



**Politecnico
di Torino**

POLITECNICO DI TORINO
Corso di Laurea in Ingegneria Gestionale

Tesi di Laurea Magistrale

*Studio di tecniche di Machine Learning per il controllo
di qualità nei processi manifatturieri.*

Relatore
Maurizio Galetto
Gianfranco Genta
Stefano Puttero

Candidato
Tommaso Raffaele Bonetto

A.A. 2024/2025
Sessione di laurea luglio 2025

Sommario

1. Introduzione	5
1.1 Transizione da Industria 4.0 a 5.0	6
1.2 Il nuovo ruolo della qualità nella produzione	7
1.3 L'importanza del controllo qualità e la sua evoluzione	8
1.5 Obiettivo e Struttura dell'elaborato	10
Capitolo 2	12
2. Industria 5.0 e il nuovo concetto di qualità	12
2.1 Industria 5.0: definizione e differenze rispetto all'Industria 4.0	12
2.2 Il nuovo concetto di qualità nei processi manifatturieri e la sua importanza	14
2.3 Metodi tradizionali: le carte di controllo	16
2.3.1 <i>Suddivisione delle carte di controllo: per variabili e per attributi</i>	18
2.3.2 <i>Ipotesi e criticità delle carte di controllo</i>	23
2.4 I limiti delle carte di controllo tradizionali ad oggi	24
2.5 La necessità di integrare le tecniche di <i>ML</i> al controllo qualità	25
Capitolo 3	28
3. L'adozione delle tecniche di <i>Machine Learning</i> per il Controllo Qualità	28
3.1 Cos'è il <i>ML</i> e perché è rilevante nei processi manifatturieri	28
3.1.1 <i>Il funzionamento del ML nel controllo qualità</i>	25
3.2 Tipologie di modelli di <i>ML</i> applicabili al controllo qualità	30
3.2.1 <i>Apprendimento supervisionato</i>	31
3.2.2 <i>Apprendimento non supervisionato</i>	32
3.2.3 <i>Apprendimento per rinforzo</i>	32
3.2.4 <i>Reti neurali e Deep Learning</i>	33
3.3 Quali sono i vantaggi e gli svantaggi delle carte di controllo basate sul <i>ML</i>	34
3.4 Considerazioni finali sul <i>ML</i> per il controllo qualità	37
Capitolo 4	38
4. Le carte di controllo basate su <i>ML</i>	38
4.1 Tipologia delle carte di controllo	38
4.1.1 <i>Carte predittive</i>	38
4.1.2 <i>Carte adattive</i>	35
4.1.3 <i>Carte per classificazione</i>	41
4.1.4 <i>Carte non-supervisionate</i>	42
4.1.5 <i>Carte ibride</i>	44
4.1.c <i>Carte neurali</i>	4c

4.2 Gli Algoritmi di ML per le carte di controllo	51
4.2.1 Support Vector Machines (SVMs).....	52
4.2.2 Random Forest	55
4.2.3 Deep Learning e Reti Neurali	5c
Capitolo 5	61
5. Risultati e Implicazioni della ricerca.....	61
5.1 Principali risultati emersi.....	61
5.2 Implicazioni pratiche	62
5.2.1 Azioni concrete per innovare il controllo qualità.....	63
5.2.2 Cambiamenti a livello organizzativo	c4
5.2.3 Nuove competenze e strumenti richiesti	c4
5.3 Analisi economica dell'adozione del ML nel controllo qualità	65
5.4 Limiti della ricerca	67
5.5.1 Sfide nell'adozione delle tecniche di ML.....	c8
5.5 Spunti per sviluppi futuri.....	68
5.5.1 Ricerca applicativa su carte ML avanzate	c8
5.5.2 Integrazione con strumenti dell'Industria 5.0	c5
5.5.3 Evoluzione normativa e certificazione della qualità	c5
Conclusione.....	71
Bibliografia.....	73

Indice delle figure

<i>Figura 1: L'evoluzione Industriale</i>	12
<i>Figura 2: Caratteristiche principali dell'Industria 5.0</i>	13
<i>Figura 3: Esempio di una Carta di Controllo</i>	17
<i>Figura 4: Rappresentazione grafica di un iperpiano delle SVM</i>	53
<i>Figura 5: Rappresentazione schematica di una rete neurale</i>	57
<i>Figura c: Rappresentazione schematica di una rete neurale artificiale</i>	58

Indice delle tabelle

<i>Tabella 1: Caratteristiche principali delle carte per variabili</i>	20
<i>Tabella 2: Caratteristiche principali delle carte per attributi</i>	22
<i>Tabella 3: Principali fasi del ML nel controllo qualità</i>	30
<i>Tabella 4: Diverse modalità di apprendimento dei dati</i>	33
<i>Tabella 5: Sintesi SPC vs. ML</i>	3c
<i>Tabella c: Caratteristiche principali delle carte di controllo basate su ML</i>	48
<i>Tabella 7: Vantaggi e Svantaggi delle carte di controllo basate su ML</i>	4S
<i>Tabella 8: Esempi di Algoritmi e ipotesi delle carte di controllo basate su ML</i>	50
<i>Tabella S: Contesto applicativo delle carte basate su ML</i>	c3
<i>Tabella 10: Vantaggi economici e produttivi</i>	c7

Capitolo 1

1. Introduzione

Il presente elaborato nasce dall'interesse di approfondire le trasformazioni che stanno coinvolgendo i sistemi produttivi con il passaggio dall'industria 4.0 all'Industria 5.0, focalizzandosi, in particolare, sulle implicazioni delle carte di controllo per la qualità nei processi manifatturieri. Difatti è evidente come in un contesto industriale sempre più dinamico, customizzato e orientato alla sostenibilità, gli strumenti tradizionali per il controllo della qualità, per quanto siano stati efficaci in passato, non riescono più a soddisfare le esigenze attuali.

Specialmente, le carte di controllo tradizionali, che rappresentano un elemento fondamentale per il controllo statistico dei processi industriali per la qualità, presentano diversi limiti strutturali e tecnici come la loro mancanza di adattabilità e capacità predittiva, soprattutto se utilizzate in contesti caratterizzati da un'alta variabilità, produzione personalizzata e rapide fluttuazioni nei parametri di processo. Tali condizioni, sempre più presenti nei sistemi manifatturieri odierni, richiedono strumenti più avanzati, in grado di integrare l'analisi dei dati in tempo reale e di apprendere in maniera automatica e autonoma.

Alla luce di quanto appena delineato, l'obiettivo di questa tesi è quello di analizzare come le tecniche di machine learning possano rivoluzionare il controllo qualità nei processi produttivi. L'intento è stato quello di focalizzarsi sull'evoluzione delle carte di controllo, orientandosi verso modelli predittivi, adattivi e intelligenti. Si vuole quindi esaminare le principali tipologie di carta basate sul machine learning, valutandone i loro vantaggi e svantaggi rispetto ai metodi tradizionali, e approfondire le condizioni necessarie per una loro implementazione in un contesto produttivo.

L'interesse per questo argomento nasce dalla crescente importanza del *machine learning* come strumento strategico per il miglioramento continuo, la riduzione degli scarti, l'ottimizzazione dei processi e la prevenzione dei difetti. Infatti l'adozione delle carte di controllo basate sul machine learning permette un monitoraggio flessibile, fornendo un supporto decisionale avanzato anche in caso di dati complessi. Tuttavia l'adozione di questi strumenti richiede non solo investimenti tecnologici ma anche un cambiamento culturale interno, l'acquisizione di nuove competenze e una maggiore integrazione tra le diverse funzioni aziendali.

Il presente lavoro dunque si propone di contribuire all'approfondimento relativo al controllo qualità affiancata all'innovazione tecnologica, in particolare al *machine learning*. Una riflessione in cui la qualità non è più solo concepita come una questione di misurazione e conformità, ma diventa un elemento strategico in grado di generare valore in termini di efficienza, affidabilità e sostenibilità.

1.1 Transizione da Industria 4.0 a 5.0

Negli ultimi decenni l'industria manifatturiera è stata oggetto di una serie di trasformazioni significative, ognuna delle quali ha apportato un cambiamento radicale nelle modalità di produzione, nei modelli organizzativi e nell'interazione tra uomo e macchina. Queste trasformazioni sono state scandite da diverse fasi evolutive, ognuna identificata con il termine di "rivoluzione industriale". Dalla meccanizzazione introdotta dall'Industria 1.0 - che ha segnato la nascita della produzione meccanica grazie all'energia a vapore - si è passati all'elettrificazione e alla produzione di massa dell'Industria 2.0, per poi giungere alla rivoluzione digitale dell'Industria 3.0, caratterizzata dall'introduzione dell'elettronica e dell'informatica nei processi produttivi. Con l'avvento dell'Industria 4.0, abbiamo assistito all'integrazione delle tecnologie digitali avanzate, come l'*Internet of Things* (IoT), il *Cloud computing*, i *Big Data* e l'intelligenza artificiale, orientate a creare fabbriche intelligenti altamente automatizzate ed efficienti [1].

Oggi assistiamo all'inizio di una nuova era: l'Industria 5.0. L'attuale rivoluzione industriale non si limita ad aumentare l'efficienza produttiva, ma persegue obiettivi più ampi e ambiziosi. L'Industria 5.0 mira, infatti, a umanizzare la tecnologia, riportando l'essere umano al centro del processo produttivo attraverso una stretta collaborazione con l'intelligenza artificiale. Si tratta di una visione che valorizza l'intelligenza umana, la creatività, l'intuizione e l'esperienza, integrandole con le capacità computazionali e operative dei sistemi automatizzati.

Una delle caratteristiche fondamentali dell'Industria 5.0 è la sinergia tra uomo e macchina, in particolare grazie ai cosiddetti *cobot* (robot collaborativi), progettati per lavorare a fianco degli operatori umani, in un ambiente lavorativo progettato per esser più sicuro e cooperativo. In questo contesto, l'intelligenza artificiale e le tecnologie emergenti non sostituiscono l'uomo ma, al contrario, lo affiancano e lo aiutano consentendogli di

concentrarsi su compiti più strategici e ad alto valore aggiunto, mentre le macchine si occupano delle attività più ripetitive, pericolose o faticose [2].

Un altro elemento distintivo di questa nuova rivoluzione industriale è la personalizzazione di massa, ovvero la capacità di produrre beni personalizzati su larga scala, consentendo di adattarsi in maniera flessibile alle specifiche esigenze dei singoli clienti. Ciò è reso possibile grazie all'impiego di tecnologie avanzate, la produzione modulare e i sistemi di produzione intelligenti, capaci di adattarsi rapidamente alle variazioni della domanda e alle diverse esigenze, con costi e tempi competitivi.

L'Industria 5.0 si caratterizza, inoltre, per una marcata attenzione alla sostenibilità ambientale. A differenza delle rivoluzioni precedenti, dove il progresso tecnologico era spesso perseguito a discapito delle risorse naturali e dell'ambiente, oggi la sfida è quella di conciliare innovazione e responsabilità ecologica. Per questa ragione si ricorre sempre più frequentemente all'uso di tecnologie *green* e approcci di produzione circolare, come lo *smart additive manufacturing*, che permettono di ridurre gli sprechi di materiale, ottimizzare l'uso delle risorse e minimizzare l'impatto ambientale lungo tutto il ciclo di vita del prodotto.

Mentre l'Industria 4.0 ha puntato su automazione, efficienza e interconnessione tra macchine, l'Industria 5.0 introduce una nuova dimensione che riporta l'essere umano ad avere un ruolo centrale e in cui la tecnologia diventa uno strumento al servizio dell'uomo e del pianeta.

L'industria del futuro è quindi un luogo dove idealmente competenze umane e tecnologie digitali si fondono armoniosamente, dando vita a un ecosistema produttivo intelligente, sostenibile e su misura per ogni individuo.

1.2 Il nuovo ruolo della qualità nella produzione

Il passaggio dalla *mass production* alla *mass customization* ha ridisegnato in maniera significativa il concetto di qualità. Se in passato la qualità era vista soprattutto come conformità ai requisiti standard, attualmente il suo ruolo si sta orientando verso la capacità di adattarsi ai bisogni specifici del singolo cliente, senza però compromettere l'efficienza produttiva.

Come osservato da Pine (1933), la *mass customization* viene definita come un modello che unisce l'efficienza della produzione di scala con la produzione su misura, favorendo così la

realizzazione di prodotti customizzati secondo le richieste singole dei clienti, a costi sostenibili per le imprese. Conseguentemente, questo modello richiede sistemi di produzione altamente flessibili, nonché una tipologia di produzione capace di adattarsi rapidamente alle variazioni della domanda [3].

Pertanto, in tale contesto, è evidente come la qualità non sia più solo un attributo fisso da verificare al termine del processo produttivo, ma un elemento dinamico che coinvolge l'intera catena di produzione. Garantire la qualità nella *mass customization* significa saper rispondere in modo tempestivo alle esigenze individuali dei consumatori, rispettando al tempo stesso standard di qualità elevati e costanti e costi contenuti. Chiaramente ciò assume un significato anche nella gestione della qualità che - invece di limitarsi solamente al controllo del prodotto finale - deve essere applicata a tutti gli *step* richiesti dal processo produttivo di un determinato prodotto o servizio. A tal proposito diventa fondamentale la capacità di prevedere in anticipo le esigenze del cliente.

L'impiego di tecnologie avanzate gioca un ruolo cruciale in questo contesto. Tra tutte, quella più rilevante è l'intelligenza artificiale che, assieme ad altri strumenti digitali, permette di monitorare in tempo reale i processi produttivi, intervenendo preventivamente per evitare deviazioni o anomalie ed ottimizzando così le prestazioni stesse della produzione. Tali tecnologie sono fondamentali affinché si abbia una produzione incentrata sulla customizzazione dei prodotti che - al tempo stesso - sia efficiente, flessibile e orientata alla qualità. A ciò si aggiunge l'importanza della raccolta e analisi dei dati, fondamentale per il miglioramento continuo consentendo di raggiungere una conoscenza più approfondita.

Qualità e innovazione risultano essere sempre più indipendenti. In un contesto in cui i bisogni dei consumatori evolvono rapidamente, la capacità di garantire soluzioni su misura mantenendo però standard elevati, richiede un costante aggiornamento dei dati, dei prodotti e delle competenze. La qualità, quindi, non è solo conformità dei prodotti, ma un fattore importante per l'innovazione e la differenziazione del prodotto stesso.

1.3 L'importanza del controllo qualità e la sua evoluzione

Tradizionalmente il controllo qualità si è sempre basato sull'utilizzo di metodi statistici, come le carte di controllo, al fine di monitorare la variabilità dei processi produttivi. È utile, però, sottolineare come le carte di controllo sono state sviluppate per contesti relativamente stabili e standardizzati, risultando particolarmente efficaci per la *mass production*. Tuttavia

in un sistema produttivo come quello attuale, che si sta sempre di più orientando verso una produzione più personalizzata che tiene conto delle esigenze dei singoli consumatori, l'applicazione di tali strumenti rivela diversi limiti strutturali.

Per poter garantire una maggiore efficacia delle carte di controllo, quest'ultime presuppongono una certa omogeneità e ripetitività del processo produttivo condizioni che, chiaramente, non è possibile riscontrare nei cicli di produzione caratterizzati da un'elevata variabilità del processo stesso. Difatti, come anche delineato da Montgomery (2012), le carte di controllo risultano essere meno efficaci nel rilevare anomalie in tempo reale e, in particolare, nel prevedere difetti in processi ove è richiesta maggiore flessibilità e customizzazione del prodotto [4].

In uno scenario come quello attuale è richiesto un approccio più dinamico e proattivo, in modo tale superare i limiti delle carte di controllo tradizionali e adottare una metodologia che sia predittiva e, al tempo stesso, adattiva. Occorre integrare le carte di controllo con tecnologie avanzate, in particolare di *ML* e intelligenza artificiale. Tali strumenti permettono di analizzare i dati in tempo reale, rilevare *pattern* complessi ed eventuali anomalie non riscontrabili tramite le carte tradizionali, anticipando il verificarsi di difetti, riducendo gli scarti e migliorando in generale l'efficienza produttiva.

È noto, infatti, come l'impiego di tecniche di *ML* abbia implementato l'efficacia delle carte di controllo nel monitoraggio nei processi manifatturieri industriali. Diversi studi hanno analizzato come queste tecniche abbiano trasformato radicalmente il controllo qualità nei sistemi produttivi, passando da un approccio statistico e poco variabile ad una visione predittiva e dinamica. Ciò consente di anticipare e correggere le anomalie prima che queste si verifichino ed influenzino negativamente il prodotto finale. L'adozione di tali tecnologie per il controllo della qualità permette di adattare in tempo reale i parametri produttivi alle specifiche esigenze del cliente, favorendo una maggiore flessibilità e reattività. Tali caratteristiche sono fondamentali se si vuole adottare una produzione personalizzata su larga scala, garantendo simultaneamente elevati standard qualitativi [5].

A conti fatti l'integrazione del *ML* permette una maggiore sensibilità, una riduzione dei falsi allarmi e una migliore adattabilità a scenari reali e dinamici, aprendo nuove prospettive per lo sviluppo dello *Statistical Process Control (SPC)* [6].

Di conseguenza è importante evidenziare come tale trasformazione non ha un impatto solo ed esclusivamente tecnologico, ma anche organizzativo e culturale. L'introduzione di metodi

tecnologici avanzati per il controllo qualità richiede nuove competenze e una maggiore integrazione tra le diverse aree funzionali aziendali, come produzione e IT. In tal senso, il controllo qualità non è più una funzione a sé stante, ma diventa parte integrante del sistema produttivo e strategico dell'impresa.

1.5 Obiettivo e Struttura dell'elaborato

Questa tesi si inserisce nel contesto della transizione verso l'Industria 5.0, un momento di forte cambiamento in cui la tecnologia non è più solo sinonimo di automazione, ma diventa uno strumento al servizio delle persone. In questo scenario ho scelto di concentrarmi su come il machine learning, una delle tecnologie oggi più rilevanti, possa affiancarsi e potenziare uno degli strumenti più tradizionali e consolidati del controllo qualità: le carte di controllo. L'obiettivo è mostrare come innovazione e tradizione possano dialogare, evolvendosi insieme per rispondere alle nuove sfide dell'industria moderna.

Per affrontare questo tema, si è scelto un approccio analitico ma accessibile, fondato su una lettura critica e comparativa delle fonti scientifiche e industriali più recenti. Si è voluto capire non solo “cosa funziona”, ma anche “perché”, “in che contesto” e “con quali implicazioni”. Ogni capitolo è pensato come una tappa di un percorso, costruito con l'intento di accompagnare chi legge in un ragionamento chiaro, progressivo e fondato.

Nel secondo capitolo è stato delineato il contesto in cui ci muoviamo oggi, ripercorrendo brevemente le rivoluzioni industriali e arrivando al cuore dell'Industria 5.0, dove il fattore umano torna centrale, senza rinunciare alla potenza della tecnologia. Da qui nasce anche una nuova idea di qualità, più ampia, che include non solo l'efficienza tecnica, ma anche il benessere, la sostenibilità e l'impatto sociale.

Il terzo capitolo si concentra proprio su questa nuova concezione della qualità e su ciò che oggi non funziona più nei modelli tradizionali di controllo. Le carte di controllo classiche, nate in un'epoca molto diversa, mostrano limiti evidenti quando si trovano a operare in ambienti produttivi instabili, complessi e fortemente personalizzati.

Il quarto capitolo introduce il *machine learning*, spiegando con parole semplici – ma senza perdere rigore – come funziona, quali tipi esistono, e perché è particolarmente adatto al mondo industriale. Nel quinto capitolo ho approfondito le nuove carte di controllo basate su ML: predittive, adattive, neurali, capaci di affrontare problemi che i metodi tradizionali non

riescono più a gestire. Ogni categoria viene spiegata attraverso logiche, algoritmi e vantaggi pratici.

Infine, l'ultimo capitolo raccoglie le riflessioni finali: cosa abbiamo capito, quali sono le ricadute operative, che tipo di trasformazione richiede tutto questo non solo nei sistemi, ma anche nella cultura aziendale, nell'organizzazione, nei ruoli e nella formazione. Ho cercato di mettere in evidenza come il controllo qualità possa diventare qualcosa di molto più grande: non solo uno strumento per evitare errori, ma un motore per migliorare in modo continuo, umano e sostenibile.

Con questa tesi, si vuole contribuire a una visione del controllo qualità che guardi avanti. Una visione in cui l'intelligenza artificiale non è una minaccia per il sapere umano, ma un suo alleato. Dove i dati non sostituiscono l'esperienza, ma la potenziano. E dove l'innovazione non si misura solo in bit o algoritmi, ma anche nella capacità di ascoltare, adattarsi e creare valore aggiunto, per le imprese e per le persone.

Capitolo 2

2. Industria 5.0 e il nuovo concetto di qualità

2.1 Industria 5.0: definizione e differenze rispetto all'Industria 4.0

L'evoluzione dell'industria a partire dalla metà del '700 ad oggi può essere riassunta in cinque grandi fasi, come mostrato in Figura 1.

L'Industria 1.0 ha segnato l'inizio della meccanizzazione grazie all'energia a vapore, avviando così la prima produzione industriale. Con l'Industria 2.0 è stato introdotto l'utilizzo dell'elettricità che ha portato alla nascita della produzione di massa. La terza rivoluzione, l'Industria 3.0, è stata caratterizzata dall'automazione dei processi, grazie all'elettronica e all'informatica. L'Industria 4.0 ha rivoluzionato il panorama industriale mediante la digitalizzazione e l'interconnessione dei sistemi, dando vita così alle cosiddette *smart factory*. Infine l'Industria 5.0 rappresenta il nuovo paradigma emergente, dove la tecnologia è al servizio dell'essere umano, favorendo la collaborazione tra uomo e macchina, la personalizzazione dei prodotti e la sostenibilità ambientale.

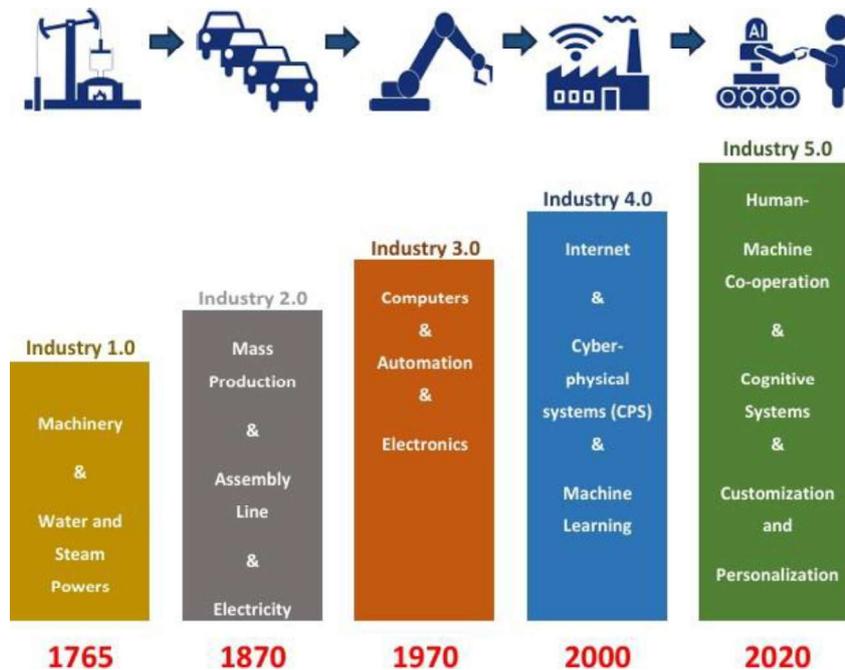


Figura 1: L'evoluzione Industriale

L'industria 5.0 rappresenta un'evoluzione sostanziale rispetto all'Industria 4.0, affermandosi come modello produttivo più efficace, sostenibile e centrato sulla figura umana. Se l'Industria 4.0 si è focalizzata sull'automazione e sull'efficienza produttiva mediante l'integrazione di tecnologie avanzate, come l'*Internet of Things* (IoT), i *big data* e l'intelligenza artificiale, l'Industria 5.0 - proprio a partire da questi concetti - espande la propria visione introducendo nuovi obiettivi che riguardano l'importanza della figura umana e l'impatto ambientale e sociale [7].

Con l'affermarsi dell'Industria 5.0 si è passati ad un modello industriale che mette al centro la resilienza, la sostenibilità e la centralità dell'essere umano, come si vede in Figura 2.



Figura 2: Caratteristiche principali dell'Industria 5.0

In questo scenario la tecnologia non è più solo vista come un modo per incrementare la produttività, ma diventa un mezzo per ampliare e amplificare le capacità umane, favorendo la collaborazione tra uomo e macchina. L'Industria 5.0 si propone, infatti, di trovare un equilibrio tra il progresso tecnologico e il benessere sociale, tra automazione e personalizzazione e tra crescita economica e responsabilità ambientale.

Una delle differenze principali rispetto al modello 4.0 è l'inversione di prospettiva. Mentre nella quarta rivoluzione industriale l'attenzione era rivolta verso l'intelligenza tecnologica, nella quinta rivoluzione il focus si sposta sull'intelligenza umana. Le tecnologie non sono più viste come sostitutive dell'uomo, ma come alleate che lo supportano e lo completano, orientandosi verso una collaborazione sinergica. L'obiettivo, quindi, non è più solo produrre

di più e meglio, ma produrre in modo più sostenibile, flessibile e significativo, sia per le imprese che per la società.

L'Industria 5.0 mette in primo piano temi come la personalizzazione di massa, la sostenibilità ambientale e l'inclusività sociale, rendendoli parte integrante della strategia industriale. A livello pratico, ciò si traduce in *smart factory* dove robot collaborativi (i cosiddetti *cobot*) e sistemi predittivi lavorano a fianco dei lavoratori, valorizzando così le competenze umane e alleviando il carico fisico e mentale [8].

In sintesi mentre l'Industria 4.0 ha fondato le basi per l'automazione avanzata e l'interconnessione dei processi, l'Industria 5.0 rappresenta un passo evolutivo verso una coesistenza tra uomo e macchina. È una visione che non solo cambia il modo di produrre, ma ridefinisce anche il significato stesso della produzione in un'economia globale che si vorrebbe sempre più attenta ai valori umani e alla sostenibilità.

2.2 Il nuovo concetto di qualità nei processi manifatturieri e la sua importanza

Il controllo qualità è una funzione fondamentale per garantire il corretto funzionamento e la competitività nei processi manifatturieri. La sua importanza va ben oltre la semplice rilevazione e correzione dei difetti di produzione. La qualità gioca un ruolo chiave in quello che rappresenta la soddisfazione per i consumatori finali, sulla reputazione del marchio, sull'efficienza dei processi e sulla sostenibilità economica e ambientale dell'impresa.

Dal punto di vista pratico, un controllo qualità ben strutturato permette di individuare tempestivamente le deviazioni dagli standard attesi, riducendo il rischio di rilavorazioni, scarti, fermi dell'impianto o resi da parte dei clienti. Tutto ciò si traduce in costi diretti inferiori, maggiore equilibrio e stabilità nella produzione e affidabilità. In settori altamente specializzati o regolamentati, come quello aerospaziale, l'automotive e il farmaceutico, la capacità di mantenere costantemente elevati standard di qualità, è un requisito fondamentale per la conformità alle normative e per poter vendere i propri prodotti sul mercato.

Il concetto di qualità è sempre stato un elemento chiave nei processi di produzione, ma nel corso del tempo la sua interpretazione e il suo ruolo hanno subito cambiamenti significativi,

adattandosi alle diverse evoluzioni influenzate dal cambiamento del contesto produttivo e tecnologico. In epoca preindustriale la qualità era convenzionalmente legata all'abilità individuale dell'artigiano e alla rispondenza a standard talvolta soggettivi. Con la rivoluzione industriale e l'avvento della produzione di massa si è invece affermata una visione più oggettiva e standardizzata della qualità, che si basa sulla conformità dei prodotti ad alcuni requisiti tecnici stabiliti in anticipo, ossia a priori.

Con l'introduzione del *SPC* intorno al 1920 - grazie anche al contributo di studiosi come Shewhart - il controllo qualità è diventato un processo sistematico e misurabile, focalizzato sul monitoraggio e sulla riduzione della variabilità nei processi. In tal modo la qualità era concepita come il risultato di un modello ben sviluppato, dove l'intervento umano si limitava spesso a monitorare e, eventualmente, a correggere le anomalie. L'Industria 4.0 ha rivoluzionato ulteriormente questo tema, introducendo una serie di tecnologie in grado di rilevare, analizzare e correggere deviazioni in tempo reale. L'integrazione di sensori *Iot*, (dispositivi incorporati in oggetti fisici, che raccolgono dati dall'ambiente circostante e li trasmettono ad altri dispositivi o sistemi tramite internet), l'uso di *Big Data*, l'analisi predittiva e il *ML* hanno reso possibile introdurre un controllo qualità automatizzato e continuo. In questo nuovo scenario, la qualità non è più valutata soltanto dopo che si è manifestato l'errore, ma è costantemente monitorata e - grazie all'elaborazione di enormi quantità di dati - riesce ad anticipare i possibili difetti. Tuttavia nonostante l'efficienza e la precisione di questi strumenti, l'approccio che ne deriva dall'Industria 4.0 tende spesso a privilegiare gli aspetti tecnici e produttivi, trascurando la sfera della soggettività, quella dell'esperienza e quella sociale che riguardano la qualità [9].

Con l'avvento dell'Industria 5.0, il concetto di qualità si espande nuovamente, seguendo una visione più centrata sulla figura umana, sostenibile e resiliente che caratterizza questa nuova fase di evoluzione. La qualità non è più percepita solo come l'assenza di difetti o la conformità a determinati requisiti tecnici, ma come la capacità complessiva del sistema produttivo di creare valore per i consumatori, l'ambiente e la società. In un contesto come quello appena descritto, la qualità diventa un concetto più ampio, che include [10]:

- la qualità tecnica, che si riferisce alla precisione e alla robustezza del prodotto;
- la qualità esperienziale, che concerne la personalizzazione del prodotto o servizio e la soddisfazione del cliente;
- la qualità ambientale, legata alla sostenibilità dei processi e al ciclo di vita del prodotto;

- la qualità sociale, che riguarda la responsabilità etica e l'impatto sulle condizioni lavorative e sulla società.

Altro aspetto fondamentale è il ruolo dell'uomo. Nell'Industria 5.0, la qualità si costruisce attraverso l'interazione tra operatori umani e sistemi intelligenti. Gli operatori non sono più semplici esecutori, ma assumono un ruolo chiave nel processo qualitativo, grazie alle loro capacità di interpretare, adattare e innovare. Pertanto, in un processo produttivo automatizzato, l'intervento umano si rivela particolarmente prezioso e utile, in particolare in quei processi che richiedono un alto grado di creatività e flessibilità. La collaborazione tra uomo e macchina, supportata da mezzi come i cobot, permette di raggiungere una qualità più flessibile, reattiva e centrata sul preposto. Dunque, nel contesto della produzione personalizzata, la qualità diventa sempre più una questione soggettiva e relazionale. Non si tratta solo di garantire che un prodotto rispetti le specifiche tecniche, ma anche di soddisfare le aspettative individuali del cliente, offrendo un valore percepito al consumatore. In tal modo, il controllo qualità si trasforma in uno strumento di dialogo tra l'impresa e il mercato [11].

In conclusione nel contesto dell'Industria 5.0 la qualità non è più solo un attributo del prodotto o un semplice indicatore di performance, ma è diventata un valore strategico. Questa guida le decisioni progettuali, influisce sul rapporto con i clienti, orienta le decisioni operative e definisce l'etica dell'impresa nel mercato globale. Ad oggi, investire in qualità significa costruire un sistema produttivo che riesca ad unire efficienza, innovazione, benessere e responsabilità.

2.3 Metodi tradizionali: le carte di controllo

Le carte di controllo tradizionali, introdotte da Walter A. Shewhart negli anni '20 del secolo scorso, rappresentano uno degli strumenti fondamentali per il controllo statistico della qualità. L'obiettivo principale di queste carte di controllo è quello di monitorare la variabilità di un processo produttivo nel tempo, distinguendo la variabilità naturale - che è intrinseca al processo - da quella attribuibile ad anomalie e guasti.

Una carta di controllo si compone di tre elementi principali: una linea centrale, che rappresenta il valore medio del parametro monitorato, e due limiti. Un limite superiore (UCL – *Upper Control Limit*) e un limite inferiore (LCL – *Lower Control Limit*), calcolati

sulla variabilità pregressa del processo. Se i dati raccolti rientrano in questi limiti, allora il processo viene considerato in controllo statistico, altrimenti scatta l'allarme di anomalia [12]. Tuttavia, nonostante la loro efficacia, le carte di controllo presentano alcune criticità, soprattutto se applicate a contesti tecnologici e moderni come quelli attuali, caratterizzati da un'elevata complessità, variabilità e personalizzazione. Queste carte presuppongono condizioni di processo stabili e stazionarie, caratteristiche che sono difficilmente sostenibili in contesti reali ad alta variabilità, come quelli legati alla *mass customization*.

Inoltre, come detto in precedenza, le carte tradizionali sono di natura reattiva, ossia rilevano l'anomalia solo dopo che questa si è manifestata. In assenza di capacità predittive queste carte non consentono di anticipare i difetti, limitandone così il loro uso. In contesti come quelli di oggi ad alta dinamicità, la rigidità dei limiti di controllo basati su medie storiche può generare diversi falsi allarmi o, al contrario, non rilevare i difetti.

Come delineato precedentemente, una carta di controllo è composta da tre elementi principali, come mostrato nella sottostante Figura 3:



Figura 3: Esempio di una Carta di Controllo

- una linea centrale (CL) che indica il target, ossia il valore medio atteso della caratteristica misurata
- un limite superiore di controllo (UCL)
- un limite inferiore di controllo (LCL)

Questi limiti vengono calcolati in base alla variabilità storica del processo e aiutano a distinguere le fluttuazioni normali, causate dalla variabilità intrinseca del processo, da

quelle anomale dovute da fattori anormali. Quindi se i punti tracciati rimangono all'interno dei due limiti, il processo viene considerato statisticamente sotto controllo mentre se i punti escono da questi due limiti, allora è necessario individuare la causa di tale instabilità, dal momento stesso che il processo non è più statisticamente in controllo [13].

L'uso delle carte tradizionali offre numerosi vantaggi nell'ambito del controllo qualità, in particolare per quei processi produttivi che sono standardizzati e caratterizzati da un'elevata ripetitività, tra i quali:

- monitorare in modo sistematico i processi produttivi: le carte di controllo offrono una sorveglianza costante del processo, rendendo più facile individuare eventuali variazioni nel tempo;
- identificare prontamente eventuali anomalie: uno dei principali vantaggi di questo strumento è la sua capacità di mettere in evidenza segnali di instabilità o deviazioni significative rispetto al comportamento previsto del processo;
- evitare interventi inutili in presenza di variabilità naturale: la variabilità è una caratteristica intrinseca di qualsiasi processo produttivo. Le carte di controllo distinguono tra fluttuazioni normali e quelle anomale, evitando azioni correttive superflue;
- impostare azioni correttive basate su dati oggettivi e documentabili: le informazioni raccolte tramite le carte di controllo forniscono una base solida per prendere decisioni tecniche e gestionali.

L'efficacia delle carte di controllo si basa su una serie di ipotesi fondamentali che occorre rispettare per garantire risultati affidabili.

2.3.1 Suddivisione delle carte di controllo: per variabili e per attributi

Le carte di controllo si distinguono in due grandi categorie principali: carte per variabili e carte per attributi, in funzione del tipo di caratteristica monitorata durante il controllo del processo produttivo.

2.3.1.1 Carte per variabili

Le carte per variabili sono utilizzate quando la caratteristica di qualità da monitorare può essere misurata su una scala continua (ad esempio peso, lunghezza, spessore, temperatura,

ecc.). Questi dati consentono un'analisi quantitativa precisa e permettono di rilevare anche piccole variazioni nel processo.

Le principali carte di tale categoria includono:

- carta \bar{x} -R (media e range) utilizzata quando si ha a che fare con piccoli campioni (tipicamente da 2 a 10 unità), ove la carta \bar{x} monitora la stabilità della media del processo, mentre la R controlla la variabilità interna del campione.
- carta \bar{x} -s (media e deviazione standard) utilizzata con campioni di dimensioni maggiori, in quanto la deviazione standard fornisce una stima più robusta della dispersione rispetto al range.
- carta I-mR (individuali e range mobile) impiegata quando non è possibile prelevare campioni multipli e si dispone di singole osservazioni raccolte in sequenza temporale.

Dunque le carte per variabili, le cui caratteristiche principali sono delineate in Tabella 1, sono particolarmente utili per individuare cambiamenti lenti e progressivi nel processo. Sono più efficienti ed efficaci quando si hanno misurazioni dirette e affidabili a disposizione [14].

Tabella 1: Caratteristiche principali delle carte per variabili

Carte di Controllo Tradizionali					
	Tipo di Carta	Caratteristiche Principali	Vantaggi	Svantaggi	Esempi di Applicazione
VARIABILI	Carta \bar{X} - R	Monitora la media e la dispersione (il range) per piccoli lotti ($n \leq 10$).	Facile da usare, molto diffusa e consente di monitorare facilmente variazioni nel valore medio e nella variabilità.	Meno sensibile ai piccoli cambiamenti e range poco affidabile con campioni grandi e funziona bene se la variabile misurata si può approssimare ad una Normale.	Controllo diametro tappi di plastica in lotti di produzione da 5 campioni.
	Carta \bar{X} - S	Alternativa alla \bar{X} - R per campioni più grandi ($n > 10$). Usata in processi continui, monitora media e dev.std	Più precisa rispetto alla carta R per grandi campioni, anche perché la dev.std è più precisa e quindi più precisa a piccole variazioni.	Calcolo più complesso a causa della dev.std e non adatta a piccoli campioni.	Misurazione del diametro di cuscinetti a sfera di campioni di $n=20$ cuscinetti, in un processo continuo.
	Carta X-RM	Usata quando non si possono fare campioni: si misura una singola unità alla volta.	Utile per dati individuali e quando i campioni non sono praticabili (es. aereo)	Meno potente statisticamente; alta variabilità.	Monitoraggio della temperatura di un forno ogni ora.

2.3.1.2 Carte per attributi

Le carte per attributi, invece, sono impiegate tipicamente quando la caratteristica qualitativa monitorata non è una misura continua, ma un dato discreto o categoriale, come la presenza o assenza di un difetto, il numero di pezzi difettosi o la proporzione di difettosità. Queste carte si basano su campioni numerici e sono spesso utilizzate nei controlli visivi o funzionali. Le carte per attributi sono così suddivise:

- carta p: misura la proporzione di unità difettose in un campione variabile per dimensione.

- carta np: tiene il conteggio del numero assoluto di unità difettose in un campione di dimensione costante.
- carta c monitora il numero di difetti per unità, in contesti ovviamente dove è possibile avere più difetti sulla stessa unità (ad esempio ammaccature su una carrozzeria).
- La carta u: simile alla carta c, ma adattata per campioni di dimensione variabile, calcolando sempre il numero di difetti per unità

Sebbene le carte per attributi, come si vede in Tabella 2, richiedano meno tempo e meno risorse (non necessitano infatti di sofisticati strumenti di misura), esse offrono un livello di dettaglio inferiore rispetto alle carte per variabili, in quanto non sono in grado di rilevare variazioni minori nel processo e non forniscono informazioni dirette sull'entità del problema [15].

Tabella 2: Caratteristiche principali delle carte per attributi

Carte di Controllo Tradizionali					
	Tipo di Carta	Caratteristiche Principali	Vantaggi	Svantaggi	Esempi di Applicazione
ATTRIBUTI	Carta p	Controlla la proporzione di unità difettose (binaria: difettoso/non difettoso).	Adatta a campioni di dimensione variabile.	Meno sensibile per piccoli cambiamenti e range molto instabile.	Ispezione qualità su prodotti finiti (es. computer difettosi).
	Carta np	Simile alla carta p ma con campioni di dimensione n fissa; conta i difetti.	Facile da interpretare.	Meno flessibile (richiede campione fisso).	Numero di pezzi difettosi in una linea di imbottigliamento.
	Carta c	Conta il numero di difetti per unità (es. graffi su una superficie).	Buona per difetti multipli per unità.	Assume che l'area o volume di controllo sia costante.	Numero di difetti presenti su una superficie.
	Carta u	Come la c, ma standardizza il numero di difetti rispetto all'unità di misura.	Utile con unità di misura variabili.	Più difficile da interpretare.	Difetti per metro quadrato in tessuti.

Pertanto la scelta tra carte per variabili e per attributi dipende fondamentalmente dal tipo di processo che si vuole monitorare, dalla natura del dato disponibile e dal livello di sensibilità richiesto.

In generale, le carte per variabili sono preferibili quando è possibile misurare direttamente la qualità, mentre quelle per attributi sono da preferire quando si lavora con ispezioni visive o quando non è economicamente conveniente rilevare valori numerici. Tuttavia, nel contesto attuale, grazie all'integrazione di sistemi di raccolta dati in tempo reale e sensori digitali, le carte per variabili sono sempre più utilizzate, in quanto sono più compatibili con ambienti automatizzati e strumenti di analisi avanzati. Ciò nonostante, le carte per attributi restano

uno strumento valido ed economico per le attività di controllo in ambiti meno tecnologici in fasi iniziali della produzione.

2.3.2 Ipotesi e criticità delle carte di controllo

Come delineato precedentemente, le carte di controllo sono senza dubbio uno degli strumenti più solidi e consolidati nell'ambito del controllo statistico della qualità (*SPC*). Tuttavia si basano su alcune ipotesi teoriche che possono influenzare la loro efficacia e affidabilità. Quando queste condizioni non sono rispettate, cosa che accade sempre più frequentemente nei contesti produttivi odierni, si manifestano determinati limiti e criticità, che compromettono l'efficacia di queste carte di controllo. Le ipotesi fondamentali sono:

1. Stabilità del processo: si presume che il processo sia staticamente stabile, ossia che la sua media e la sua variabilità rimangano costanti nel tempo, a meno che non intervengano eventi straordinari. In contesti come quelli dell'Industria 5.0 ad alta personalizzazione, tale stabilità potrebbe non essere più garantita.
2. Indipendenza delle osservazioni: le osservazioni raccolte devono essere indipendenti l'una dall'altra, senza autocorrelazione. Nella realtà, tipicamente nei processi continui o in sistemi automatizzati con cicli ripetitivi, questa ipotesi viene spesso violata, portando ad un'interpretazione errata dei segnali.
3. Distribuzione normale dei dati: per quanto concerne le carte per variabili, queste si presuppongono che i dati seguano una distribuzione quanto più possibile normale. In un contesto reale ci sono molte situazioni, come ad esempio nel caso di limiti fisici o tecnici, in cui la distribuzione può risultare distorta, riducendo così l'efficacia della carta.
4. Omogeneità dei campioni: è di assoluta importanza che le unità osservate all'interno di ogni campione provengano dallo stesso processo e nelle stesse condizioni. Chiaramente però nella realtà diversi fattori come ad esempio cambi macchina, operatori diversi o variazioni nelle condizioni ambientali, possono portare ad una significativa eterogeneità nei dati.

Queste congetture, sebbene adeguate in contesti di produzione standardizzata e ripetitiva, perdono di validità nei moderni sistemi produttivi, caratterizzati da grande variabilità, personalizzazione e dinamicità. In queste situazioni, l'uso delle carte tradizionali potrebbe

causare frequenti falsi allarmi o, al contrario, portare ad una sottostima di deviazioni invece significative, limitandone così l'efficacia [16].

Quando queste ipotesi non vengono rispettate emergono diverse criticità operative come i *falsi positivi*, ossia segnalazioni di anomalie quando in realtà si tratta soltanto di variazioni naturali del processo. Al contrario, ci potrebbero essere i *falsi negativi* che si verificano quando non si è in grado di rilevare anomalie significative perché i dati non seguono la distribuzione prevista. Un'altra criticità è la *difficoltà di interpretazione*, vale a dire che in contesti con fattori molto variabili, il significato di un punto fuori controllo potrebbe risultare poco chiaro. Infine vi è un'*adattabilità ridotta*, dal momento che le carte tradizionali non riescono ad adattarsi in tempo reale ai cambiamenti strutturali o alle configurazioni dinamiche del processo.

A tal proposito, per le motivazioni delineate precedentemente, occorre che le carte di controllo siano affiancate, o in alcuni casi sostituite, da approcci più avanzati, che si basano su modelli predittivi, intelligenza artificiale e sistemi adattivi, capaci di gestire in tempo reale la complessità e la variabilità dei processi produttivi contemporanei.

2.4 I limiti delle carte di controllo tradizionali ad oggi

Dai paragrafi precedenti appare evidente come nel contesto odierno dell'Industria 5.0 la produzione manifatturiera stia subendo una trasformazione verso modelli più flessibili, personalizzati, interconnessi e sostenibili, dove l'interazione tra essere umani e tecnologie è il fulcro di questa evoluzione. In questo nuovo scenario le tradizionali carte di controllo mostrano diversi limiti strutturali, dal momento che erano state progettate all'epoca per ambienti industriali stabili, ripetitivi e con un basso livello di variabilità.

Uno dei principali limiti è la scarsa adattabilità delle carte di controllo in contesti di produzione caratterizzate da un'alta variabilità. Difatti, in settori dove si producono articoli unici o ci sono frequenti cambi di configurazione, diventa sempre più complicato accumulare una base di dati omogenea sufficiente a calcolare i limiti di controllo statisticamente significativi. Di conseguenza, il monitoraggio perde di affidabilità e sensibilità, portando a falsi allarmi o, al contrario, a non rilevare anomalie realmente esistenti.

Oltre tutto le carte di controllo non si integrano facilmente con i moderni sistemi produttivi, in cui i dati vengono raccolti in tempo reale da sensori Iot e analizzati attraverso algoritmi intelligenti. Tali sistemi richiedono strumenti di monitoraggio capaci di reagire dinamicamente, apprendere dai dati e adattarsi a condizioni operative in continuo mutamento. La logica rigida e statica delle carte tradizionali non consente di sfruttare completamente il potenziale informativo dei dati digitali e nemmeno di supportare decisioni proattive e predittive. Un ulteriore limite riguarda l'incapacità delle carte di controllo di cogliere e analizzare aspetti qualitativi, che non sono misurabili tramite strumenti e parametri tecnici. Infatti, ad oggi, la qualità si può definire multidimensionale e comprende aspetti come la qualità esperienziale, legata alla personalizzazione, oppure la qualità ambientale o, ancora, la qualità sociale che concerne il benessere degli operatori e delle loro condizioni di lavoro. Dunque, le carte tradizionali, focalizzandosi solo su misurazioni quantitative e standardizzate, non hanno la capacità di rappresentare o influenzare tali aspetti.

In conclusione, nonostante le carte di controllo tradizionali possano ancora avere un determinato valore in contesti produttivi stabili e standardizzati, queste però non sono più sufficienti ad affrontare le sfide dell'industria moderna. Con l'avanzare dell'industria 5.0, anche il controllo della qualità necessita di evolversi, integrando l'intelligenza artificiale, focalizzandosi sul valore e sull'adattamento. Occorre che le carte tradizionali siano in grado di interagire con l'intero sistema digitale dell'azienda e contribuire attivamente ad una produzione più sostenibile, personalizzata e centrata sull'essere umano [17].

2.5 La necessità di integrare le tecniche di *ML* al controllo qualità

Arrivati a questo punto, è chiaro come nel contesto odierno - dove la complessità dei processi, la personalizzazione dei prodotti e la quantità di dati generati superano di gran lunga le capacità degli strumenti tradizionali delineati fino ad ora - sia fondamentale implementare le pratiche di controllo di qualità.

Le carte di controllo, che si basano su approcci statistici classici e su ipotesi rigide come la stabilità del processo, la normalità dei dati e l'indipendenza delle osservazioni, sono sempre meno efficaci nel monitorare processi caratterizzati da alta variabilità, fortemente digitalizzati e soggetti a cambiamenti frequenti [18].

Per poter affrontare queste sfide, è necessario adottare alcuni strumenti avanzati basati sul *ML*, che sono in grado di trasformare le carte di controllo da semplici strumenti di rilevazione in sistemi predittivi intelligenti e adattabili ai diversi scenari. Infatti, il *ML* permette di approntare modelli che apprendono dai dati storici e gestionali, identificando schemi ricorrenti, anomalie complesse e *pattern* che i metodi tradizionali non riescono a rilevare in maniera tempestiva.

Tra le principali applicazioni del *ML* nell'ambito della qualità, emergono alcune soluzioni fondamentali [19]:

- Modelli predittivi intelligenti: grazie agli algoritmi sia supervisionati che non supervisionati, è possibile identificare diversi segnali nei dati di processo, anticipando così il rischio di difetti o di situazioni di controllo statistico fuori norma. Questo approccio consente di intervenire prima che si verifichi un evento critico, trasformando il controllo qualità da una semplice segnalazione di allarme ad una vera e propria azione proattiva.
- Carte di controllo adattive: il *ML* offre la possibilità di rinnovare le tradizionali carte di controllo, rendendole dinamiche e capaci di aggiornare automaticamente i limiti in base all'evoluzione del processo. In tal modo, vengono superate le criticità che riguardano i limiti statici e la dipendenza dalle assunzioni teoriche, che spesso non si adattano alla realtà dei processi produttivi.
- Sistemi esperti e decisionali: l'unione di regole logiche e modelli di apprendimento automatico consentono di creare mezzi e strumenti che supportano gli operatori nelle decisioni più complesse, suggerendo azioni correttive e personalizzate in base alle specificità del processo e del contesto produttivo.
- Strumenti statistici robusti e flessibili: molti algoritmi di *ML*, come le reti neurali, non necessitano che i dati siano normalizzati e possono tollerare la presenza di autocorrelazione e rumore. Questi metodi si rivelano particolarmente utili in processi intermittenti o con piccoli lotti, dove le tecniche tradizionali di controllo perdono di efficacia.

In sintesi l'adozione del *ML* per il controllo qualità non è solo una miglioria tecnologica, ma una vera e propria rivoluzione: si passa da un sistema con limiti fissi e analisi retrospettive ad un approccio più dinamico, adattabile e proiettato verso il futuro. In tale contesto, le carte di controllo non vengono abbandonate, ma reinventate per divenire parte attiva di un

sistema di qualità intelligente, perfettamente in linea con la visione dell'Industria 5.0: più flessibile, predittiva e con un focus maggiore sull'essere umano.

Capitolo 3

3. L'adozione delle tecniche di *Machine Learning* per il Controllo Qualità

3.1 Cos'è il *ML* e perché è rilevante nei processi manifatturieri

Il *ML* è un ramo dell'intelligenza artificiale che si dedica allo sviluppo di algoritmi capaci di apprendere dai dati in maniera autonoma, migliorando le loro prestazioni tramite l'esperienza, senza dover essere riprogrammati per ogni cambiamento o un nuovo scenario. In altre parole, un sistema che utilizza il *ML* non si basa su regole fisse, ma crea modelli adattivi che si evolvono in base ai dati che analizza. Questo approccio si fonda su metodi statistici, computazionali e probabilistici ed è efficace per risolvere problemi complessi, non lineari e variabili.

Nel contesto odierno dei processi manifatturieri e ancor di più nel nuovo ambito dell'Industria 5.0, il *ML* sta diventando sempre più cruciale. I processi produttivi di oggi sono caratterizzati da una complessità operativa elevata, una crescente personalizzazione della produzione e un'interazione continua tra tecnologie digitali e operatori umani. Nello scenario appena descritto, i metodi tradizionali di controllo e ottimizzazione dei processi, che si basano su logiche deterministiche e modelli statici, non sono più sufficienti per garantire livelli adeguati di efficienza, reattività e qualità.

Il *ML*, d'altra parte, offre l'opportunità di trasformare l'enorme quantità di dati provenienti da sensori, macchinari, sistemi informativi e dispositivi Iot in efficienza operativa [20]. Questa operatività consente di supportare decisioni in tempo reale. In tal modo, si passa da un approccio focalizzato sulla gestione dei problemi già manifestati ad un sistema predittivo e proattivo, ove è possibile in grado di:

- anticipare guasti e difetti
- rilevare anche le più piccole deviazioni nei processi
- adattare dinamicamente i parametri operativi
- suggerire azioni correttive, anche in maniera automatizzata

L'introduzione del *ML* nei processi manifatturieri porta con sé diversi vantaggi significativi, specialmente nel controllo qualità. In un settore dove i margini di errore sono sempre più ridotti e dove la personalizzazione e la sostenibilità sono diventati fattori cruciali, il *ML* si presenta come un fattore concreto per aumentare la competitività e affidabilità. Non si tratta solo di introdurre tecnologie avanzate, ma di rendere i processi più intelligenti, resilienti e trainati dai dati.

3.1.1 Il funzionamento del *ML* nel controllo qualità

Uno dei principali vantaggi del *ML* nei processi manifatturieri è il miglioramento del controllo qualità. L'uso del *ML* nel controllo qualità si basa su un processo ben definito che ha inizio dalla raccolta dei dati e si conclude con decisioni operative automatizzate o supportate. Tale processo si suddivide principalmente in cinque fasi, ognuna con un ruolo specifico all'interno del sistema [21]:

1. *raccolta dei dati di processo*: tutto ha inizio con la disponibilità dei dati grezzi generati in tempo reale dalle linee di produzione. Questi dati possono essere generati da diverse fonti, come: sensori fisici montati su macchinari, sistemi gestionali ERP, software MES, dispositivi IoT e altri strumenti gestionali. Le informazioni raccolte comprendono, ad esempio, temperatura, pressione, velocità, vibrazioni o risultati di ispezioni visive come immagini. La quantità e la qualità dei dati sono fattori fondamentali per il successo di un modello di *ML* [22];
2. *processamento dei dati*: i dati reali tendono ad essere frequentemente disordinati, incompleti o cosiddetti *no-signal*. Pertanto, la fase di processamento è indispensabile, dal momento che, se il modello è alimentato da dati di scarsa qualità questo produrrà risultati poco affidabili. Il processamento include attività come la pulizia dei dati, per eliminare valori anomali o mancanti; il filtraggio, al fine di rimuovere disturbi o segnali poco significativi; la normalizzazione o standardizzazione, per rendere i dati confrontabili e compatibili con gli algoritmi di *ML*;
3. *apprendimento del modello*: durante la fase di apprendimento, il modello di *ML* viene addestrato su dati storici, ossia su esempi di scenari passati in cui sono noti sia gli input che gli output. A seconda del tipo di problema e del metodo di apprendimento, si seleziona l'algoritmo più adatto. In questa fase, il modello impara a riconoscere le relazioni tra i dati di input e l'esito desiderato, costruendo un sistema capace di fare previsioni sui nuovi dati;

4. *output del modello*: una volta addestrato, il modello può essere utilizzato su dati in tempo reale. Gli output possono variare a seconda del contesto, come classificazione (ad esempio, prodotto conforme o non-conforme), previsione numerica o rilevamento di anomalie. In tal modo, il *ML* consente di anticipare difetti o problemi che altrimenti verrebbero rilevati solo al momento in cui questi diventassero noti;
5. *decisione operativa*: l'output del modello alimenta la fase finale, la decisione operativa. A seconda della configurazione, il sistema può generare allarmi automatici per segnalare condizioni critiche, suggerire azioni correttive all'operatore o regolare direttamente i parametri del macchinario o del processo, per prevenire il verificarsi di difetti o anomalie. Così facendo, il controllo qualità diventa proattivo e adattivo, contribuendo a ridurre gli scarti, ottimizzare le risorse e migliorare la reattività dell'intero sistema produttivo.

Il processo appena descritto e sintetizzato in Tabella 3 rende il *ML* uno strumento potente e flessibile per il controllo qualità, soprattutto in quei contesti manifatturieri complessi, dove le variabili sono molteplici e in continuo cambiamento. L'obiettivo non è solo quello di sostituire l'occhio umano, ma quello di potenziare le capacità decisionali, con sistemi capaci di apprendere, adattarsi e migliorare nel tempo [2].

Tabella 3: Principali fasi del *ML* nel controllo qualità

Fase	Descrizione
1. Raccolta dei dati di processo	Raccolti da sensori, macchinari, sistemi gestionali, IoT
2. Riprocessamento dei dati	Pulizia, filtraggio e normalizzazione dei dati grezzi
3. Apprendimento del modello	Addestramento del modello ML
4. Output del modello	Classificazione, previsione difetti, rilevamento anomalie
5. Decisione operativa	Azioni correttive, allarmi, aggiornamento dei parametri

3.2 Tipologie di modelli di *ML* applicabili al controllo qualità

Per comprendere meglio come il *ML* si applica nel settore manifatturiero, in particolare per quanto concerne il controllo qualità, è indispensabile esaminare e analizzare, almeno in prima battuta, le varie forme di apprendimento automatico che sono alla base delle architetture intelligenti utilizzate oggi nell'industria. In questo paragrafo, si vuole delineare

i principali modelli dell'apprendimento automatico del *ML*, evidenziando le loro caratteristiche, differenze e ambiti di applicazione.

In termini pratici, l'apprendimento di una macchina si concretizza nell'elaborazione di esempi passati, ognuno dei quali è descritto da un insieme di caratteristiche, fornite in input come vettori numerici. L'algoritmo cerca di costruire un modello matematico che sia in grado di individuare *pattern* nei dati e, successivamente, di effettuare previsioni o decisioni su nuovi scenari simili. L'efficacia di un algoritmo viene valutata sulla base di una metrica di prestazione, tipicamente la precisione predittiva o accuratezza, ossia la percentuale di casi correttamente classificati rispetto al totale. In alternativa, può essere considerato il tasso di errore, ovvero la percentuale di previsioni errate.

L'uso del *ML* nei processi industriali si basa su diverse modalità di apprendimento, ognuna con le proprie caratteristiche e aree di applicazione. Esistono diverse modalità attraverso cui un algoritmo può apprendere dai dati e queste vengono generalmente suddivise in tre tipi: apprendimento supervisionato, non supervisionato e apprendimento per rinforzo [24]. È fondamentale comprendere queste tipologie per scegliere l'approccio più adatto in base al problema da affrontare, ai dati a disposizione e agli obiettivi di produzione.

3.2.1 Apprendimento supervisionato

L'apprendimento supervisionato è la tipologia più diffusa nelle applicazioni di *ML* per la qualità. In questo approccio il sistema viene addestrato su un insieme di dati etichettati: ogni esempio include non solo i valori delle variabili in input, ma anche l'output corretto da apprendere. L'obiettivo è creare un modello capace di generalizzare e prevedere il risultato corretto per i nuovi dati che non sono ancora stati analizzati [25].

Nel contesto del controllo qualità, tale tipo di apprendimento viene utilizzato per:

- classificare i prodotti come conformi o non conformi;
- stimare la probabilità di un difetto in base alle condizioni operative;
- prevedere le deviazioni delle specifiche di tolleranza.

Tra gli algoritmi più utilizzati, i quali verranno delineati in maniera più esaustiva successivamente, in questo campo troviamo:

- *Support Vector Machine (SVM)*, ideali per classificazioni binarie e set di dati ben separabili;
- *Random Forest*, che uniscono più alberi decisionali per creare modelli robusti e stabili;
- Reti neurali artificiali, perfette per problemi complessi con relazioni non lineari;
- Regressione lineare o logistica, per situazioni con output numerici o binari.

3.2.2 Apprendimento non supervisionato

A differenza dell'apprendimento supervisionato, in questo caso l'algoritmo non riceve etichette o risultati da cui apprendere. Il suo obiettivo è identificare autonomamente schemi, relazioni o strutture nascoste nei dati. Questo metodo è particolarmente vantaggioso quando non si hanno output etichettati o quando si desidera analizzare grandi quantità di dati che non sono ancora stati interpretati.

Nel controllo qualità, si rivela utile per [26]:

- rilevare comportamenti anomali nel processo produttivo;
- raggruppare lotti o cicli produttivi simili;
- condurre analisi su variabili critiche.

I principali metodi utilizzati includono:

- *K-Means Clustering* per segmentare i dati in gruppi omogenei;
- *Principal Component Analysis (PCA)*, per ridurre la dimensionalità e mettere in evidenza le variazioni più significative;
- *Autoencoder*, reti neurali capaci di identificare anomalie ricostruendo i dati di input.

3.2.3 Apprendimento per rinforzo

L'apprendimento per rinforzo si basa su un meccanismo di prova ed errore: l'algoritmo interagisce con l'ambiente, ricevendo ricompense o penalità in base alle azioni intraprese. Non viene fornito un set di dati etichettato, ma un obiettivo da raggiungere.

Anche se meno diffuso nelle applicazioni attuali di controllo qualità, trova impiego in situazioni dove l'agente deve adattare le proprie decisioni in tempo reale, come:

- ottimizzazione dei parametri di processo in sistemi dinamici;

- regolazione autonoma in contesti produttivi ad alta variabilità;
- manutenzione predittiva e adattiva [27].

3.2.4 Reti neurali e *Deep Learning*

Le reti neurali artificiali e, più in generale, le tecniche di *deep learning*, rappresentano modelli avanzati in grado di apprendere rappresentazioni complesse direttamente dai dati. Composte da più livelli (*layer*) di neuroni artificiali, queste architetture sono ideali per gestire informazioni complesse e non strutturate, come immagini o segnali temporali.

Nel controllo qualità, vengono utilizzate per:

- il riconoscimento automatico di difetti in immagini;
- l'analisi predittiva su segnali multivariati raccolti da sensori;
- la classificazione di stati di processo su base storica o in tempo reale.

Questi modelli, pur richiedendo maggiore potenza computazionale e dati in grande quantità, offrono un'elevata precisione predittiva e capacità di adattamento [28].

Di seguito, viene riportata la Tabella 4 che riassume i metodi appena delineati:

Tabella 4: Diverse modalità di apprendimento dei dati

Tipo di Apprendimento	Caratteristiche	Applicazioni nel controllo qualità	Algoritmi / Tecniche
Supervisionato	Richiede dati etichettati Associa input a output noti.	Classificazione difetti Previsione di scarti Analisi tolleranze.	SVM; <i>Random Forest</i> ; Regressione; Reti Neurali.
Non Supervisionato	Nessuna etichetta Identifica <i>pattern</i> Cluster o anomalie	Rilevamento anomalie Segmentazione cicli produttivi.	<i>K-Means, PCA, Autoencoder</i>
Per Rinforzo	Apprendimento tramite interazione con l'ambiente e feedback.	Ottimizzazione in tempo reale Manutenzione predittiva.	<i>Q-learning, Deep Q Network</i>
Reti Neurali / Deep Learning	Architetture profonde in grado di apprendere rappresentazioni complesse dai dati.	Ispezione visiva automatica. Analisi segnali complessi.	CNN RNN <i>Autoencoder</i> profondi

3.3 Quali sono i vantaggi e gli svantaggi delle carte di controllo basate su *ML*

Come delineato precedentemente, l'evoluzione dei processi produttivi, sempre più complessi e interconnessi, ha reso necessario un ripensamento degli strumenti di controllo qualità. Il passaggio dalle tradizionali carte di controllo *SPC* a quelle basate su *ML* segna un cambiamento importante.

Le carte tradizionali si fondano su modelli statistici classici, che si basano su assunzioni di normalità, indipendenza e stazionarietà del processo. Funzionano bene in contesti stabili, dove poche variabili, che non interagiscono tra loro, riescono a descrivere adeguatamente il sistema produttivo. Sono strumenti facili da implementare, semplici da interpretare e richiedono poca potenza di calcolo, rendendole ideali per controlli su singole variabili o in situazioni di bassa variabilità. Tuttavia, presentano limiti evidenti: faticano a individuare anomalie complesse o comportamenti non lineari e non sono adatte a processi multivariati o ad alta dinamicità. Inoltre, sono sensibili al rumore nei dati, il che porta a frequenti falsi allarmi [29].

D'altra parte, le carte che si basano su *ML* superano molti di questi limiti. Il principale vantaggio delle carte di controllo basate su *ML* è la loro straordinaria capacità di adattarsi in tempo reale ai cambiamenti nei processi produttivi. A differenza dei metodi statistici tradizionali, che richiedono che il processo sia stabile e che si basano su distribuzioni note, come quella Normale, gli algoritmi di *ML* apprendono direttamente dai dati reali, anche quando questi sono complessi, multivariati o non lineari. Questo li rende particolarmente efficaci nei moderni ambienti produttivi, dove la variabilità è la normalità e la completa standardizzazione è spesso impraticabile.

Un altro grande vantaggio è la loro sensibilità avanzata nel rilevare anomalie: il *ML* è in grado di scoprire schemi nascosti o piccole deviazioni che, pur non superando i limiti tradizionali, possono essere segnali precursori di guasti o difetti. Questo consente di intervenire preventivamente in maniera molto più tempestiva rispetto ad un approccio reattivo tipico delle carte *SPC*. Inoltre, le carte su *ML* sono meno suscettibili al rumore: i modelli intelligenti imparano a distinguere tra variazioni normali e anomalie significative, riducendo significativamente il numero di falsi allarmi, che nelle carte tradizionali sono una delle principali cause di inefficienza e interventi superflui [30].

La loro continua adattabilità è un ulteriore punto di forza. I modelli possono aggiornarsi automaticamente in base ai nuovi dati raccolti, mantenendo alta l'affidabilità del controllo senza necessità di ricalcoli manuali o ridefinizioni periodiche dei limiti di intervento. Dunque, adottare carte di controllo basate su *ML* consente di sfruttare al massimo l'integrazione con i sistemi digitali e IoT, realizzando un controllo qualità efficace ed intelligente, predittivo e interconnesso su larga scala.

Nonostante i chiari vantaggi, le carte *ML* presentano anche alcune criticità da non sottovalutare.

Il primo aspetto negativo è la complessità computazionale. Infatti, gli algoritmi di *ML* (in particolare quelli più complessi come, ad esempio, le reti neurali profonde) richiedono notevoli risorse di calcolo sia durante la fase di addestramento che di applicazione. Ciò implica la necessità di avere infrastrutture adeguate e sistemi di gestione dei dati efficienti.

Un altro svantaggio è la minore interpretabilità. Mentre le carte tradizionali si basano su regole statistiche che possono essere comprese anche da operatori non specializzati, i modelli di *ML*, invece, operano spesso come un sistema ignoto ai dipendenti. Questo rende più difficile giustificare alcune decisioni o risultati del sistema, che può essere un problema in un contesto regolamentato e in ambito certificativo [31].

Anche l'alta dipendenza dalla qualità e dalla quantità dei dati è un altro limite significativo. Per costruire modelli che siano affidabili, sono necessari *dataset* storici ampi, rappresentativi e puliti. Errori di misura, dati mancanti o mal calibrati possono compromettere seriamente l'efficacia del modello. Inoltre i sistemi basati su *machine learning* richiedono una manutenzione continua. Difatti, il cambiamento delle condizioni operative nel tempo potrebbero rendere obsoleti i modelli attuali, se non vengono riaddestrati continuamente. Ciò comporta costi aggiuntivi di gestione e necessità di figure professionali specializzate del *ML*.

Infine, vi è il tema del costo di implementazione: oltre agli investimenti tecnologici e infrastrutturali, è necessario prevedere formazione del personale, cambiamenti organizzativi e, in molti casi, la revisione dei sistemi di gestione della qualità.

Dunque, le carte di controllo basate su *ML* rappresentano un grande passo avanti rispetto ai metodi tradizionali, ma la loro adozione richiede una certa consapevolezza tecnica, organizzativa ed economica. Questi strumenti sono estremamente potenti in contesti dinamici e complessi, ma non possono essere considerati una soluzione, necessitando di un

approccio strategico e di supporto continuo per sfruttare completamente il loro potenziale. Di seguito viene riportata la Tabella 5 che sintetizza le differenze principali tra le carte di controllo classiche e quelle basate su *ML* [32].

Tabella 5: Sintesi SPC vs. ML

Tipologia	Carte Tradizionali SPC	Carte basate su ML
Approccio	Statistico (si basa per lo più su distribuzioni note come la Normale)	Si basa per di più su modelli di tipo predittivo, classificazione, regressione e modelli adattivi
Dati Input	Singole variabili o comunque un numero molto limitato, indipendenti	Dati multivariati, complessi e non lineari
Ipotesi principali	Normalità, indipendenza e stazionarietà del processo	Generalizzazione e stabilità dei dati, consistenza qualitativa dei dati
Limiti di controllo	Limiti prefissati ($\pm 3\sigma$)	Limiti adattabili e variabili
Tipo di segnale	Superamento dei limiti	Superamento dei limiti, errore di previsione, anomalia e classificazione binaria in alcuni casi
Adattabilità	Bassa: i limiti sono fissi e sono calcolati manualmente	Alta: i modelli sono adattivi, apprendono autonomamente e sono aggiornabili
Interpretabilità	Alta: difatti le regole statistiche sono molto chiare e di facile comprensione	Bassa: sicuramente per quanto concerne le reti neurali questa è bassa mentre, invece, è un po' più alta per i modelli come SVM e gli alberi decisionali
Rilevamento di anomalie	Tale aspetto è limitato alle deviazioni semplici e comunque evidenti	Molto elevato, dal momento che rileva pattern nascosti, non lineari e multivariati
Manutenzione	Bassa: solo quando necessario si ricalcolano manualmente i limiti	Alta: ogni qualvolta cambia lo storico dei dati iniziali e necessità di monitorare costantemente l'evolversi dei dati e del processo
Sensibilità al rumore	Alta: frequenti falsi allarmi	Bassa: i modelli di ML infatti riducono notevolmente il verificarsi dei falsi allarmi
Computazionalità	Bassa: i calcoli sono semplici	Molto alta: dato che i modelli sono complessi e la capacità di calcolo è molto elevata

Vantaggi	<p>Le carte tradizionali, dunque, sono semplici da implementare e hanno facile interpretabilità. Queste sono comunque utili in quei processi che si possono considerare stabili e che richiedono pochi dati. Sono quindi ideali per il controllo statistico ad una variabile.</p>	<p>Queste, invece, sono molto utili per quei processi che non sono lineari ma al contrario sono dinamici e/o multivariati. Difatti, vengono rilevate anomalie quasi impercettibili e si adattano molto meglio ai contesti odierni, in rapida evoluzione e molto dinamici. Infine, possono essere usati per implementare le carte tradizionali (modelli <i>Hybrid</i>).</p>
Svantaggi	<p>Sono poco adatte a contesti multivariati o con variabili dipendenti, non rilevano anomalie complesse e assumono sempre la caratteristica di normalità e indipendenza.</p>	<p>Sicuramente, oltre a richiedere competenze di calcolo elevate richiedono anche costi maggiori. Inoltre, sono necessari molti più dati, sono meno trasparenti (quindi minore interpretabilità) e occorre che siano monitorate e aggiornate di continuo.</p>

3.4 Considerazioni finali sul ML per il controllo qualità

L'adozione del *ML* nelle carte di controllo segna un cambiamento significativo nel modo in cui pensiamo al controllo qualità. Non si tratta solo di affinare la sensibilità nel rilevare anomalie, ma di trasformare il controllo qualità in un sistema intelligente, adattabile e predittivo.

Il vero valore aggiunto delle carte basate su *ML* risiede nella loro capacità di prevedere i problemi, piuttosto che limitarci a identificarli dopo che si sono già verificati. I modelli di *ML*, apprendendo continuamente dai dati reali, permettono di intervenire prima che si presentino difetti concreti, contribuendo a ridurre scarti, rilavorazioni e fermi produttivi. Inoltre, rendono possibile il monitoraggio di processi complessi e multivariati, che sarebbero difficili da gestire con gli strumenti statistici tradizionali [33].

Questa innovazione richiede nuove competenze, una gestione dei dati solida ed infine un'infrastruttura tecnologica adeguata. Non tutte le aziende possono implementarla subito: il *ML* non è una sostituzione diretta delle carte *SPC* classiche, ma piuttosto un potenziamento strategico da integrare gradualmente, con visione e preparazione. In sintesi, il *ML* non sostituisce il controllo qualità tradizionale, ma lo innalza a un livello superiore, rendendolo parte integrante del miglioramento continuo e della competitività industriale a lungo termine.

Capitolo 4

4. Le carte di controllo basate su *ML*

4.1 Tipologia delle carte di controllo

Nei contesti produttivi moderni i processi sono complessi e i dati possono essere multivariati, autocorrelati o influenzati in maniera non lineare. A tal proposito l'adozione del *ML* per la creazione delle carte di controllo rappresenta un passo avanti notevole. Le carte di controllo basate su *ML* utilizzano modelli predittivi o di classificazione per apprendere il comportamento normale del processo, analizzando grandi volumi di dati storici. Questi modelli sono in grado di individuare deviazioni significative che possono indicare anomalie o segnali fuori controllo, anche quando una carta tradizionale non riuscirebbe a farlo.

Le carte di controllo basate su *ML* possono essere suddivise in diverse categorie, a seconda dell'algoritmo impiegato e dall'obiettivo specifico.

4.1.1 Carte predittive

Queste carte sono l'evoluzione rispetto alle tradizionali carte di controllo, progettate per gestire la complessità dei processi moderni. A differenza delle carte classiche, che si limitano a monitorare una singola variabile di qualità nel tempo, le carte predittive utilizzano un modello di *ML* per anticipare il valore atteso della variabile da controllare, basandosi su un insieme di variabili in input che descrivono le condizioni operative del processo.

Il funzionamento di una carta predittiva si sviluppa in diverse fasi. Si inizia con la raccolta di dati storici che includono sia le variabili indipendenti (temperatura, pressione, ecc.) sia il valore dell'output da monitorare. Questi dati vengono utilizzati per approntare un modello predittivo capace di apprendere la relazione tra input e output. Una volta che il modello è in grado di stimare con precisione il valore atteso dell'output, si procede al monitoraggio in tempo reale. Per ogni nuova osservazione, il modello fornisce una previsione e la differenza tra valore reale – osservato - e quello previsto, ossia il residuo, che viene tracciata nel tempo all'interno della carta [34].

I residui, se il modello è ben calibrato, dovrebbero distribuirsi intorno allo zero. L'idea di base è che, in condizioni normali, i valori osservati si avvicinino quanto più possibile a quelli

previsti, mentre scostamenti significativi possono indicare potenziali anomalie. I limiti di controllo, di solito calcolati su base statistica, vengono applicati al grafico dei residui per capire se il processo è sotto controllo o meno.

Uno dei principali vantaggi di questo approccio è la sua capacità di adattarsi a processi con più variabili e non lineari, dove i metodi tradizionali faticerebbero a rilevare deviazioni significative. Inoltre, la carta predittiva permette di personalizzare il monitoraggio in base al contesto operativo: il modello considera diversi fattori contemporaneamente, migliorando la sensibilità ai cambiamenti reali del sistema.

Tuttavia vi sono anche degli svantaggi e criticità da considerare. Prima di tutto, la qualità della carta dipende fortemente dalla precisione del modello predittivo. Un modello impreciso o mal addestrato potrebbe generare residui fuorvianti e, conseguentemente, falsi allarmi. In secondo luogo, i modelli di *ML* necessitano di manutenzione periodica e devono essere aggiornati con dati recenti per rimanere validi nel tempo. Inoltre quando si utilizzano modelli complessi - come le reti neurali profonde - diventa più complesso delineare perché una certa situazione sia stata segnalata come anomala, il che potrebbe rendere più difficile l'adozione dei modelli complessi in ambienti regolamentati o ad alta responsabilità. Infine, un'ipotesi fondamentale è che il modello sia addestrato su dati rappresentativi del comportamento normale del processo. Se i dati di *training* includessero situazioni anomale o fasi transitorie, il modello potrebbe imparare a considerarle normali, perdendo così la sua capacità di interpretazione e analisi [35].

In breve, le carte predittive rappresentano uno strumento potente e flessibile per tenere sotto controllo processi più complessi, adattandosi in modo più efficace alle dinamiche moderne rispetto ai metodi tradizionali. Tuttavia, per funzionare meglio, necessitano di una progettazione attenta, dati di alta qualità e un'infrastruttura in grado di supportare un ciclo continuo di apprendimento e aggiornamento del modello.

4.1.2 Carte adattive

Le carte adattive sono state create per affrontare un problema evidente delle tradizionali carte di controllo, vale a dire la loro rigidità. Nei contesti produttivi reali, i processi non sono mai statici. Si evolvono nel tempo, si adattano a nuove condizioni e subiscono l'influenza di fattori esterni come la temperatura, l'usura delle macchine e la variabilità dei materiali. In queste circostanze, una carta con limiti fissi sulla base di dati storici raccolti mesi prima, può

diventare rapidamente obsoleta o fuorviante. Le carte adattive, al contrario, si fondono su un principio semplice ma efficace, ossia il controllo del processo deve essere in grado di evolversi insieme al processo stesso.

Queste carte non stabiliscono una volta per tutte i propri limiti di controllo, come accadeva con le tradizionali carte di controllo ma, al contrario, li aggiornano costantemente [36]. Monitorano i dati in tempo reale e, in base all'evoluzione del comportamento del sistema, ricalcolano la media, la varianza e la deviazione standard. Ciò non significa che accettino tutto senza criterio. Difatti l'adattamento è in funzione dell'ambiente esterno ed è guidato da algoritmi progettati per distinguere tra variazioni naturali e possibili segnali di anomalie. In sostanza, la carta impara mentre opera: non solo monitora, ma si adatta al processo e alle sue variazioni in maniera efficace. In un ambiente di produzione dove le condizioni possono cambiare drasticamente da un'ora all'altra, o in una linea multiprodotto dove ogni ciclo presenta parametri leggermente diversi, questa capacità di adattamento è fondamentale. Una carta con limiti fissi genererebbe continui allarmi non giustificati, costringendo gli operatori a ignorarli o a disattivarli. Con una carta adattiva, invece, il sistema continua a monitorare in modo intelligente, riducendo il rumore e concentrandosi sui segnali realmente anomali [37].

Naturalmente tale approccio non è privo di rischi. Se la carta si adattasse troppo rapidamente, potrebbe accettare anche le anomalie e considerarle come una nuova normalità. In tal caso, un guasto lento o un degrado progressivo potrebbero passare inosservati. È quindi fondamentale trovare un equilibrio: l'algoritmo deve essere sviluppato per adattarsi solo quando il cambiamento è credibile, non immediato e in linea con l'andamento del processo. Si tratta di un delicato compromesso tra flessibilità e rigore.

Le carte adattive non sono pensate per situazioni semplici. Queste necessitano di dati di alta qualità, di una raccolta continua e di un'infrastruttura tecnologica capace di supportare modelli aggiornabili in tempo reale. Queste carte integrate con tecniche di *ML*, migliorano ulteriormente la loro capacità di leggere i segnali, riconoscere pattern nascosti e reagire in maniera proattiva.

Ciò che rende davvero efficaci le carte adattive è che, a differenza dei modelli statici, non cercano di forzare il processo all'interno di una struttura rigida. Accettano che la realtà sia variabile e si aggiornano per essere efficaci. Non inseguono l'illusione della stabilità, ma costruiscono un controllo che rimane efficace anche quando l'ambiente esterno muta.

4.1.3 Carte per classificazione

Le carte di controllo basate sulla classificazione nel contesto del *ML* segnano un vero e proprio cambiamento rispetto ai metodi tradizionali di controllo statistico. Non si limitano a monitorare una variabile e a verificare se rientra in una soglia numerica predefinita, viceversa categorizzano direttamente lo stato del processo. L'obiettivo non è più solo misurare quanto un dato si discosti dalla media, ma piuttosto decidere, basandosi su un insieme di informazioni, se il processo è normale o anormale, se sta funzionando o no.

Questo tipo di carta si basa sull'addestramento di un modello di classificazione supervisionato. Ciò significa che, prima di poter essere utilizzata per il controllo, la carta ha bisogno di dati etichettati, cioè un insieme di osservazioni precedenti per le quali si conosce già se il processo era in uno stato di controllo o fuori controllo. Il modello impara a distinguere tra queste due o più classi, analizzando la relazione tra le variabili di input, che possono essere molteplici e correlate tra loro, e l'etichetta finale che rappresenta lo stato del sistema. Una volta addestrato il modello, questo entra in gioco sottoforma di classificatore durante la fase di monitoraggio. Per ogni nuova osservazione, il sistema non si limita a calcolare una deviazione o un residuo, ma emette una decisione.

Un esempio potrebbe essere il seguente. Accetto perché lo stato del processo è simile a quelli etichettati come normali oppure rifiuto in quanto il *pattern* in esame è simile a quelli considerati come non normali. In alcuni casi, il modello fornisce anche una probabilità associata a ciascuna classe, rendendo il sistema più flessibile e adattabile [38].

Tale approccio si rivela particolarmente efficace in situazioni complesse e variabili, dove i segnali di allerta non sono sempre legati ad una singola variabile che supera i limiti, ma piuttosto a combinazioni di variabili che, nell'insieme, segnalano un comportamento anomalo. Una carta basata sulla classificazione può racchiudere tutto questo in una decisione binaria, rendendo gli output più facili da interpretare per gli operatori, ma con un contenuto informativo molto più ampio.

I vantaggi di questo tipo di carte sono evidenti. Innanzitutto, possono gestire dati di varie tipologie: numerici, categorici, temporali. Inoltre, non è necessario che i dati seguano una distribuzione normale, come spesso richiesto dai metodi tradizionali. Soprattutto possono rilevare relazioni non lineari tra le variabili, evidenziando schemi che una semplice analisi

statistica potrebbe trascurare. Infine, a differenza delle carte predittive, il messaggio che trasmettono è chiaro: il processo è sotto controllo oppure no.

Tuttavia ci sono anche delle criticità. La più significativa è sicuramente che tutto dipende dalla qualità del modello e, in particolare, dalla qualità delle etichette fornite durante la fase di addestramento. Se i dati storici sono mal etichettati se, ad esempio, gli stati anomali non sono stati riconosciuti correttamente, il modello tenderà a classificare in maniera errata. Inoltre questi sistemi spesso funzionano come delle scatole nere, ossia forniscono risposte chiare, ma con una spiegazione che è molto risicata. In un contesto in cui è fondamentale capire perché qualcosa è fuori controllo (ad esempio per poter intervenire e correggere), tale mancanza di trasparenza può rappresentare un serio limite. Un altro aspetto importante da considerare è l'adattabilità. Un classificatore standard non si aggiorna automaticamente, per rimanere efficace ha bisogno di essere riaddestrato con dati più recenti, soprattutto se il processo evolve nel tempo. Altrimenti rischia di diventare obsoleto e innescare decisioni errate [39].

Le carte basate su classificazione non sono semplicemente un'alternativa alle carte tradizionali, ma rappresentano un approccio completamente diverso. Non si concentrano su una deviazione rispetto ad una soglia, ma analizzano un *pattern* complessivo per valutare se il processo è ancora in condizioni di controllo. Possono essere più intelligenti, più precise e più adatte a contesti in cui il controllo non si limita ad una sola variabile. Tuttavia questa intelligenza richiede dati di qualità, modelli robusti e una progettazione meticolosa. Se implementate correttamente, consentono di passare da un controllo reattivo ad uno proattivo, dove il sistema può segnalare un rischio prima che diventi un problema più grande.

4.1.4 Carte non-supervisionate

Le carte di controllo non supervisionate affrontano il monitoraggio dei processi produttivi da una prospettiva diversa: non necessitano di etichette, il che significa che non richiedono una classificazione preventiva dei dati come normali o non normali. Ciò le rende particolarmente importanti in situazioni in cui non si dispone di una documentazione storica precisa sui fuori controllo, o quando i dati sono scarsi e privi di annotazioni affidabili.

Nelle carte di controllo tradizionali, il controllo statistico si basa sull'idea di costruire un modello di riferimento utilizzando dati stabili, etichettati e rappresentativi del

comportamento corretto del processo. Nella pratica queste condizioni non sono sempre rispettate. Ed è qui che entrano in gioco le carte non supervisionate. Questi strumenti analizzano algoritmi che apprendono a riconoscere il comportamento normale analizzando la struttura intrinseca dei dati, senza che sia necessario che qualcuno indichi in maniera esplicita quali osservazioni siano accettabili e quali no [40].

Un approccio comune prevede l'uso di tecniche di *clustering*, ossia di raggruppamento, come *K-Means* o *DBSCAN*, che raggruppano i dati in base a somiglianze interne. Una volta individuati i gruppi principali, che rappresentano le configurazioni normali del processo, le nuove osservazioni possono essere valutate in base alla loro distanza o coerenza rispetto a questi gruppi. Se un nuovo punto si discosta troppo da tutti i *cluster* identificati viene segnalato come potenziale anomalia. In altri casi si usano metodi come *Isolation Forest*, che isolano sistematicamente le osservazioni meno frequenti, oppure *Autoencoder* non supervisionati, che sono in grado di imparare una rappresentazione compatta dei dati e misurare la differenza tra input originale e ricostruzione. Tali carte non supervisionate non originano necessariamente un grafico classico con limiti superiori e inferiori. Il concetto di fuori controllo si traduce in un punteggio di anomalia: più un dato è atipico rispetto alla distribuzione appresa, maggiore sarà il punteggio e più probabile sarà che venga considerato anomalo. In alcuni casi, si può anche stabilire un limite decisionale (una soglia di anomalia), oltre il quale viene generato un allarme [41].

Il punto di forza di questo approccio è la sua autonomia. Funziona anche quando il processo è nuovo, poco documentato o troppo complesso per essere etichettato in modo chiaro. È ideale per scenari in cui si desidera esplorare comportamenti sospetti, senza doverli definire in anticipo. Inoltre è particolarmente adatto per ambienti in cui le anomalie sono rare o imprevedibili e dove non si ha la possibilità di raccogliere esempi sufficienti per costruire un modello supervisionato affidabile.

Tuttavia ci sono delle limitazioni significative anche in tal caso. Le carte non supervisionate non hanno la capacità di riconoscere un'anomalia, sanno solo identificare ciò che è raro o diverso. Questa attitudine potrebbe portare a falsi allarmi quando ci sono variazioni legittime, oppure a trascurare anomalie che, pur essendo pericolose, sembrano simili a situazioni già conosciute. Inoltre l'interpretazione dei risultati non è sempre immediata. Quando un algoritmo segnala un punto come anomalo, non è detto che sia facile identificare la causa di tale anomalia.

Anche la configurazione iniziale richiede una certa attenzione. La scelta del metodo, dei parametri e delle rappresentazioni dei dati può influenzare notevolmente la sensibilità del sistema. Una volta che una carta di questo tipo è in funzione, deve comunque essere monitorata e verificata, non perché necessiti di etichette per operare, ma perché ogni sistema che prende decisioni critiche deve essere sottoposto ad una validazione continua.

In sintesi, le carte non supervisionate cambiano l'approccio del controllo da quello guidato dall'uomo a quello trainato dai dati. Non richiedono che il processo si adatti ad un modello predefinito, apprendono direttamente da ciò che accade, rilevando le deviazioni in modo naturale. In contesti nuovi, complessi o difficilmente etichettabili, possono rappresentare la via più accessibile e, talvolta, anche l'unica possibile per garantire un monitoraggio tempestivo ed efficace. Non forniscono certamente tutte le risposte, ma sono sicuramente strumenti eccellenti per affrontare anche gli scenari più complessi.

4.1.5 Carte ibride

Le carte di controllo ibride rappresentano un miscuglio di diversi approcci e modelli. Nascono dall'idea che nessun singolo metodo, che sia predittivo, adattivo, classificatorio, non supervisionato o basato su reti neurali, possa da solo affrontare la complessità e le esigenze pratiche e reali dei sistemi produttivi attuali. Le carte ibride non seguono quindi un'unica strada, ma uniscono tecniche diverse per garantire un controllo più robusto, flessibile e intelligente.

In pratica, una carta ibrida può utilizzare un modello predittivo per stimare un valore di output atteso, una rete neurale per identificare *pattern* complessi nei dati multivariati, e allo stesso tempo un algoritmo di classificazione per determinare se il processo è sotto controllo. Il sistema può anche includere elementi non supervisionati, come un rilevatore di anomalie, per aggiungere una seconda linea di difesa basata su comportamenti atipici. Ogni metodo o tecnica offre una prospettiva diversa sul processo e, una volta aggregata, l'informazione porta a decisioni più affidabili [42].

L'obiettivo non è solo quello di avere più metodi a disposizione, ma anche sfruttare i punti di forza di ciascuno per compensare le singole limitazioni dei diversi approcci. Ad esempio, un classificatore supervisionato può essere molto preciso, ma diventa inefficace se mancano dati etichettati. Un modello predittivo può rilevare deviazioni quantitative, ma non sempre riesce ad identificare il tipo di anomalia in corso. Una rete neurale può essere potente, ma

spesso è poco trasparente, ossia di difficile interpretazione. Un sistema non supervisionato è flessibile, ma può risultare talvolta troppo generico. In un'architettura ibrida queste parti si integrano: il classificatore fornisce una decisione binaria, il modello predittivo quantifica lo scostamento e un algoritmo di rilevamento delle anomalie offre un punteggio di anomalia per guidare le priorità degli interventi.

Il funzionamento di una carta di controllo ibrida è piuttosto complesso. I dati che arrivano vengono elaborati simultaneamente da diversi moduli, ognuno dei quali genera un segnale, un valore previsto, una probabilità, una classe, un residuo e un errore di ricostruzione. Il sistema finale può prendere una decisione aggregata, ad esempio utilizzando un sistema a soglie multiple o una logica di voto, oppure può lasciare la decisione ad un modello che interpreta e combina i risultati dei moduli sottostanti.

Questo tipo di carta presenta un vantaggio significativo in ambienti complessi, ove le anomalie possono manifestarsi in modi molto diversi tra loro e possono essere improvvise o lente, isolate o sistematiche, rumorose o silenziose. Una carta ibrida ha maggiori probabilità di captare segnali deboli o sfumature che potrebbero sfuggire ad un approccio singolo. Inoltre la si può configurare per essere più sensibile in alcune fasi del processo e più tollerante in altre, offrendo così un controllo dinamico e contestuale [43].

Naturalmente le carte ibride sono sistemi complessi che richiedono una progettazione meticolosa, una buona comprensione dei dati e spesso una stretta collaborazione tra esperti del settore e *data scientist*. Pertanto, queste carte devono essere testate, calibrate e validate in ogni loro componente, poiché un errore in uno dei moduli può compromettere la qualità della decisione finale. Inoltre la trasparenza può diventare un problema: più modelli vengono combinati, più difficile diventa spiegare perché una certa osservazione è stata considerata anomala o fuori controllo. Difatti vi è anche il rischio di avere ridondanze o conflitti tra i vari moduli. Per affrontare queste situazioni, occorre avere strategie chiare di integrazione e logiche di priorità [44].

Nonostante la complessità le carte ibride rappresentano un passo enorme nell'evoluzione del controllo qualità. Tali carte non cercano una verità assoluta nei dati, ma creano una rete di segnali che, se ben coordinati, consentono un monitoraggio accurato, flessibile e più in sintonia con la realtà complessa dei processi produttivi odierni. In una *smart factory* dove tutto è interconnesso e ogni dato ha la sua importanza, le carte ibride non sono solo un compromesso, ma rappresentano una scelta strategica per ottenere il massimo con il minimo margine d'errore.

4.1.6 Carte neurali

Le carte di controllo che si basano sulle reti neurali sono tra le soluzioni più avanzate e sofisticate nel campo del controllo di processo supportato dal *ML*.

A differenza dei modelli tradizionali o dei classificatori più semplici, le reti neurali sono progettate per affrontare relazioni più complesse, non lineari e ad alta dimensionalità tra le variabili di un processo. Questo le rende particolarmente efficaci nei contesti produttivi moderni, dove le dimensioni sono più complesse per essere analizzate da modelli lineari o regole statiche.

Quando si parla di una carta di controllo basata su rete neurale, non ci riferiamo semplicemente all'applicazione di un modello e al monitoraggio del suo output. Si tratta piuttosto di utilizzare la rete come il cuore del sistema di monitoraggio, che apprende direttamente dai dati storici come si presenta il comportamento normale di un processo e diventa capace di riconoscere quando qualcosa si discosta in modo significativo da quel modello.

A seconda di come è progettata, una rete neurale può essere utilizzata in due modi principali. Nel primo caso, può agire come un modello predittivo: viene addestrata per prevedere una o più variabili chiave del processo basandosi su altri input e la carta di controllo viene creata analizzando le differenze tra i valori reali e quelli previsti, proprio come nelle carte predittive. La grande novità è che la rete è capace di modellare anche relazioni molto complesse e non lineari, adattandosi a strutture di dati complesse. Nel secondo caso, la rete può servire come filtro per il rilevamento delle anomalie. Qui si allena una rete, spesso un *autoencoder*, a riprodurre fedelmente le condizioni normali del processo. Quando l'errore di ricostruzione aumenta in modo anomalo, significa che il processo sta deviando da ciò che la rete considera normale [45].

Il vantaggio di questo approccio è proprio la sua flessibilità. Le reti neurali possono analizzare simultaneamente decine o addirittura centinaia di variabili, riconoscere schemi temporali, adattarsi a segnali rumorosi e imparare da dati non etichettati. In settori come l'industria chimica, la manifattura avanzata o la produzione automatizzata, queste capacità sono essenziali per monitorare sistemi in cui ogni ciclo è leggermente diverso dal precedente e dove le relazioni tra le variabili possono cambiare nel tempo o in base alle condizioni operative.

Tuttavia le reti neurali portano con sé anche alcune sfide. Il primo ostacolo è l'opacità, vale a dire una rete neurale - specialmente se profonda - è una struttura complessa da decifrare. Quando il sistema segnala che qualcosa non va, non è facile capire quale variabile abbia scatenato il problema, né perché la rete lo abbia identificato come un'anomalia. Questo può diventare un grosso problema in contesti dove è fondamentale avere tracciabilità o spiegazioni chiare delle decisioni. Inoltre, le reti neurali hanno bisogno di enormi quantità di dati per generalizzare in maniera efficace. Non solo devono analizzare molti esempi di comportamento normale, ma devono anche comprendere la variabilità naturale del processo. Se i dati non sono rappresentativi, la rete rischia di etichettare come anomale situazioni del tutto accettabili o, peggio, di non riuscire a individuare le vere anomalie. Un altro aspetto da considerare, infine, è la manutenzione del modello. Le reti devono essere aggiornate regolarmente per riflettere l'evoluzione del processo, il che richiede un'infrastruttura tecnica adeguata e personale competente in grado di gestire l'intero ciclo di vita del modello, dal training all'implementazione fino alla validazione.

Nonostante le complessità le carte basate su reti neurali offrono un controllo che supera di gran lunga l'approccio tradizionale. Non si limitano a segnalare un valore fuori scala, ma sono in grado di riconoscere dinamiche, identificare *pattern* sottili e persino anticipare il degrado di un processo prima che diventi evidente. In contesti dove efficienza, precisione e prevenzione sono fondamentali, questo tipo di carta può diventare un alleato strategico per mantenere alti standard di qualità e ridurre i tempi di inattività [46].

In sintesi, utilizzare reti neurali nel controllo statistico di processo significa passare da un controllo basato su soglie a uno che si fonda sulla comprensione del comportamento complessivo del sistema. È una scelta audace, ma se supportata da dati solidi, risorse tecniche adeguate e una gestione attenta, può portare a risultati che nessun'altra carta di controllo può eguagliare.

Di seguito vengono riportate tre diverse tabelle (Tabella 6, Tabella 7 e Tabella 8), che sintetizzano le diverse tipologie delle carte di controllo.

Tabella c: Caratteristiche principali delle carte di controllo basate su ML

Carte di Controllo Tradizionali basate su ML	
Tipo di Carta	Caratteristiche Principali
Predittiva	Le carte di controllo predittive oltre ad osservare il valore attuale durante il processo, forniscono anche una stima dei valori futuri grazie all'implementazione dei modelli di Machine Learning che vengono confrontati con i limiti di controllo per individuare possibili anomalie in anticipo. Dunque, si tratta di una carta di controllo che prevede anomalie/fuori controllo futuri, invece di assettare che si verifichino. Si sposta il focus dal monitorare al prevenire
Adattiva	Le carte di controllo adattive sono pensate per aggiornare i limiti di controllo durante il processo produttivo (in tempo reale o in intervalli regolari); ciò è reso possibile grazie all'integrazione di modelli/algoritmi di Machine Learning
Classificazione	Tale approccio basato sul ML consente di addestrare un modello di ML a distinguere/classificare condizioni di processo OK o NOK, ossia "normali" e "non normali/anomalie"; ciò si basa sui dati storici che sono stati etichettati (SI/NO) e sui metodi non supervisionati. Dunque, la carta di controllo in questione non è caratterizzata da limiti di controllo fissi, ma da una decisione binaria
Non supervisionata	Le carte di controllo non supervisionate usano algoritmi di Machine Learning per rilevare anomalie senza bisogno di dati etichettati. Analizzano la struttura dei dati per identificare comportamenti atipici, basandosi sull'assunzione che la normalità sia riconoscibile.
Ibrida	Approccio flessibile per il monitoraggio nei processi produttivi che grazie ai modelli di ML le carte tradizionali vengono implementate con la capacità adattiva e predittiva
Rete Neurale	Tale approccio è sempre più diffuso per il monitoraggio, soprattutto in processi industriali complessi dove i metodi tradizionali non sono sufficienti. In tal caso viene combinato l'approccio classico del monitoraggio statistico con la capacità predittiva delle reti neurali artificiali

Tabella 7: Vantaggi e Svantaggi delle carte di controllo basate su ML

Carte di Controllo Tradizionali basate su ML		
Tipo di Carta	Vantaggi	Svantaggi
Predittiva	Permette di intervenire prima che si verifichi una deviazione, ideale per processi lenti, riduce gli scarti e i costi grazie al controllo e alla manutenzione preventiva, adatto a processi dinamici e complessi ove i limiti statici non sono sufficienti	Richiede molti dati storici che siano ben strutturati, modelli come LSTM sono più complessi da applicare/addestrare, serve una continua manutenzione e aggiornamento per poter tenere conto dei cambiamenti nel processo, meno interpretabile dal momento che spiegare perché un valore futuro sarà anomalo è più complesso
Adattiva	Consente di rilevare in maniera più accurata eventuali deviazioni/anomalie, riducendo così i falsi allarmi, si adattano meglio a contesti più dinamici e non stazionari	Tuttavia, queste carte presentano alcuni svantaggi come: costi di implementazione più alti, maggiore complessità nella programmazione, più difficili da interpretare e necessitano di dati in input di qualità/completi
Classificazione	Uno dei vantaggi è che non richiede la definizione di limiti numeri statici, si può anche utilizzare in contesti più complessi e non lineari, può essere aggiornato durante l'avanzare del processo ed infine ha la capacità di rilevare anche piccole anomalie	Uno dei principali limiti è quello che richiede dati etichettati per l'addestramento dell'algorithmo, che non sempre sono disponibili. Pertanto, se il modello non viene configurato correttamente, ciò potrebbe portare a falsi allarmi e, infine, è più difficile da interpretare rispetto ad una carta tradizionale
Non supervisionata	Il principale vantaggio è quello di funzionare anche in assenza di dati etichettati. Inoltre hanno un'ottima capacità di individuare pattern atipici e si adattano bene a processi altamente variabili	Tuttavia, non distinguono il tipo di anomalia ma individuano solo ciò che è diverso. È maggiore il rischio di falsi allarmi o di non rilevare anomalie poco evidenti. Infine, i risultati sono difficili da interpretare e il modello è sensibile alla scelta dei parametri e alla qualità dei dati
Ibrida	Maggiore capacità rispetto alle carte tradizionali, adatto anche a processi multivariati e non lineari, possibilità di rilevare pattern più nascosti e riduce i falsi allarmi	Maggiore complessità di sviluppo e computazionale, richiede dati e che siano puliti e interpretabilità ridotta, infine occorre manutenzione periodica per seguire l'evoluzione del processo
Rete Neurale	Le reti neurali sono in grado di approcciare relazioni complesse e multivariate, ideali quando il processo non è lineare e i modelli statistici non sono sufficienti, rileva anomalie complesse	Richiede addestramento su dati normali del processo, necessita di una manutenzione periodica, più costosa e ovviamente a livello computazionale più complessa

Tabella 8: Esempi di Algoritmi e ipotesi delle carte di controllo basate su ML

Carte di Controllo Tradizionali basate su ML		
Tipo di Carta	Esempi di Algoritmi ML utilizzati	Ipotesi
Predittiva	<p>LSTM (Long Short-Term Memory) rappresenta una variante delle reti neurali RNN ed è ideale in quei processi industriali dove lo stato attuale dipende da più eventi passati;</p> <p>ARIMA (Auto Regressive Integrated Moving Average);</p> <p>Modelli ibridi (deep learning);</p> <p>Autoencoder che è una rete neurale artificiale progettata per ricostruire gli input in uscita. in altre parole, l'Autoencoder comprime i dati e poi li ricostruisce</p>	<p>Occorre che i dati storici contengano informazioni predittive valide, i dati devono essere stabili, completi e affidabili, il modello deve poter apprendere le dinamiche del processo e gli errori di previsioni devono essere stimabili per poter definire limiti validi</p>
Adattiva	<p>Regressione lineare (ML supervisionato), ove i limiti si adattano in base alla media prevista del processo;</p> <p>Reti neurali, come: RNN e LSTM, ove apprendono gli schemi e le dinamiche del processo e adattano i limiti di controllo in funzione di queste previsioni;</p> <p>Random Forest che si basa sull'approccio degli alberi decisionali e fornisce una stima del peso/importanze che hanno le variabili;</p>	<p>I dati storici utilizzati devono rappresentare bene il modello;</p> <p>Le relazioni tra variabili stabili nel tempo e vi è indipendenza e autocorrelazione nei dati;</p> <p>La capacità adattiva del modello di ML deve essere stabile nel tempo, altrimenti occorre un meccanismo di ri-addestramento periodico.</p>
Classificazione	<p>Support Vector Machine (SVM) che, come scopo, ha quello di creare un iperpiano di separazione ottimale tra classi</p> <p>Decision Tree, che divide lo spazio secondo regole logiche (ad esempio, "se...allora.");</p> <p>KNN (K-Nearest Neighbors) Il KNN classifica una nuova osservazione in base ai K vicini più simili; A quel nuovo punto assegna la classe più votata</p>	<p>Le classi "OK" e "NO OK" si possano definire chiaramente e che i dati forniti siano sufficienti per distinguere i casi di controllo e fuori controllo;</p> <p>Si richiede che la distribuzione dei dati sia stabile nel tempo e che le osservazioni siano indipendenti e che il modello venga aggiornato</p>
Non supervisionata	<p>Autoencoder</p> <p>Isolation Forest</p> <p>DBSCAN / K-Means – per clustering e individuazione di punti lontani.</p> <p>PCA (Principal Component Analysis)</p>	<p>Per un corretto funzionamento si ipotizza che i dati normali formano una struttura riconoscibile, che le anomalie siano rare e divergano significativamente dalla normalità. Infine, che i dati in input siano affidabili e coerenti con il processo</p>
Ibrida	<p>PCA (Principal Component Analysis) è un metodo che permette di ridurre la dimensionalità dei dati e la complessità nei sistemi con molte variabili e costruire carte di controllo multivariate più appropriate e gestibili</p> <p>Autoencoder</p> <p>SVM, Decision Tree, Reti Neurali, CNN</p>	<p>La struttura del processo può essere appresa dal modello ML, i dati utilizzati per l'addestramento rappresentano il comportamento abituale del processo e quest'ultimo non cambia significativamente nel tempo, occorre utilizzare/scegliere carte SPC con criterio</p>
Rete Neurale	<p>MLP (Multilayer Perceptron) ove la differenza tra valore reale e predetto può essere tracciato su una carta di controllo</p> <p>LSTM</p> <p>Autoencoder</p> <p>CNN individua un pattern, ideale per le immagini</p>	<p>Richiede l'esistenza di una struttura regolare e normale da cui apprendere; Una deviazione significativa tra valore reale e valore predetto indica un comportamento anomalo, la distribuzione dei dati deve restare stabile nel tempo</p>

4.2 Gli Algoritmi di *ML* per le carte di controllo

Gli algoritmi di *ML* sono fondamentali per il corretto funzionamento delle carte di controllo basate su *machine learning*. Difatti essi rappresentano il fulcro del funzionamento delle carte di controllo in questione, poiché a seconda del tipo di algoritmo scelto ci si orienta verso una certa tipologia di carta di controllo piuttosto che un'altra. Tali algoritmi possono essere categorizzati in base al tipo di scenario a cui sono sottoposti durante il processo di apprendimento. Come già delineato nei capitoli precedenti, si è soliti a suddividere i paradigmi dell'apprendimento automatico in tre sezioni [47]:

- supervisionato: si costruisce un modello a partire dai dati di addestramento etichettati, in quanto l'obiettivo è elaborare una regola che associ input e output corrispondente;
- non supervisionato: si costruisce un modello a partire dai dati di addestramento non etichettati o senza un corrispondente valore di output, in quanto l'obiettivo è identificare dei pattern negli input al fine di riprodurli o prevederli;
- con rinforzo: l'obiettivo è progettare un sistema che, attraverso le interazioni con l'ambiente, migliori le proprie performance.

Particolare attenzione va posta sul primo approccio, poiché viene utilizzato nella fase sperimentale su cui si basano gli altri due approcci e, inoltre, la maggior parte delle applicazioni utilizza algoritmi di apprendimento supervisionato.

Gli algoritmi che si appoggiano all'apprendimento supervisionato sono utilizzati in diversi settori e hanno la capacità di effettuare ipotesi induttive, cioè ipotesi che si ottengono dall'analisi di una serie di problemi per ottenere una soluzione idonea ad un problema di tipo generale. All'interno dell'apprendimento supervisionato, possiamo distinguere due categorie principali di algoritmi [48]:

- *algoritmi di classificazione*: hanno il compito di assegnare ogni osservazione a una classe ben definita tra un insieme finito di categorie, come ad esempio distinguere tra un prodotto conforme e uno non conforme;
- *algoritmi di regressione*: i quali forniscono un valore numerico continuo, come una misura di scostamento da una specifica o una previsione sulla durata di un processo.

Tale distinzione è cruciale perché aiuta a scegliere l'algoritmo più adatto al problema da risolvere, alla natura dei dati disponibili e al tipo di output richiesto. Tra gli algoritmi più

utilizzati nel controllo qualità ci sono metodi come *Support Vector Machine* (SVM), *Decision Tree*, *Random Forest* e tecniche di *Deep Learning* basate su reti neurali artificiali. Ognuno di questi approcci ha i suoi vantaggi e limiti specifici, che verranno delineate nei paragrafi successivi [49].

4.2.1 *Support Vector Machines (SVMs)*

Le *SVM* sono tra gli algoritmi di apprendimento supervisionato più solidi e affermati nel campo del *ML*, particolarmente indicati per affrontare problemi di classificazione binaria. Nel contesto industriale e produttivo, stanno trovando sempre più applicazione nei sistemi di monitoraggio statistico della qualità, specialmente quando si desidera creare una carta di controllo intelligente che superi i limiti statici delle carte di controllo tradizionali [50].

Il concetto chiave di una *SVM* è quello di separare le osservazioni di due classi distinte (come, ad esempio, il normale stato del processo rispetto a quello anomalo) tramite un iperpiano di separazione ottimale, come si vede in Figura 4. Tale iperpiano non viene scelto a caso: l'obiettivo è quello di trovare la retta di separazione delle classi che massimizza il margine tra le classi stesse, identificando il margine come la distanza minima tra la retta e i punti delle due classi. Il calcolo della retta viene fatto utilizzando solo una porzione del *data set*, ovvero i valori di una classe che più si avvicinano alla retta di separazione, chiamati «vettori di supporto». I vettori di supporto rappresentano i dati dell'insieme di training classificabili con maggiore difficoltà [51].

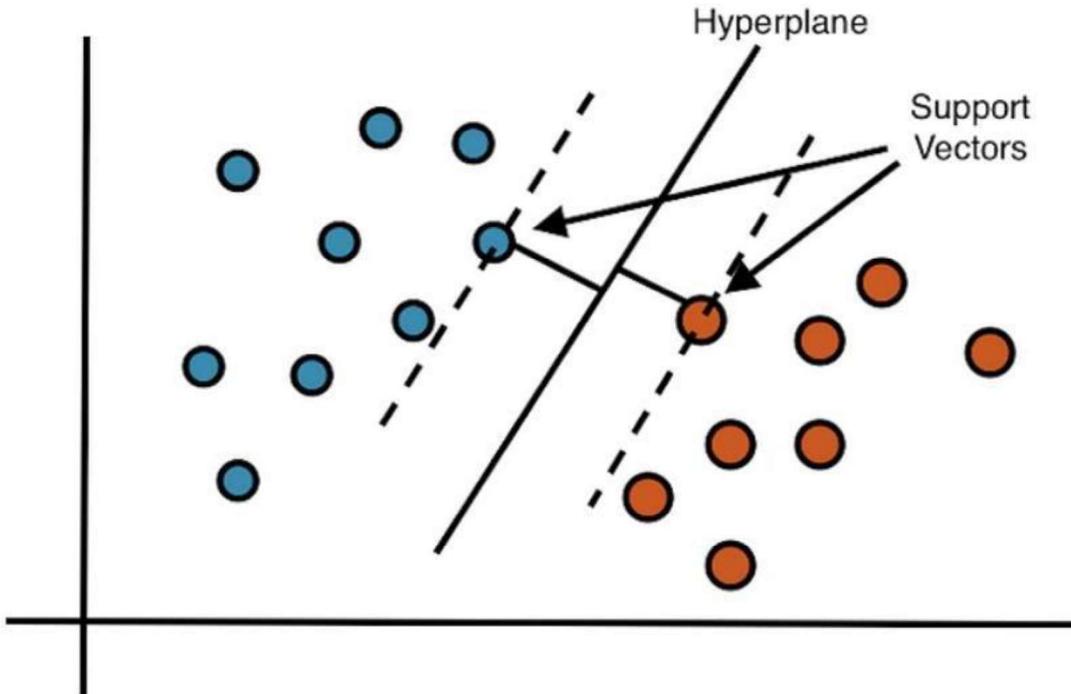


Figura 4: Rappresentazione grafica di un iperpiano delle SVM

Ref: <https://ichi.pro/it/spiegazione-di-support-vector-machine-svm-57743104c50515>

Uno dei principali vantaggi delle *SVM* è la loro abilità di operare anche in spazi ad alta dimensionalità, rendendole perfette per applicazioni industriali dove le variabili di input sono numerose e interconnesse. Inoltre, le *SVM* possono anche affrontare casi non linearmente separabili. In questi casi, i dati vengono implicitamente mappati in uno spazio di dimensioni superiori, dove esiste una separazione lineare tra le classi.

Nel contesto delle carte di controllo, una *SVM* viene addestrata su un *dataset* storico etichettato che include esempi sia di processi in condizioni normali sia di situazioni di fuori controllo. Una volta completato l'addestramento, la *SVM* è capace di classificare nuovi dati di processo in tempo reale, decidendo se lo stato attuale rientra nella normalità o se rappresenta un'anomalia. Questo approccio permette di spostare l'attenzione dal semplice monitoraggio di soglie numeriche fisse a una variazione multivariata del comportamento complessivo del processo.

Un esempio di applicazione di tale approccio è il monitoraggio di sistemi complessi, come le linee produttive automatizzate, gli impianti chimici o i processi di precisione, dove molte variabili interagiscono in modi non lineari. In questi casi, una carta di controllo basata su *SVM* può considerare simultaneamente decine di parametri per stabilire se il processo è

sotto controllo o meno, fornendo una classificazione binaria o probabilistica che può essere utilizzata come segnale di allerta o preallerta.

L'efficacia delle *SVM* presenta però alcune criticità e limiti. Prima di tutto si tratta di modelli piuttosto complessi, specialmente quando si tratta di scenari non lineari. Ciò può rendere difficile l'interpretazione del modello, un aspetto cruciale in contesti produttivi dove è fondamentale capire le cause di un'anomalia per poter intervenire in modo tempestivo e mirato. Inoltre le *SVM* sono molto sensibili alla scelta dei parametri che devono essere selezionati in maniera accurata. Una scelta non ottimale dei parametri rischia di portare ad una situazione di *over fitting*, ossia quando il modello si adatta troppo ai dati di training, o *under fitting*, cioè quando il modello è troppo semplice per apprendere la complessità del processo [52].

Inoltre ci sono anche alcuni limiti. Dal punto di vista computazionale, ad esempio, le *SVM* possono diventare gravose in termini di tempo e risorse quando si lavora con *dataset* molto grandi, poiché la complessità dell'ottimizzazione di un margine aumenta con il numero di osservazioni. Inoltre, un modello addestrato non è facilmente aggiornabile: per integrare nuovi dati o adattarsi ad un processo in evoluzione, spesso è necessario riaddestrare totalmente il modello.

Le ipotesi fondamentali su cui si basa una *SVM* meritano sicuramente attenzione. Il modello presuppone che ci sia una separazione tra le classi e che le osservazioni siano *i.i.d.*, ossia indipendentemente e identicamente distribuite. Tuttavia nella realtà, i dati di processo tendono ad essere autocorrelati e a subire variazioni temporali che infrangono questa ipotesi, rendendo necessaria una preelaborazione dei dati.

Nonostante tali limitazioni, le *SVM* sono viste come una scelta eccellente in molti studi scientifici per la creazione di carte di controllo intelligenti. Ad esempio, è noto come l'uso delle *SVM* può migliorare notevolmente la capacità di rilevamento delle anomalie in maniera preventiva, specialmente in contesti multivariati complessi. In conclusione, l'adozione delle *SVM* nelle carte di controllo per la qualità rappresenta un passo significativo verso un controllo intelligente dei processi produttivi. Se utilizzate propriamente, offrono un'accuratezza elevata, una forte capacità di generalizzazione e una notevole flessibilità nel modellare processi reali. È fondamentale avere una buona comprensione del processo e disporre di un'infrastruttura adeguata a sfruttare appieno i vantaggi.

4.2.2 *Random Forest*

Il *Random Forest* è uno degli algoritmi di apprendimento supervisionato più utilizzati nel contesto del *ML*. È usato per lo più per la sua robustezza e abilità nel gestire problemi complessi di classificazione e regressione. A differenza di altri modelli che si basano su una struttura decisionale, come nel caso dei *Decision Tree*, il *Random Forest* adotta un approccio di *ensemble learning*. In altre parole, costituisce una «foresta» di alberi decisionali e combina le loro previsioni per migliorare l'accuratezza e ridurre il rischio di errori [53].

Al fine di comprendere in maniera più accurata il *Random Forest*, è utile delineare il concetto di *Decision Tree*. Un *Decision Tree* è una struttura ad albero che dirige le decisioni, suddividendo progressivamente i dati in sottoinsiemi più omogenei, in base alle caratteristiche più informative. Ogni nodo dell'albero rappresenta una decisione basata su una variabile del *dataset*, e i rami portano a possibili esiti. L'albero continua a ramificarsi fino a raggiungere delle foglie che rappresentano la previsione finale. Tuttavia i *Decision Tree* sono strutture fragili, ossia sono facilmente influenzabili dai dati di addestramento e, se non vengono potati o calibrati correttamente, rischiano di overfittare, cioè di adattarsi troppo ai dati storici senza riuscire a generalizzare bene sui dati nuovi.

Il *Random Forest*, invece, supera il limite descritto soprastante creando numerosi alberi decisionali indipendenti, ognuno dei quali viene addestrato su un campione casuale del *dataset*, una tecnica nota come *bootstrap aggregating*. Inoltre, mentre ogni albero cresce, l'algoritmo seleziona casualmente un sottoinsieme delle caratteristiche disponibili per ogni divisione, il che riduce ulteriormente la varianza e aumenta la robustezza. Infine per ogni nuova osservazione, ogni albero fornisce una previsione, e la foresta combina questi risultati attraverso il voto di maggioranza (per la classificazione) o la media (per la regressione) [54].

Nel contesto delle carte di controllo per la qualità, il *Random Forest* viene impiegato per costruire modelli capaci di prevedere se lo stato di un processo produttivo sia conforme o anomalo, basandosi su una serie di variabili di processo osservate in tempo reale. Questo approccio consente di traslare dal monitoraggio basato su semplici soglie fisse ad un modello multivariato che integra dinamicamente più parametri. Il principale vantaggio di questo metodo è la sua capacità di rilevare combinazioni complesse di condizioni operative che potrebbero indicare un rischio di fuori controllo, anche quando ciascuna singola variabile sembra rimanere nei limiti di controllo.

Uno dei punti di forza del *Random Forest* è la sua abilità nel gestire dati ad alta dimensionalità, ovvero *dataset* con molte variabili, anche se correlate tra loro. Questo modello è capace di fornire una classifica dell'importanza delle variabili, utile al fine di comprendere quali fattori influenzano maggiormente la qualità del prodotto o la stabilità del processo. Questo è particolarmente vantaggioso non solo nel monitoraggio, ma anche per ottimizzare i parametri di processo e diagnosticare le cause di eventuali scostamenti.

Nonostante la sua solidità, il *Random Forest* ha alcune criticità. In primis, l'interpretabilità del modello è inferiore rispetto a quella di un singolo albero decisionale, il che può rendere difficile spiegare in modo semplice perché una certa osservazione sia stata classificata come anomala. Dal punto di vista computazionale, invece, addestrare e utilizzare una foresta composta da molti alberi può richiedere molte risorse, specialmente con *dataset* di grandi dimensioni. Inoltre, il *Random Forest* può avere difficoltà in presenza di classi sbilanciate, ossia quando i dati di una delle due classi sono molto meno numerosi rispetto all'altra, il che richiede l'uso di tecniche di bilanciamento.

Le ipotesi su cui si basa il *Random Forest* non sono particolarmente rigide, il che lo rende ideale per un'ampia gamma di applicazioni industriali. Tuttavia, si presume che le osservazioni siano indipendenti e distribuite in modo identico (i.i.d), un'ipotesi che non sempre si applica ai dati di processo, che spesso presentano autocorrelazioni o tendenze temporali. In tali situazioni, è importante processare i dati in maniera adeguata a garantire che il modello sia valido [55].

Le prestazioni di questo sistema sono particolarmente apprezzate in contesti produttivi con alta variabilità, ove è fondamentale gestire grandi volumi di dati provenienti da sensori e sistemi di monitoraggio. In sostanza, adottare il *Random Forest* nelle carte di controllo per la qualità è una scelta strategica. Tale metodo è in grado di anticipare le deviazioni nei processi e di promuovere un miglioramento continuo. Tuttavia, come per ogni modello avanzato, è essenziale avere una solida infrastruttura tecnologica e le competenze necessarie per gestirne lo sviluppo, la validazione e l'aggiornamento nel tempo.

4.2.3 *Deep Learning* e Reti Neurali

Negli ultimi anni, il *Deep Learning* ha rivoluzionato l'ambito del *ML*, portando con sé modelli altamente prestazionali per analizzare dati complessi. In particolare, le reti neurali profonde (DNN) e le reti neurali convoluzionali (CNN) sono diventate strumenti

fondamentali nel controllo della qualità industriale, grazie alla loro abilità di apprendere automaticamente rappresentazioni di alto livello dai dati grezzi. Ad oggi, queste tecnologie sono sempre più integrate nei sistemi di carte di controllo avanzate, progettati per monitorare in tempo reale il comportamento dei processi produttivi, individuare anomalie e prevenire difetti.

Una rete neurale, descritta in maniera semplificata, si ispira alla struttura del cervello umano, come si può notare dalla Figura 5:

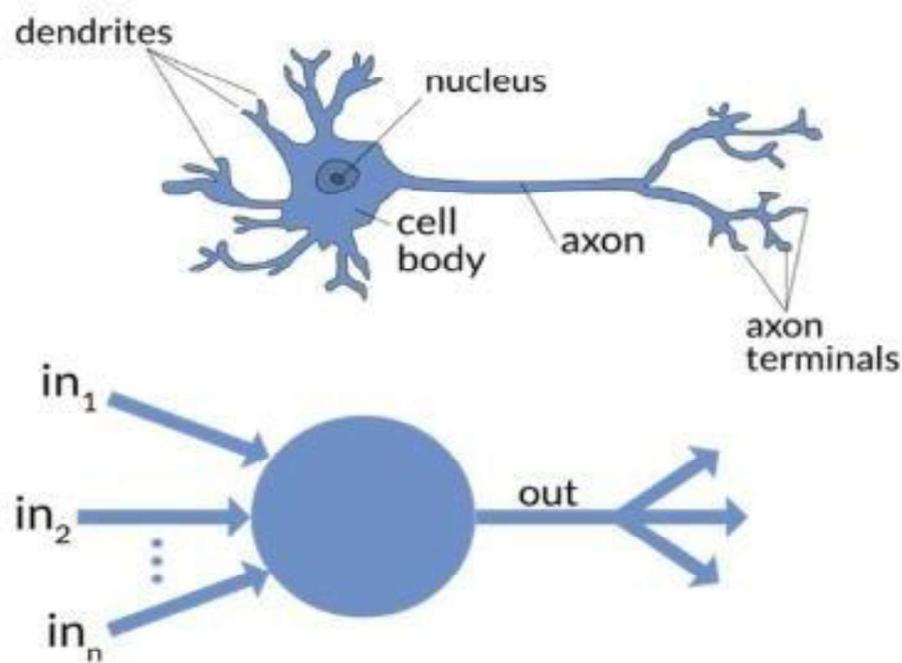


Figura 5: Rappresentazione schematica di una rete neurale

Ref: <https://dreams.news/articles/reti-neurali-artificiali-quando-l-it-si-ispira-al-cervello-biologico-parte-1>

Una rete neurale artificiale invece, rappresentata in Figura 6, è composta da neuroni artificiali disposti in strati che trasformano progressivamente le informazioni ricevute. Ogni neurone riceve segnali in ingresso, li elabora tramite una funzione di attivazione e produce un segnale in uscita che viene poi trasmesso ai neuroni dello strato successivo. A differenza delle reti più semplici, le reti neurali profonde includono un numero maggiore di strati nascosti, permettendo di apprendere modelli altamente complessi e non lineari.

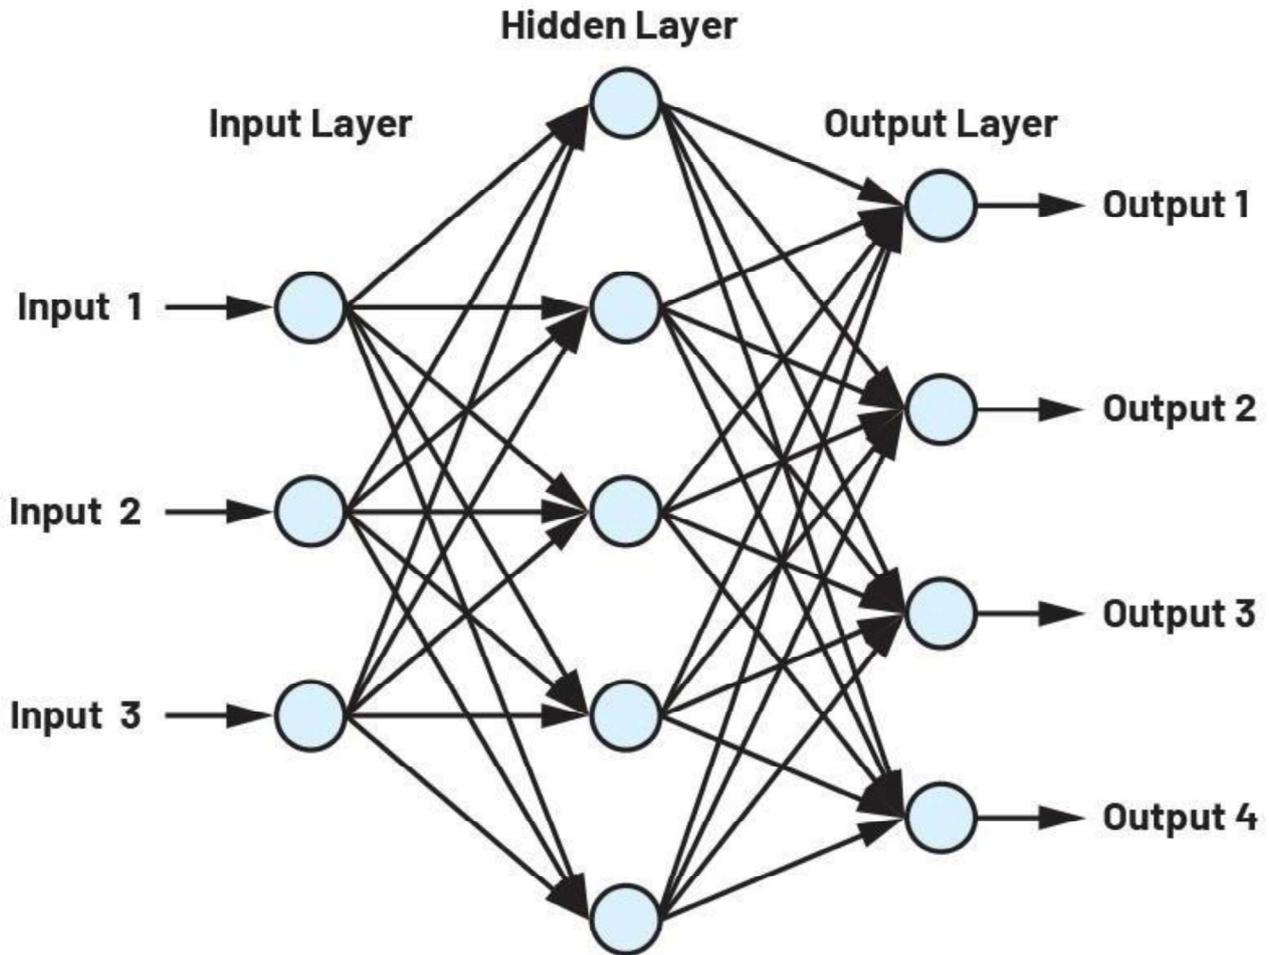


Figura c: Rappresentazione schematica di una rete neurale artificiale

Ref: <https://www.elettronicanews.it/reti-neurali-convoluzionali-cose-il-machine-learning/>

Nell'ambito delle carte di controllo qualitative, il *Deep Learning* ha rivoluzionato le regole del gioco, passando da un controllo basato su limiti fissi ad un approccio più intelligente che si basa sul comportamento complessivo del processo. Grazie alle reti neurali è possibile analizzare simultaneamente centinaia di variabili di processo, sia numeriche che di altro tipo, e costruire modelli che apprendono come queste variabili influenzano la qualità del prodotto.

Un esempio comune di questo approccio è l'uso degli *Autoencoder*, una particolare architettura di rete neurale non supervisionata, sviluppata per ricostruire i dati di input in modo preciso. Addestrando un *Autoencoder* solo con dati di processo normali, il sistema riesce a imparare una rappresentazione compatta di ciò che è considerato normale. Durante il monitoraggio, se i dati attuali non possono essere ricostruiti correttamente

dall'*Autoencoder*, l'errore di ricostruzione diventa un campanello d'allarme che segnala un possibile stato di controllo non ottimale.

Un'altra architettura molto popolare è la *Convolutional Neural Network* (CNN), particolarmente efficace nell'elaborazione di immagini o segnali. Le CNN sono ampiamente utilizzate nel controllo visivo automatizzato, ad esempio, per ispezionare superfici, saldature, tessuti o componenti elettronici. Integrare le CNN nelle carte di controllo visive consente di individuare micro-difetti o imperfezioni che sfuggono ai metodi tradizionali o all'occhio umano.

Oltre agli *Autoencoder* e alle *CNN*, anche le *Reti Neurali Ricorrenti* (RNN) e le loro varianti più sofisticate, come la *Long Short-Term Memory* (LSTM), sono fondamentali per il monitoraggio di processi temporali. Tali tecnologie particolarmente utili in contesti come le linee di produzione continue, grazie alla loro abilità di modellare sequenze temporali e di individuare anomalie legate all'evoluzione del processo [56].

Integrare tali architetture nelle carte di controllo porta con sé numerosi vantaggi. Le reti neurali possono gestire dati ad alta dimensionalità e non strutturati, modellare relazioni non lineari e catturare interazioni complesse tra variabili. Inoltre, offrono la flessibilità di operare in modalità supervisionata, non supervisionata, adattandosi così a diversi livelli di conoscenza del sistema.

L'adozione del *Deep Learning* presenta anche delle sfide. In primo luogo i modelli neurali, specialmente quelli più complessi, necessitano di grandi quantità di dati per essere addestrati in modo efficace, il che potrebbe essere problematico in contesti dove le anomalie sono rare o poco delineate. Inoltre le reti neurali sono spesso viste come delle «scatole nere», poiché è difficile spiegare in modo chiaro e trasparente perché una certa osservazione venga classificata come anomala. Tale aspetto di mancanza di interpretabilità è particolarmente critico nei settori regolamentati, ove è fondamentale avere chiarezza e trasparenza e giustificare le decisioni di qualità. Un altro aspetto critico da considerare è il costo computazionale. L'addestramento di modelli di *deep learning* richiedono hardware significative, che potrebbero non essere sempre accessibili o giustificabili, soprattutto in contesti industriali di piccole o medie dimensioni.

Nonostante le basi del *Deep Learning* siano meno rigide rispetto ai modelli statistici tradizionali, ci sono comunque alcune ipotesi da considerare. In particolare si presume che i dati siano rappresentativi delle condizioni reali del processo e che siano disponibili in

quantità sufficiente per garantire un apprendimento efficace. Inoltre è fondamentale che gli stessi siano di buona qualità, privi di errori o rumori eccessivi che potrebbero compromettere la fase di addestramento [57].

In conclusione il *Deep Learning* e le reti neurali sono tecnologie chiave per creare carte di controllo intelligenti e adattive, in grado di monitorare in tempo reale processi complessi e multivariati. Offrono un livello di controllo senza precedenti, ma richiedono infrastrutture adeguate, competenze avanzate e un approccio metodico nella gestione dei dati. Se progettate e integrate correttamente, queste tecnologie possono rivoluzionare il modo in cui le aziende garantiscono la qualità, riducendo gli scarti, costi e rischi operativi.

Capitolo 5

5. Risultati e Implicazioni della ricerca

5.1 Principali risultati emersi

Uno degli aspetti più interessanti emersi da questo lavoro è il confronto tra le tradizionali carte di controllo e quelle che utilizzano tecniche di *ML*. L'analisi ha rivelato che le carte *ML* non sono solo un semplice aggiornamento tecnico, ma rappresentano una vera e propria evoluzione nel modo di lavorare. A differenza degli approcci statistici classici - che spesso si basano su ipotesi rigide e poco in linea con la realtà produttiva attuale - le carte *ML* si dimostrano strumenti dinamici, adattabili e molto più in sintonia con i processi industriali moderni.

Uno dei punti di forza principali è la capacità predittiva; questi strumenti non si limitano a registrare le deviazioni dopo che si sono verificate, ma apprendono dai dati in tempo reale, anticipando i difetti e suggerendo interventi prima che il problema possa influire sulla qualità. La loro flessibilità operativa e la capacità di gestire dati complessi e multivariati le rendono estremamente efficaci in contesti ad alta variabilità, come quelli caratterizzati da produzione personalizzata, lotti ridotti e alta automazione.

Mentre le carte tradizionali possono perdere in precisione, le carte *ML* mantengono una sensibilità e un'affidabilità superiori. È particolarmente significativo che queste soluzioni siano perfettamente compatibili con gli ecosistemi digitali emergenti: sistemi IoT, fabbriche intelligenti e ambienti cyber-fisici. In questi contesti, l'integrazione delle carte *ML* nei flussi informativi aziendali permette di chiudere il cerchio tra dati, controllo e decisione operativa in modo fluido e continuo [58].

Ciò che emerge con chiarezza è che l'impatto delle carte *ML* va ben oltre l'aspetto tecnico. La loro adozione non solo richiede, ma stimola anche un cambiamento profondo, una vera e propria trasformazione culturale e organizzativa. La qualità, che prima era vista come una funzione settoriale e reattiva, si evolve in un processo trasversale, predittivo e strategico. Questo richiede nuove competenze, una maggiore collaborazione tra i vari reparti

(produzione, IT, qualità) e una revisione degli standard operativi e normativi. In altre parole, l'innovazione non si limita agli strumenti, ma abbraccia l'intera struttura aziendale.

In sintesi i risultati ottenuti confermano che le carte di controllo basate su *ML* non sono solo un progresso tecnologico. Rappresentano un vero e proprio cambio di prospettiva nella gestione della qualità, trasformandola in una leva strategica per affrontare le sfide e cogliere le opportunità dell'Industria 5.0. Se adottate correttamente, hanno il potenziale di migliorare non solo l'efficienza e l'affidabilità, ma anche la resilienza, la sostenibilità e l'intelligenza complessiva dei processi produttivi.

5.2 Implicazioni pratiche

I risultati di questo lavoro mettono in evidenza che il controllo qualità, come lo conosciamo nell'ambito dell'Industria 4.0, ha bisogno di una revisione profonda per allinearsi con i principi più avanzati dell'Industria 5.0. Le aziende manifatturiere che vogliono rimanere competitive non possono più considerare il controllo qualità come un aspetto secondario o statico. Questo deve diventare un elemento centrale per l'innovazione e la sostenibilità del loro modello produttivo. Il cambiamento non riguarda solo gli strumenti, ma coinvolge l'intero ecosistema aziendale, dalle tecnologie utilizzate, all'organizzazione interna, fino alle competenze delle persone.

Tuttavia la scelta della carta di controllo basata su *ML* non è affatto una scelta facile e scontata. Difatti, come si è visto nel corso dell'elaborato, esistono varie tipologie di carte di controllo. Al fine di fare maggiore chiarezza, di seguito viene riportata la Tabella 9 che dimostra che non esiste un'unica soluzione valida per tutti i contesti. La scelta della tipologia di carta deve considerare diversi fattori: complessità del processo, tipo di dati disponibili, obiettivi strategici e livello di tecnologia dell'azienda. Comprendere vantaggi e limiti delle diverse soluzioni *ML* consente di adottare un approccio più consapevole ed efficace nella modernizzazione del controllo qualità.

Tabella 5: Contesto applicativo delle carte basate su ML

Tipo di Carta ML	Funzionalità Principali	Vantaggi	Svantaggi	Contesto Ideale
Carte Predittive	Prevedono i difetti prima che si manifestino	Anticipano i problemi, migliorano l'efficienza	Richiedono dati di alta qualità	Produzioni ad alta variabilità e difetti ricorrenti
Carte Adattive	Adattano automaticamente i limiti di controllo	Flessibilità in tempo reale, limiti dinamici	Sensibili ai cambi di processo improvvisi	Processi dinamici in continuo cambiamento
Carte Classificazione per	Classificano i prodotti in base alla conformità	Decisioni rapide su conformità / non conformità	Dipendono da modelli di classificazione ben addestrati	Controllo qualità rapido su grandi volumi
Carte Non-Supervisionate	Rilevano pattern e anomalie senza etichette	Funzionano anche senza output noti	Difficili da interpretare, rischio over fitting	Sistemi con scarsa conoscenza a priori
Carte Ibride	Combinano approcci statistici e modelli ML	Compromesso tra precisione e trasparenza	Richiedono tuning avanzato	Transizione tra carte tradizionali e avanzate
Carte Neurali	Usano reti neurali per sistemi complessi	Gestiscono dati non lineari e dinamici	Bassa interpretabilità, alta complessità computazionale	Processi critici con immagini, segnali o dati complessi

5.2.1 Azioni concrete per innovare il controllo qualità

Per innovare il controllo qualità è fondamentale avere un piano d'azione chiaro e progressivo. Un primo passo consiste nella digitalizzazione della raccolta dei dati, utilizzando sensori IoT e sistemi interconnessi per ottenere informazioni tempestive, affidabili e in tempo reale. Successivamente è essenziale costruire una base dati solida, ben

strutturata e pulita, che è la condizione necessaria per applicare modelli di *ML* in modo efficace.

Un approccio cauto, ma efficace prevede l'introduzione iniziale di strumenti di *ML* in modalità ibrida, combinando i metodi tradizionali con soluzioni intelligenti in contesti pilota, dove è possibile monitorare i risultati e perfezionare l'applicazione. È anche molto utile la collaborazione con partner esterni come università, centri di ricerca e fornitori tecnologici, per accedere a competenze avanzate e accelerare l'apprendimento interno.

5.2.2 Cambiamenti a livello organizzativo

Adottare carte di controllo basate su *ML* richiede un cambiamento organizzativo significativo. È essenziale rompere i silos informativi tra produzione, qualità e IT, promuovendo una comunicazione fluida e continua tra i vari reparti. È fondamentale coltivare una cultura aziendale che abbracci la sperimentazione e l'innovazione, dove gli errori non sono visti come fallimenti, ma come opportunità di apprendimento.

Anche i processi decisionali devono subire un'evoluzione: i dati e le analisi generate dai sistemi intelligenti devono essere integrati con momenti di valutazione, correzione e miglioramento. Questo richiede la creazione di team interfunzionali e l'introduzione di nuove figure professionali, come *data scientist*, analisti predittivi e ingegneri dell'automazione, capaci di tradurre i dati in decisioni operative.

5.2.3 Nuove competenze e strumenti richiesti

Il controllo qualità del futuro richiede nuove competenze a tutti i livelli dell'organizzazione. La cosiddetta *data literacy*, ovvero la capacità di comprendere, interpretare e utilizzare i dati, deve diventare una competenza comune, non solo appannaggio degli specialisti. Gli ingegneri della qualità, in particolare, dovranno familiarizzare con i concetti fondamentali dell'intelligenza artificiale, degli algoritmi di *ML* e delle logiche predittive.

Oltre alle competenze, le aziende dovranno investire in infrastrutture adeguate, come le piattaforme digitali avanzate per la raccolta, la visualizzazione e l'analisi dei dati, gli ambienti integrati per il monitoraggio in tempo reale e gli strumenti che consentano non solo di reagire, ma anche di anticipare. Senza questo investimento tecnologico e culturale, il potenziale delle carte *ML* rischia di rimanere inespresso [59].

In conclusione, innovare il controllo qualità nell'era dell'Industria 5.0 non significa solo adottare nuovi strumenti, ma ripensare il proprio modo di operare. È una trasformazione che coinvolge processi, persone e visione strategica.

5.3 Analisi economica dell'adozione del *ML* nel controllo qualità

L'adozione delle carte di controllo basate su *ML* non è solo un passo avanti nella tecnologia, ma rappresenta un vero e proprio investimento strategico capace di creare un valore economico tangibile. Grazie alla loro capacità predittiva, questi strumenti permettono di intervenire rapidamente per prevenire difetti, ottimizzare i processi e ridurre in modo significativo i costi legati alla scarsa qualità

Uno studio ha dimostrato come integrare il *ML* nei processi di controllo qualità può portare a una diminuzione del 20-30% dei costi totali legati alla non conformità, oltre a migliorare la produttività complessiva del sistema. Questo studio ha esaminato casi reali di carte di controllo intelligenti in ambienti produttivi ad alta variabilità, evidenziando un'accelerazione nei tempi di risposta ai difetti e una notevole riduzione dei rilavori e degli scarti [60].

Parallelamente degli studi hanno riscontrato che l'introduzione di carte *ML* su linee di produzione altamente automatizzate ha portato a una riduzione nei tempi medi di inattività degli impianti e a un aumento nella prontezza operativa del sistema qualità [61].

Dal punto di vista economico, adottare tecnologie di *ML* per il controllo qualità rappresenta un investimento strategico. Anche se ci sono costi iniziali da considerare, come hardware, software, formazione e consulenza, i benefici che si possono ottenere sono molteplici:

- riduzione degli scarti e delle rilavorazioni: grazie alla loro capacità predittiva, queste tecnologie permettono di intervenire prima che i difetti si manifestino, migliorando così l'efficienza dell'intero sistema produttivo;
- diminuzione dei fermi macchina: i sistemi di *ML*, quando integrati con sensori e manutenzione predittiva, consentono di prevedere guasti e ottimizzare la disponibilità degli impianti;
- miglioramento della soddisfazione del cliente: una qualità più costante e una maggiore capacità di personalizzazione possono aumentare la fidelizzazione e il valore percepito dai clienti;

- ottimizzazione delle risorse: la possibilità di analizzare i dati in tempo reale aiuta a ridurre gli sprechi di materiale, energia e tempo;
- vantaggi fiscali e finanziari: in alcuni contesti nazionali ed europei, l'adozione di tecnologie 4.0 e 5.0 è incentivata da fondi pubblici, crediti d'imposta e agevolazioni legate alla digitalizzazione e alla sostenibilità;

Tuttavia per massimizzare il ritorno sull'investimento è necessario adottare un approccio graduale e sistemico. Le imprese dovranno iniziare da piccoli progetti pilota, valorizzare i dati già disponibili e sviluppare le competenze interne. Parallelamente sarà fondamentale monitorare l'evoluzione normativa, assicurando che i nuovi strumenti siano conformi ai requisiti legali e certificativi. Le organizzazioni dovranno inoltre dotarsi di sistemi di monitoraggio delle performance dei modelli *ML*, promuovendo audit periodici e procedure di verifica continua.

A livello macroeconomico, l'adozione diffusa dell'intelligenza artificiale nei sistemi qualità potrebbe contribuire alla crescita della produttività industriale, all'incremento dell'efficienza energetica e al rafforzamento della competitività sui mercati internazionali. In un'ottica di politica industriale, favorire l'adozione del *ML* significa anche stimolare la creazione di ecosistemi di innovazione, composti da imprese, università e centri di ricerca interconnessi. Di seguito viene riportata la Tabella 10, che riassume a livello economico gli impatti delle carte di controllo basate su *machine learning*.

Tabella 10: Vantaggi economici e produttivi

Beneficio Economico	Descrizione	Impatto Stimato
Riduzione degli scarti e rilavorazioni	Intervento predittivo al fine di prevenire difetti e scarti	Riduzione dei costi del 20/30%
Diminuzione dei blocchi di produzione	Manutenzione predittiva che previene guasti	Riduzione dei tempi di inattività
Miglioramento della soddisfazione del cliente	Miglior controllo della qualità e customizzazione	Incremento della qualità
Ottimizzazione delle risorse	Analisi in tempo reale che riduce il consumo e l'inattività	Riduzione dei costi energetici e delle risorse
Vantaggi fiscali e finanziari	Incentivi pubblici per l'innovazione digitale	Bonus, crediti d'imposta, incentivi
Crescita della produttività industriale	Adozione ML come motore di efficienza sistemica	Aumento della produttività e riduzione delle inefficienze
Rafforzamento della competitività	Maggiore qualità e reattività nei mercati globali	Miglior posizionamento strategico

Guardando al futuro, le carte *ML* sono destinate a diventare ancora più sofisticate grazie all'integrazione con tecnologie emergenti quali *digital twin*, *edge computing*, intelligenza artificiale generativa e robotica collaborativa. Anche il quadro normativo evolverà verso standard più dinamici e adattivi, coerenti con la flessibilità richiesta dai moderni sistemi produttivi [62].

In questo nuovo scenario, la qualità non sarà più solo una misura di conformità, ma diventerà una vera e propria leva strategica per l'innovazione, la resilienza e il posizionamento sul mercato globale. Le imprese che sapranno cogliere questa opportunità, investendo non solo in tecnologie ma anche in competenze e cultura organizzativa, potranno trarre vantaggi concreti e duraturi dalla transizione verso un controllo qualità intelligente e sostenibile.

5.4 Limiti della ricerca

Nonostante l'analisi approfondita e il rigore teorico, questa tesi presenta alcuni limiti che è importante sottolineare, sia per mantenere un'onestà intellettuale, sia per fornire spunti utili a future ricerche e applicazioni pratiche.

La discussione è stata di natura teorico-descrittiva e non ha incluso una sperimentazione pratica o uno studio di caso aziendale. Questo limita la possibilità di verificare in modo empirico l'efficacia e l'efficienza delle carte di controllo basate su *ML* in un contesto reale.

5.5.1 Sfide nell'adozione delle tecniche di *ML*

L'adozione delle tecniche di *ML* nel controllo qualità è un percorso innovativo, ma non privo di sfide. Ecco alcune delle principali difficoltà che si possono incontrare:

- costi iniziali elevati: per implementare queste tecnologie è necessario investire significativamente in infrastrutture digitali, software e formazione del personale.
- formazione continua: il team tecnico e manageriale deve costantemente aggiornarsi, acquisendo nuove competenze nell'analisi dei dati e nella comprensione dei modelli predittivi.
- resistenze culturali: il cambiamento organizzativo richiesto può scontrarsi con ostacoli culturali e una certa riluttanza all'innovazione.
- interpretabilità dei modelli: molti algoritmi di *ML*, soprattutto quelli più complessi, possono risultare poco trasparenti e difficili da spiegare.
- qualità e disponibilità dei dati: l'efficacia del *ML* dipende dalla disponibilità di dati completi, accurati e ben strutturati, cosa che non è sempre garantita in tutti i contesti produttivi.

In sintesi, sebbene le tecnologie di *ML* siano estremamente promettenti, la loro adozione efficace richiede un'elevata preparazione e conoscenza del tema a riguardo.

5.5 Spunti per sviluppi futuri

Partendo dai limiti evidenziati e dalle opportunità emerse in questo lavoro, si delineano diverse strade per future ricerche e applicazioni pratiche.

5.5.1 Ricerca applicativa su carte *ML* avanzate

Un primo ambito promettente è la sperimentazione pratica delle carte di controllo basate su *ML*, in particolare quelle ibride e neurali. Le carte ibride, che uniscono logiche statistiche a modelli predittivi, potrebbero rappresentare un ottimo compromesso tra interpretabilità e adattabilità. D'altra parte le carte neurali, grazie all'uso di reti profonde, sono perfette per gestire processi complessi e dinamici. Un'analisi comparativa delle prestazioni di queste

diverse tipologie, applicate a casi aziendali reali, offre un'opportunità concreta per convalidare le teorie discusse.

5.5.2 Integrazione con strumenti dell'Industria 5.0

Un secondo sviluppo naturale è l'integrazione delle carte *ML* con altri strumenti tipici dell'Industria 5.0. Tra questi il concetto di “gemello digitale” si distingue come una delle applicazioni più promettenti: creare un gemello digitale del processo produttivo, costantemente aggiornato con dati reali, permette di simulare scenari, prevedere anomalie e ottimizzare le prestazioni. Le carte *ML* potrebbero fungere da sistema di controllo predittivo all'interno del gemello digitale stesso.

Un aspetto altrettanto affascinante è l'interazione con *l'edge computing* che permette di elaborare i dati direttamente sui dispositivi o sui macchinari. Questo approccio non solo riduce la latenza, ma aumenta anche l'autonomia decisionale. In questo scenario, le carte basate su *ML* potrebbero essere implementate direttamente nelle linee produttive, consentendo reazioni immediate alle variazioni di processo. Inoltre, strumenti come la manutenzione predittiva e i sistemi cyber-fisici potrebbero trarre enormi vantaggi dalla sinergia con le carte *ML*, ampliando le loro capacità di monitoraggio e anticipazione dei guasti [63].

5.5.3 Evoluzione normativa e certificazione della qualità

L'introduzione di tecnologie intelligenti nel controllo qualità porta con sé anche sfide normative e regolatorie.

Le attuali norme ISO e i sistemi di certificazione si basano ancora su metodologie tradizionali che si fondano su controlli statici e approcci deterministici. Sarà quindi fondamentale sviluppare nuovi standard che possano integrare strumenti basati sull'intelligenza artificiale, garantendo al contempo tracciabilità, trasparenza e verificabilità [64].

In aggiunta l'accreditamento degli strumenti *ML* per scopi certificativi potrebbe richiedere la creazione di linee guida comuni, sia a livello nazionale che internazionale. Questo è un settore in rapida evoluzione e le aziende che desiderano adottare carte *ML* dovranno affrontare un panorama normativo in continua trasformazione.

I futuri sviluppi del controllo qualità intelligente non si limiteranno solo all'evoluzione tecnica dei modelli, ma richiederanno un ecosistema integrato di strumenti, standard e

competenze. La strada è aperta e la ricerca avrà un ruolo cruciale nel guidare questa trasformazione verso modelli industriali sempre più flessibili, intelligenti e umani.

Conclusione

L'obiettivo principale di questa tesi è stato quello di esaminare come si è evoluto il controllo qualità in un periodo di grande cambiamento per il settore manifatturiero e, in particolare, sull'integrazione delle tecniche di *Machine learning* nelle carte di controllo che costituiscono uno degli strumenti più tradizionali e rappresentativi della qualità per le industrie.

Il tema è di grande attualità in un momento in cui le aziende si trovano ad affrontare sfide molto complesse (necessità di creare prodotti sempre più personalizzati, minimizzare gli sprechi e le inefficienze, mantenere alti standard qualitativi) rispettando criteri di sostenibilità ambientale e responsabilità sociale.

La decisione di trattare questo argomento nasce da un interesse personale per un'area che si colloca tra ingegneria gestionale e innovazione tecnologica. In un'epoca in cui la digitalizzazione e l'intelligenza artificiale stanno radicalmente cambiando il panorama industriale, ho ritenuto opportuno analizzare il modo in cui strumenti tradizionali come le carte di controllo possano essere reinterpretati alla luce delle nuove tecnologie.

Il percorso di ricerca si è sviluppato partendo da una panoramica generale fino ad arrivare ad un'analisi più tecnica delle soluzioni più avanzate. Ogni capitolo è stato strutturato come una tappa che intreccia concetti teorici e applicazioni pratiche con l'obiettivo di fornire una visione più ampia e chiara riguardo circa l'utilizzo delle carte di controllo basate sul *ml*.

Un aspetto di rilievo emerso in vari punti dell'elaborato riguarda il legame tra tecnologie di *machine learning* e principi fondamentali dell'Industria 5.0. Il *machine learning* non è solo uno strumento per ottimizzare i processi, ma può diventare un alleato prezioso per sviluppare un modello industriale più umano, inclusivo e sostenibile. Automatizzando le attività ripetitive, questi sistemi liberano risorse umane che possono essere reindirizzate verso mansioni più creative e strategiche, rafforzando così la dimensione umana dell'industria invece che sopprimerla.

La struttura della tesi è stata pensata per offrire una visione più chiara riguardo l'argomento. Il *ML* rappresenta una risposta concreta ed efficace alle sfide dell'Industria 5.0. La sua abilità di apprendere dai dati, scoprire *pattern* nascosti e adattarsi in tempo reale alle condizioni del processo produttivo lo rende uno strumento perfetto per il controllo qualità odierno. Con

il *ML*, è possibile trasformare le tradizionali carte di controllo in strumenti predittivi, proattivi e adattivi.

Nella stesura dell'elaborato, sono state esaminate diverse tipologie di carte di controllo basate su *ML*: ogni algoritmo ha mostrato caratteristiche uniche che lo rendono più o meno adatto a seconda del tipo di processo, della disponibilità dei dati e degli obiettivi specifici.

Dunque, è noto come, in uno scenario come quello delineato finora si rende necessaria l'integrazione di strumenti più avanzati. Le carte di controllo basate su machine learning rappresentano un'evoluzione significativa: grazie a modelli predittivi, adattivi e auto-apprendenti, permettono un monitoraggio continuo e dinamico dei processi, superando le principali limitazioni delle carte tradizionali. In particolare si dimostrano efficaci in ambienti non stazionari, dove le assunzioni statistiche classiche, come la distribuzione normale dei dati o l'indipendenza delle osservazioni, che non sono rispettate.

Le implicazioni pratiche emerse includono la necessità di rivedere i processi di controllo qualità in un'ottica digitale, l'introduzione di nuove figure professionali ibride, competenti sia in statistica che in informatica, e una maggiore integrazione tra i sistemi IT e la produzione. Il controllo qualità non può più essere visto come una funzione isolata, ma deve diventare parte integrante della strategia aziendale.

Tuttavia la transizione verso le carte di controllo basate su *ML* presenta anche delle sfide. In primo luogo, l'implementazione richiede risorse computazionali, investimenti in infrastrutture e competenze specialistiche. In secondo luogo, la scarsa interpretabilità di alcuni modelli, come le reti neurali profonde, può ostacolare l'accettazione e la validazione dei risultati da parte degli operatori. Infine, per adottare questi strumenti è necessaria una base dati solida e affidabile, che non è sempre disponibile.

Dalla ricerca è emerso che i modelli di controllo basati su machine learning offrono una risposta coerente e necessaria alle sfide dell'Industria 5.0. Non sostituiscono completamente gli strumenti tradizionali, ma ne ampliano le potenzialità, permettendo un controllo qualità più reattivo, predittivo e integrato. Tuttavia, il loro utilizzo efficace richiede una revisione delle pratiche aziendali e un'evoluzione culturale che riconosca il valore dei dati come risorsa strategica.

Bibliografia

- [1] S. Sankaran and S. R. R. Senthil, "A significant leap in the industrial revolution with the help of artificial intelligence," *Mater. Today Proc.*, vol. 80, pp. 2731–2735, 2024, doi: 10.1016/j.matpr.2023.08.373.
- [2] P. K. R. Maddikunta, Q.-V. Pham, P. B. Prabadevi, N. Deepa, K. Dev, T. R. Gadekallu, R. Ruby, and M. Liyanage, "Industry 5.0: A survey on enabling technologies and potential applications," *J. Ind. Inf. Integr.*, vol. 26, p. 100257, 2022, doi:10.1016/j.jii.2021.100257.
- [3] M. Stuart, E. Mullins, and E. Drew, "Statistical quality control and improvement," *Eur. J. Oper. Res.*, vol. 88, no. 2, pp. 203–214, 1996, doi: 10.1016/0377-2217(95)00069-0.c.
- [4] P. K. R. Maddikunta, Q.-V. Pham, P. B. Prabadevi, N. Deepa, K. Dev, T. R. Gadekallu, R. Ruby, and M. Liyanage, "Industry 5.0: A survey on enabling technologies and potential applications," *J. Ind. Inf. Integr.*, vol. 26, p. 100257, 2022, doi:10.1016/j.jii.2021.100257.
- [5] I. Kovalenko, K. Barton, J. Moyne, and D. M. Tilbury, "Opportunities and challenges to integrate artificial intelligence into manufacturing systems: Thoughts from a panel discussion".
- [6] S. Loker, *Mass customization and sizing*, in *Sizing in Clothing*, S. P. Ashdown, Ed. Cambridge, UK: Woodhead Publishing, 2007, ch. 8, pp. 246–263.
- [7] A. Kovari, "Industry 5.0: Generalized definition, key applications, opportunities and threats," *Acta Polytech. Hungarica*, vol. 21, no. 3, pp. 267–284, 2024.
- [8] A. Gupta and R. Gupta, "Challenges and opportunities of Industry 5.0 in the context of sustainable development goals," *AI and Ethics*, vol. 2, pp. 377–393, 2022, doi: 10.1007/s43681-022-00178-2.
- [9] M. Best and D. Neuhauser, "Walter A Shewhart, 1924, and the Hawthorne factory," *Qual. Saf. Health Care*, vol. 15, no. 2, pp. 142–143, 2006, doi: 10.1136/qshc.2006.018093.

- [10] P. H. Tran, A. A. Nadi, T. H. Nguyen, K. D. Tran, and K. P. Tran, "Application of machine learning in statistical process control charts: A survey and perspective," in *Control Charts and Machine Learning for Anomaly Detection in Manufacturing*, Springer Series in Reliability Engineering, 2021, pp. 25–54, doi: 10.1007/978-3-030-83819-5_2.
- [11] A. Kovari, "Industry 5.0: Generalized definition, key applications, opportunities and threats," *Acta Polytech. Hungarica*, vol. 21, no. 3, pp. 267–284, 2024.
- [12] H. Ipek, H. Ankara, and H. Ozdag, "The application of statistical process control," *Miner. Eng.*, vol. 12, no. 7, pp. 827–835, 1999, doi: 10.1016/S0892-6875(99)00067-9.
- [13] M. Malindzakova, K. Čulková, and J. Trpčevská, "Shewhart control charts implementation for quality and production management," *Processes*, vol. 11, no. 4, p. 1246, Apr. 2023, doi: 10.3390/pr11041246.
- [14] M. A. Rahim and A. A. Al-Ghamdi, "Joint economic design of \bar{X} and R control charts under non-normality," *Omega*, vol. 38, no. 5, pp. 456–464, 2010, doi: 10.1016/j.omega.2009.11.003.
- [15] M. A. Rahim and A. A. Al-Ghamdi, "Joint economic design of \bar{X} and R control charts under non-normality," *Omega*, vol. 38, no. 5, pp. 456–464, 2010, doi: 10.1016/j.omega.2009.11.003.
- [16] S. Chakraborti and R. S. Sparks, "Statistical process monitoring and the issue of assumptions in practice: Normality and independence," in *Distribution-Free Methods for Statistical Process Monitoring and Control*, M. V. Koutras and I. S. Triantafyllou, Eds. Cham, Switzerland: Springer, 2020, pp. 137–155, doi: 10.1007/978-3-030-25081-2_4.
- [17] T. Tanjung, I. Ghazali, W. H. W. Mahmood, and S. G. Herawan, "Drivers and barriers to Industrial Revolution 5.0 readiness: A comprehensive review of key factors," *Smart Manuf.*, vol. 1, p. 100051, 2025, doi: 10.1016/j.sciman.2024.100051.
- [18] J. Mayer and R. Jochem, "Capability indices for digitized industries: A review and outlook of machine learning applications for predictive process control," *Processes*, vol. 12, no. 8, p. 1730, Aug. 2024, doi: 10.3390/pr12081730.

- [19] H. Sabahno and A. Amiri, "New statistical and machine learning based control charts with variable parameters for monitoring generalized linear model profiles," *Comput. Ind. Eng.*, vol. 184, p. 109562, 2023, doi: 10.1016/j.cie.2023.109562.
- [20] S. Sundaram, R. Bothra, and A. Mehta, "Artificial Intelligence and Machine Learning for Industry 5.0," *Int. J. Adv. Res. Sci. Commun. Technol. (IJARST)*, vol. 4, no. 6, pp. 140–144, Apr. 2024, doi: 10.48175/IJARST-17622.
- [21] R. Rai, M. K. Tiwari, D. Ivanov, and A. Dolgui, "Machine learning in manufacturing and industry 4.0 applications," *Int. J. Prod. Res.*, vol. 59, no. 16, pp. 4773–4778, 2021, doi: 10.1080/00207543.2021.1956675.
- [22] H. Zhang, S. S. Dereck, Z. Wang, X. Lv, K. Xu, L. Wu, Y. Jia, J. Wu, Z. Long, W. Liang, X. G. Ma, and R. Zhuang, "Large scale foundation models for intelligent manufacturing applications: A survey,"
- [23] T. M. Mitchell, *The Discipline of Machine Learning*, Pittsburgh, PA, USA: Carnegie Mellon University, School of Computer Science, Tech. Rep. CMU-ML-06-108, Jul. 2006.
- [24] S. Fahle, C. Prinz, and B. Kuhlenkötter, "Systematic review on machine learning (ML) methods for manufacturing processes – Identifying artificial intelligence (AI) methods for field application," *Procedia CIRP*, vol. 93, pp. 413–418, 2020, doi: 10.1016/j.procir.2020.04.109
- [25] H. Tercan and T. Meisen, "Machine learning and deep learning based predictive quality in manufacturing: a systematic review," *J. Intell. Manuf.*, vol. 33, no. 7, pp. 1879–1905, 2022, doi: 10.1007/s10845-022-01963-8.
- [26] E. F. Agyemang, "Anomaly detection using unsupervised machine learning algorithms: A simulation study," *Sci. Afr.*, vol. 26, p. e02386, Sep. 2024, doi: 10.1016/j.sciaf. 2024.e02386.
- [27] Z. J. Viharos and R. Jakab, "Reinforcement learning for statistical process control in manufacturing," *Measurement*, vol. 182, p. 109616, Jun. 2021, doi: 10.1016/j.measurement.2021.109616.

- [28] M. R. Islam, M. Z. H. Zamil, M. E. Rayed, M. M. Kabir, M. F. Mridha, S. Nishimura, and J. Shin, "Deep learning and computer vision techniques for enhanced quality control in manufacturing processes," *IEEE Access*, vol. 12, pp. 121449–121470, Jan. 2024, doi: 10.1109/ACCESS.2024.3453664.
- [29] J. Mayer and R. Jochem, "Capability indices for digitized industries: A review and outlook of machine learning applications for predictive process control," *Processes*, vol. 12, no. 8, p. 1730, Aug. 2024, doi: 10.3390/pr12081730.
- [30] P. Qiu, "Machine learning approaches for statistical process control," *Wiley StatsRef: Statistics Reference Online*, 2017, doi: 10.1002/ISBN.stat00999.pub9.
- [31] D. S. Watson, "Conceptual challenges for interpretable machine learning," *Synthese*, vol. 200, no. 65, pp. 1–33, Mar. 2022, doi: 10.1007/s11229-022-03485-5.
- [32] J. Krauß, B. M. Pacheco, H. M. Zang, and R. H. Schmitt, "Automated machine learning for predictive quality in production," *Procedia CIRP*, vol. 93, pp. 443–448, 2020, doi: 10.1016/j.procir.2020.04.039.
- [33] P. Qiu, "Machine learning approaches for statistical process control," *Wiley StatsRef: Statistics Reference Online*, 2017, doi: 10.1002/ISBN.stat00999.pub9.
- [34] M. K. Msakni, A. Risan, and P. Schütz, "Using machine learning prediction models for quality control: A case study from the automotive industry," *Comput. Manag. Sci.*, vol. 20, no. 14, pp. 1–28, Mar. 2023, doi: 10.1007/s10287-023-00448-0.
- [35] Z. Wu, P. D. Christofides, W. Wu, Y. Wang, F. Abdullah, A. Alnajdi, and Y. Kadakia, "A tutorial review of machine learning-based model predictive control methods," *Rev. Chem. Eng.*, vol. 41, no. 4, pp. 359–400, Dec. 2024, doi: 10.1515/revce-2024-0055.
- [36] B. Aytaçoğlu, A. R. Driscoll, and W. H. Woodall, "Design of adaptive EWMA control charts using the conditional false alarm rate," *Qual. Reliab. Engng. Int.*, vol. 39, no. 6, pp. 2206–2214, 2023, doi: 10.1002/qre.3324.

- [37] T. Sałaciński, J. Chrzanowski, and T. Chmielewski, "Statistical process control using control charts with variable parameters," *Processes*, vol. 11, no. 9, p. 2744, Sep. 2023, doi: 10.3390/pr11092744.
- [38] Y. Yu, J. Chen, S. Zhang, and T. Hong, "Classification model of control charts based on ML-SVM," in *Proc. 2023 Int. Conf. Adv. Artif. Intell. Appl. (AAIA 2023)*, Wuhan, China, Nov. 2023, doi: 10.1145/3603273.3630506.
- [39] X. Xie and P. Qiu, "Dynamic process monitoring using machine learning control charts," in *Statistical Methods for Process Control*, Springer Series in Reliability Engineering, 2023, pp. 87–112, doi: 10.1007/978-3-031-30510-8_4.
- [40] A. Zeiser, B. Özcan, B. van Stein, and T. Bäck, "Evaluation of deep unsupervised anomaly detection methods with a data-centric approach for on-line inspection," *Comput. Ind.*, vol. 146, p. 103852, 2023, doi: 10.1016/j.compind.2023.103852.
- [41] P. Gupta and P. Tripathy, "Unsupervised learning for real-time data anomaly detection: A comprehensive approach," *Int. J. Comput. Sci. Eng. (SSRG-IJCSE)*, vol. 11, no. 10, pp. 1–11
- [42] H. Sabahno and S. T. A. Niaki, "New machine-learning control charts for simultaneous monitoring of multivariate normal process parameters with detection and identification, Aug. 2023, doi: 10.3390/math11163566.
- [43] V. Ranaee and A. Ebrahimzadeh, "Control chart pattern recognition using a novel hybrid intelligent method," *Appl. Soft Comput.*, vol. 11, no. 4, pp. 2676–2686, 2011, doi: 10.1016/j.asoc.2010.10.016.
- [44] V. Ranaee and A. Ebrahimzadeh, "Control chart pattern recognition using a novel hybrid intelligent method," *Appl. Soft Comput.*, vol. 11, no. 4, pp. 2676–2686, 2011, doi: 10.1016/j.asoc.2010.10.016.
- [45] A. Malinovskaya, P. Mozharovskyi, and P. Otto, "Statistical process monitoring of artificial neural networks," Jul. 2023.
- [46] S. Lee, M. Kwak, K.-L. Tsui, and S. B. Kim, "Process monitoring using variational autoencoder for high-dimensional nonlinear processes," *Eng. Appl. Artif. Intell.*, vol. 83, pp. 13–27, May 2019, doi: 10.1016/j.engappai.2019.04.013.

- [47] E. F. Morales and H. J. Escalante, "A brief introduction to supervised, unsupervised, and reinforcement learning," in *Artificial Intelligence in Data Science*, Academic Press, 2022, ch. 17, pp. 371–392, doi: 10.1016/B978-0-12-820125-1.00017-8.
- [48] C. Hoseini, M. A. Badar, and A. M. Shahhosseini, "A review of machine learning methods applicable to quality issues," *Technol. Forecast. Soc. Change*, vol. 198, p. 122934, 2023, doi: 10.1016/j.techfore.2023.122934.
- [49] A. A. F. Awwad and M. M. A. Ali, "Supervised learning: A systematic literature review," *Int. J. Adv. Comput. Sci. Appl.*, vol. 13, no. 9, pp. 546–555, 2022, doi: 10.14569/IJACSA.2022.0130965.
- [50] J. Cervantes, F. Garcia-Lamont, L. Rodríguez-Mazahua, and A. Lopez, "A comprehensive survey on support vector machine classification: Applications, challenges and trends," *Neurocomputing*, vol. 408, pp. 189–215, 2020, doi: 10.1016/j.neucom.2019.10.118.
- [51] H. Adams, E. Farnell, and B. Story, "Support vector machines and Radon's theorem," *Manuscript submitted to AIMS Journal*, Sep. 2022.
- [52] A. T. C. Goh and S. H. Goh, "Support vector machines: Their use in geotechnical engineering as illustrated using seismic liquefaction data, doi: 10.1016/j.compgeo.2007.06.001.
- [53] A. Hoarau, A. Martin, J.-C. Dubois, and Y. Le Gall, "Evidential random forests," *Expert Syst. Appl.*, vol. 230, p. 120652, 2023, doi: 10.1016/j.eswa.2023.120652.
- [54] Z. Sun, G. Wang, P. Li, H. Wang, M. Zhang, and X. Liang, "An improved random forest based on the classification accuracy and correlation measurement of decision trees," *Expert Syst. Appl.*, vol. 237, p. 121549, 2024, doi: 10.1016/j.eswa.2023.121549.
- [55] T. Coleman, W. Peng, and L. Mentch, "Scalable and efficient hypothesis testing with random forests," *J. Mach. Learn. Res.*, vol. 23, no. 130, pp. 1–35, Jun. 2022.
- [56] H. C. Altunay and Z. Albayrak, "A hybrid CNN+LSTM-based intrusion detection system for industrial IoT networks," *ICT Express*, Dec. 2022, doi: 10.1016/j.icte.2022.03.002.

- [57] S. Razavi, "Deep learning, explained: Fundamentals, explainability, and bridgeability to process-based modelling," *Environ. Model. Softw.*, , 2021, doi: 10.1016/j.envsoft.2021.105159.
- [58] I. Kovalenko, K. Barton, J. Moyne, and D. M. Tilbury, "Opportunities and challenges to integrate artificial intelligence into manufacturing systems: Thoughts from a panel discussion".
- [59] A. Gupta and R. Gupta, "Challenges and opportunities of Industry 5.0 in the context of sustainable development goals," *AI and Ethics*, 2022, doi: 10.1007/s43681-022-00178-2.
- [60] M. Mandolini, L. Manuguerra, M. Sartini, G. M. Lo Presti, and F. Pescatori, "A cost modelling methodology based on machine learning for engineered-to-order products," 2024, doi: 10.1016/j.engappai.2024.107711.
- [61] R. Gardas and S. Narwane, "An analysis of critical factors for adopting machine learning in manufacturing supply chains," *J. Manuf. Syst.*, doi: 10.1016/j.jmsy.2023.09.013
- [62] R. X. Gao, J. Krüger, M. Merklein, H.-C. Möhring, and J. Váncza, "Artificial Intelligence in manufacturing: State of the art, perspectives, and future directions," 2024, doi: 10.1016/j.bulsat.2024.100017.
- [63] M.-S. Kang, D.-H. Lee, M. S. Bajestani, D. B. Kim, and S. D. Noh, "Edge computing-based digital twin framework based on ISO 23247 for enhancing data processing capabilities", Jan. 2023, doi: 10.3390/machines13010019.
- [64] J. Oviedo, M. Rodriguez, A. Trenta, D. Cannas, D. Natale, and M. Piattini, "ISO/IEC quality standards for AI engineering," *J. Syst. Softw.*, , 2024, doi: 10.1016/j.jss.2024.111774.

A conclusione di questo elaborato mi è doveroso dedicare questo spazio alle persone che hanno contribuito alla realizzazione dello stesso.

In primis, un ringraziamento speciale ai miei relatori, professor Galetto e professor Genta per avermi seguito durante la stesura e a Stefano Puttero per i suoi preziosi consigli.

Ringrazio infinitamente le mie sorelle Francesca e Camilla, mio fratello Filippo e i miei genitori che mi hanno consentito di svolgere questo primo step del mio percorso universitario senza farmi mancare nulla e mi hanno sempre sostenuto, appoggiando ogni mia decisione, fin dalla scelta del mio percorso di studi.

Un sincero grazie ai miei amici di una vita: Francesco, Tommaso, Giorgio, Tommaso, Pietro, Enrico e Edoardo che nonostante abbiamo intrapreso percorsi di studi differenti, sono sempre stati al mio fianco, pronti ad aiutarmi nei momenti di difficoltà.