insieme integrato di tecniche per explainable knowledge-aware process intelligence. Il progetto si concentra su due filoni di ricerca. Il primo filone consiste nell'estendere gli approcci di process mining con conoscenza di background (espressa possibilmente con formalismi logici espressivi), al fine di informare e guidare i task di process mining e migliorarne la qualità, l'efficacia e l'interpretabilità dei loro risultati. Il secondo filone mira ad aumentare la trasparenza delle pipeline di process mining e l'interpretabilità dei loro risultati, tramite la definizione di meccanismi per modellare e tracciare tutti gli step di trasformazione dei dati e per spiegare/giustificare perché un certo risultato sia stato prodotto da un task di process mining (es., perché un modello predittivo abbia ritornato una certa predizione o quale sia la root cause di una violazione di conformance). Il progetto coinvolge 5 unità (UNIBZ, UNICAL, UNIMIB, UNIROMA1, oltre a ICAR-CNR) e prevede la sperimentazione delle tecniche sviluppate anche in un contesto di logica industriale.

Riferimenti bibliografici

- [Alfeo *et al.*, 2020] Antonio L. Alfeo, Mario G. C. A. Cimino, Giuseppe Manco, Ettore Ritacco, e Gigliola Vaglini. Using an autoencoder in the design of an anomaly detector for smart manufacturing. *Pattern Recognit. Lett.*, 136:272–278, 2020.
- [Fazzinga *et al.*, 2020] Bettina Fazzinga, Francesco Folino, Filippo Furfaro, e Luigi Pontieri. An ensemble-based approach to the security-oriented classification of low-level log traces. *Expert Syst. Appl.*, 153:113386, 2020.
- [Fazzinga *et al.*, TO APPEAR] Bettina Fazzinga, Sergio Flesca, Filippo Furfaro, e Luigi Pontieri. Process mining meets argumentation: Explainable interpretations of low-level event logs via abstract argumentation. *Information Systems*, TO APPEAR.
- [Manco *et al.*, 2017] Giuseppe Manco, Ettore Ritacco, Pasquale Rullo, Lorenzo Gallucci, Will Astill, Dianne Kimber, e Marco Antonelli. Fault detection and explanation through big data analysis on sensor streams. *Expert Syst. Appl.*, 87:141–156, 2017.
- [van der Aalst, 2016] Wil M. P. van der Aalst. *Process Mining - Data Science in Action, Second Edition*. Springer, 2016.