



UNIVERSITA' POLITECNICA DELLE MARCHE

FACOLTA' DI INGEGNERIA

Corso di Laurea triennale in Ingegneria Gestionale

Analisi e comparazione di tecnologie per l'ottimizzazione delle linee di produzione nel contesto del Digital Twin

Relatore:

Prof. Maurizio Bevilacqua

Tesi di laurea di:

Beatrice Pendenza

Correlatore:

Ing. Croci Stefano

A.A. 2025/2026

A mio padre,
che continua ad accompagnarmi in ogni traguardo.
Questa laurea è anche tua.

Al termine di questo percorso desidero esprimere la mia più sincera gratitudine a tutte le persone che, in modi diversi, hanno contribuito a rendere possibile il raggiungimento di questo importante traguardo.

Ringrazio il mio relatore, Prof. Maurizio Bevilacqua, per la disponibilità dimostrata durante questo percorso e per aver reso possibile la realizzazione di questo elaborato.

Un sentito ringraziamento va al mio tutor di tirocinio, Stefano Croci, per la disponibilità, il supporto e la guida durante lo svolgimento del tirocinio e nella realizzazione di questo elaborato.

Ringrazio mia madre e mia sorella, che hanno condiviso con me questo lungo percorso universitario e questo momento così importante della mia vita. Un grazie speciale va alla mia mamma, che, nonostante le difficoltà affrontate lungo il nostro cammino, ha sempre desiderato vedermi felice e realizzata. Le voglio bene e le sono grata per aver contribuito a rendere possibile il raggiungimento di questo traguardo. Un pensiero speciale va anche al mio nipotino Tony, che con il suo sorriso e la sua spontaneità ha saputo regalarmi tanti momenti di gioia e leggerezza.

Un grazie ai miei compagni di università, con i quali ho condiviso momenti di spensieratezza, risate, serate indimenticabili e tanti ricordi che porterò sempre con me. Un pensiero speciale va a Laura, Rosi ed Ettore, con cui ho condiviso una parte importante di questo percorso. In particolare, grazie a Laura, per essermi stata accanto con affetto e sincerità nei momenti in cui ne avevo più bisogno.

Un ringraziamento speciale va a Elena, per esserci sempre stata. Grazie per la tua amicizia, per il sostegno, per avermi ascoltata nei momenti più difficili e per aver condiviso con me ogni passo di questo percorso.

Grazie a Edda, che è arrivata nell'ultima parte del mio percorso universitario, ma che è stata fondamentale per aiutarmi a ritrovare fiducia in me stessa. Grazie per aver creduto nelle mie capacità quando io facevo fatica a farlo e per avermi dato la forza di arrivare fino a qui.

Un pensiero affettuoso va anche ai miei nonni. So quanto sarebbero stati felici e orgogliosi di vedermi raggiungere questo traguardo. Il loro ricordo continuerà ad accompagnarmi sempre.

Infine, il ringraziamento più grande è per mio padre.

Avrei voluto con tutto il cuore averti accanto in questo giorno e poter condividere con te la gioia di questo traguardo. Anche se la vita ci ha separati troppo presto, il tuo amore, i tuoi insegnamenti e il ricordo di ciò che sei stato mi accompagnano ogni giorno.

Ovunque tu sia, so che mi guarderai e che sarai fiero di me.

Questa laurea è anche tua.

Sommario

Introduzione	6
Introduzione al concetto di Digital Twin	8
1.1 Definizione e origine del Digital Twin.....	8
1.2 Contesto industriale e motivazioni	10
1.3 Architettura e implementazione del Digital Twin	14
1.4 Ruolo del Digital Twin e integrazione con gli algoritmi intelligenti.....	19
Metodologia e stato dell'arte sugli algoritmi per il Digital Twin.....	22
2.1 Approccio metodologico	22
2.2 Stato dell'arte per famiglie di algoritmi	26
2.2.1 Modelli matematici: la razionalità dell'ottimizzazione classica	28
2.2.2 Euristiche e metaeuristiche: la flessibilità come valore industriale.....	30
2.2.3 Machine Learning: l'intelligenza adattiva della fabbrica digitale.....	33
2.2.4 Reinforcement Learning: l'apprendimento autonomo dei sistemi produttivi	36
2.3 Analisi comparativa	40
3.0 – Caratteristiche del contesto produttivo simulato	49
3.1 – Collegamento tra architettura del Digital Twin e caso di studio fittizio.....	51
3.1.1 – Applicazione del modello MILP al caso di studio fittizio	54
3.1.2 – Applicazione delle metaeuristiche al caso di studio fittizio	56
3.1.3 – Applicazione del Machine Learning al caso di studio fittizio	58
3.1.4 – Applicazione del Reinforcement Learning al caso simulato.....	61
3.2 – Confronto integrato tra le famiglie di algoritmi nel caso di studio fittizio.....	63
Conclusione	66

Introduzione

Negli ultimi anni, i sistemi di produzione hanno conosciuto una trasformazione continua, guidata da una crescente pressione verso efficienza, flessibilità e capacità di risposta in contesti caratterizzati da elevata incertezza. Le aziende si trovano a gestire decisioni operative in presenza di catene di fornitura instabili, domanda variabile e risorse limitate, dovendo coordinare vincoli produttivi, obiettivi economici e requisiti di servizio in tempi ristretti (Kagermann et al., 2013; Ivanov & Dolgui, 2020). In questo scenario, la mera disponibilità di dati non rappresenta più il principale ostacolo: numerosi studi sottolineano come il vero fattore critico sia la capacità di trasformare i dati in informazioni utili e in decisioni operative coerenti con la strategia aziendale (Wuest et al., 2016; Müller et al., 2018). Diventa quindi fondamentale disporre di strumenti in grado di collegare sistematicamente i dati operativi a modelli decisionali strutturati, capaci di valutare alternative e supportare decisioni rapide e informate.

In questo contesto, si registra un interesse crescente verso modelli digitali integrati con tecniche di ottimizzazione e apprendimento automatico, che consentono di rappresentare processi produttivi, simulare scenari e confrontare strategie decisionali prima dell'implementazione fisica (Grieves & Vickers, 2017; Jones et al., 2020). La letteratura recente evidenzia come la componente algoritmica rappresenti il “nucleo decisionale” di questi modelli: la qualità dei risultati ottenuti dipende non solo dall'accuratezza del modello digitale, ma anche dalla scelta dell'algoritmo più appropriato per risolvere il problema, gestire i vincoli e utilizzare al meglio i dati disponibili (Rasheed et al., 2020; Zhuang et al., 2021). Tuttavia, in molti contributi la selezione degli algoritmi avviene in modo implicito o poco strutturato, mentre nella pratica industriale emergono esigenze concrete: comprendere quali tecniche adottare, con quali requisiti informativi e tenendo conto dei compromessi tra qualità della soluzione, tempo di calcolo e robustezza rispetto alla variabilità operativa (Mittal et al., 2019; Safavi et al., 2022).

Partendo da queste premesse, questo lavoro analizza il ruolo degli algoritmi di ottimizzazione all'interno di un modello digitale applicato a un contesto produttivo simulato, con l'obiettivo di confrontare il contributo di diverse famiglie algoritmiche al processo decisionale. L'attenzione si focalizza non solo sulla descrizione delle tecnologie digitali, già ampiamente trattate in letteratura, ma soprattutto sulla costruzione di un percorso metodologico per valutare come modelli matematici, metaeuristiche, tecniche di Machine Learning e approcci di Reinforcement Learning possano integrarsi per supportare decisioni operative in ambienti caratterizzati da capacità di linea eterogenee, risorse umane limitate e domanda variabile (Gendreau & Potvin, 2019; Pan et al., 2023). Il lavoro si inserisce nella corrente di ricerca che propone framework strutturati per la selezione e il confronto di algoritmi nei sistemi produttivi, mettendo in luce criteri di scelta basati non solo sulle prestazioni numeriche, ma anche su requisiti informativi,

scalabilità e robustezza delle soluzioni (Tao et al., 2019; Galli et al., 2021).

Gli obiettivi della ricerca, definiti in accordo con il tutor, si sviluppano su tre assi principali. In primo luogo, si intende esaminare il contributo degli algoritmi di ottimizzazione all'interno di un modello digitale per il supporto decisionale operativo, con riferimento al miglioramento dell'efficienza produttiva, alla gestione dei vincoli e alla coordinazione di risorse limitate e domanda fluttuante. In secondo luogo, si propone di studiare le caratteristiche distintive delle diverse famiglie algoritmiche, evidenziandone punti di forza, limiti, requisiti informativi e condizioni di applicabilità, per costruire una base comparativa utile anche in altri contesti industriali (Gendreau & Potvin, 2019; Sun et al., 2022). Terzo, si prevede di condurre un'analisi comparativa sull'efficacia degli algoritmi nell'identificare configurazioni produttive vantaggiose, valutando come i diversi approcci soddisfino i vincoli del sistema, sfruttino la capacità disponibile e contengano i costi operativi complessivi.

Per raggiungere tali obiettivi è stato sviluppato un caso di studio simulato che riproduce, in modo controllato, le caratteristiche essenziali di un ambiente produttivo agroalimentare: linee multiple con capacità differenziate, disponibilità variabile di operatori, domanda oraria da soddisfare e costi operativi legati alle scelte di configurazione. Lo scenario non riflette una realtà aziendale specifica, ma è stato progettato per simulare realisticamente le dinamiche di un sistema produttivo, superando i vincoli di riservatezza dei dati e consentendo di esplorare liberamente diverse politiche decisionali (Uhlemann et al., 2017; Monostori, 2018). In questo ambiente virtuale, i diversi algoritmi vengono implementati in modo coerente, garantendo che tutti operino con le stesse informazioni, vincoli e obiettivi, per permettere un confronto trasparente e metodologicamente solido.

L'elaborato accompagna progressivamente il lettore dal quadro generale alla valutazione applicativa. Il Capitolo 1 introduce il contesto e le motivazioni che rendono attuale e rilevante l'uso di modelli digitali e tecniche di ottimizzazione nei sistemi produttivi contemporanei. Il Capitolo 2 approfondisce le principali famiglie di algoritmi considerate, illustrandone le logiche di funzionamento e i principali ambiti di utilizzo. Il Capitolo 3 rappresenta il nucleo applicativo: descrive il caso di studio, formalizza il problema in termini di input, vincoli e obiettivi, implementa le diverse famiglie algoritmiche e confronta i risultati ottenuti in termini di qualità delle soluzioni e capacità di supportare decisioni operative. Le conclusioni discutono i principali contributi della ricerca, le implicazioni metodologiche, i limiti del lavoro e possibili sviluppi futuri. L'introduzione non anticipa i contenuti tecnici dei capitoli successivi, ma ne chiarisce la struttura logica e la direzione complessiva, offrendo una guida alla lettura coerente con gli obiettivi della tesi.

Introduzione al concetto di Digital Twin

1.1 Definizione e origine del Digital Twin

Il concetto di Digital Twin è attualmente riconosciuto come elemento fondamentale della trasformazione digitale industriale, considerato tra le tecnologie più significative dell'Industria 4.0 e del nascente paradigma dell'Industria 5.0 (Tao et al., 2018; Jones et al., 2020). La sua definizione, benché stabilizzata nei suoi aspetti essenziali, deriva da un'evoluzione teorico-tecnologica ventennale, durante la quale numerosi studiosi hanno contribuito a definirne caratteristiche, funzionalità e potenzialità applicative.

In termini generali, il Digital Twin è descritto come una rappresentazione digitale dinamica di un oggetto, processo o sistema fisico, contraddistinta da un continuo scambio bidirezionale di informazioni che permette il sincronismo tra realtà fisica e ambiente virtuale (Boschert & Rosen, 2016; Rasheed et al., 2020). Rappresenta quindi un modello digitale dinamico, in continuo aggiornamento, in grado di rappresentare e anticipare il comportamento del sistema reale integrando modelli matematici, dati contestuali, simulazioni e metodologie analitiche avanzate.

Recentemente, questo concetto è emerso come una delle innovazioni tecnologiche più significative dell'Industria 4.0, per la sua capacità di generare una replica virtuale dinamica di un sistema fisico mediante dati reali e modelli sofisticati (Tao et al., 2018; Boschert & Rosen, 2016). Jones et al. (2020) definiscono il Digital Twin come "un complesso integrato di modelli virtuali, dati e servizi che rappresentano un'entità fisica durante tutto il suo ciclo vitale", la cui efficienza si basa su cinque aspetti chiave:

- comunicazione bidirezionale delle informazioni, che assicura un costante aggiornamento tra l'elemento fisico e quello digitale (Jones et al., 2020);
- sincronizzazione temporale, cruciale per la coerenza tra i due ambiti (Jones et al., 2020);
- funzionalità predittive fondate su modelli di simulazione e analisi, che permettono di prevedere anomalie o inefficienze (Jones et al., 2020);
- interoperabilità tra diversi sistemi e piattaforme, che facilita l'integrazione nell'ambiente industriale (Jones et al., 2020);

- e capacità evolutiva del modello digitale, che si sviluppa in parallelo con i cambiamenti dell'entità fisica (Jones et al., 2020).

Queste caratteristiche differenziano il Digital Twin da un semplice modello digitale statico, consentendo alle imprese di controllare in tempo reale l'efficienza dei loro impianti, testare scenari virtuali e implementare strategie di manutenzione predittiva basate sui dati.

Le origini concettuali del Digital Twin vengono comunemente attribuite a Michael Grieves, che nel 2002 presentò il "Conceptual Ideal for PLM", successivamente elaborato nel suo noto Mirrored Spaces Model (Grieves, 2003; Grieves & Vickers, 2017). In questa formulazione iniziale, il Digital Twin emerge come supporto al Product Lifecycle Management, finalizzato a stabilire un legame costante tra prodotto fisico e sua rappresentazione virtuale. Nonostante la semplicità rispetto agli standard attuali, questo modello introduce due elementi chiave tuttora validi: la relazione tra entità fisica e digitale e il flusso informativo che le collega.

Un ulteriore sviluppo concettuale si deve alla NASA, particolarmente al lavoro di Glaessgen e Stargel (2012), che impiegarono il termine Digital Twin per indicare modelli prognostici sofisticati capaci di prevedere malfunzionamenti e deterioramenti strutturali nei componenti aerospaziali. Qui si manifesta una delle prime concezioni "intelligenti" del digital twin, non più semplice rappresentazione ma sistema predittivo con capacità di apprendimento e adattamento. Questo approccio ha gettato le fondamenta per lo sviluppo di modelli digitali orientati alla manutenzione predittiva e alla gestione della complessità operativa.

Dal 2015, con la diffusione estensiva delle tecnologie Internet of Things (IoT), big data analytics, cyber-physical systems e cloud computing, il Digital Twin conosce uno sviluppo senza precedenti. Studiosi come Kritzinger et al. (2018), Fuller et al. (2020) e Negri et al. (2017) evidenziano come la capacità di acquisire dati in tempo reale trasformi profondamente il concetto di modello digitale. In questo periodo si afferma la distinzione ormai classica tra:

- Digital Model: rappresentazione statica senza collegamento ai dati reali;
- Digital Shadow: modello con aggiornamento unidirezionale (dal fisico al digitale);
- Digital Twin: modello con interazione bidirezionale, in grado di influenzare il sistema fisico.

Questa classificazione, proposta da Kritzinger et al. (2018), diviene un riferimento essenziale per definire i livelli di maturità digitale.

Contemporaneamente, la ricerca internazionale amplia l'ambito applicativo del Digital Twin introducendo prospettive interpretative sempre più evolute. Tao et al. (2019) trattano di Digital Twin-Driven Smart Manufacturing, sottolineando come possa orientare l'intero ecosistema produttivo, dalla pianificazione alla simulazione, fino all'ottimizzazione dei processi. Madni &

Madni (2019) definiscono invece i Cognitive Twins, ovvero Digital Twin dotati di capacità di apprendimento basate su algoritmi di Machine Learning e Reinforcement Learning, capaci di supportare decisioni autonome. Questi rappresentano lo stadio più avanzato dell'evoluzione concettuale, in cui il modello digitale diventa un autentico agente decisionale.

La letteratura recente identifica inoltre vari livelli di complessità del Digital Twin — component twin, system twin, process twin, enterprise twin — che dimostrano come la tecnologia sia attualmente utilizzata non solo per rappresentare singoli elementi, ma anche sistemi produttivi articolati, intere linee di produzione e persino catene di approvvigionamento complete (Leng et al., 2022; Minerva et al., 2022). Questa espansione riflette la crescente maturità della tecnologia e il suo ruolo nell'ottimizzazione dei processi industriali.

Come notano Jones et al. (2020), l'aspetto più innovativo del Digital Twin consiste nella sua capacità di evolversi nel tempo, adattandosi ai mutamenti del sistema reale attraverso il continuo interscambio tra dati, modelli e simulazioni. Non si tratta quindi di un semplice "modello digitale realistico", ma di un ecosistema ciber-fisico complesso che integra conoscenza, sensori, dati storici operativi e algoritmi intelligenti.

In conclusione, la definizione e l'origine del Digital Twin risultano da una progressiva stratificazione di contributi scientifici e tecnologici provenienti da ambiti diversi: ingegneria dei sistemi, modellazione numerica, scienze dei dati, intelligenza artificiale e informatica industriale. Da questa evoluzione multidisciplinare emerge l'attuale concezione del Digital Twin come strumento strategico per l'ottimizzazione, la previsione e la gestione intelligente dei processi produttivi, aprendo la strada alle applicazioni e agli sviluppi trattati nelle sezioni successive

1.2 Contesto industriale e motivazioni

Recentemente, il settore industriale ha subito cambiamenti sostanziali che hanno trasformato profondamente come le aziende pianificano, amministrano e perfezionano i loro processi di produzione. Le sfide competitive globali, l'instabilità della domanda, le pressioni economiche e la crescente incertezza operativa hanno costretto le imprese ad affrontare una complessità mai vista prima (Kagermann et al., 2013; Suri, 2018). Si aggiungono fattori come la maggiore personalizzazione dei prodotti, la riduzione del ciclo vitale degli articoli e l'aumento della variabilità nelle forniture, complicando ulteriormente la gestione delle risorse (McKinsey Global Institute, 2021; Buer et al., 2021).

Questa complessità deriva da vari fattori convergenti.

Innanzitutto, i mercati sono diventati più instabili e difficili da prevedere: la domanda fluttua in modo sempre meno prevedibile, i volumi si modificano velocemente e i clienti esigono maggiore adattabilità, limitando l'efficienza dei sistemi di pianificazione tradizionali (Ivanov & Dolgui, 2020). In secondo luogo, è aumentata la diversità nei processi produttivi, che frequentemente uniscono operazioni automatizzate e manuali, creando una variabilità interna che complica la pianificazione (Peruzzini et al., 2020). Inoltre, l'attenzione crescente verso sostenibilità, efficienza energetica e riduzione degli sprechi obbliga le aziende a sviluppare nuove strategie per migliorare il monitoraggio e la tracciabilità dei flussi operativi (European Commission, 2020).

Secondo Deloitte (2023), una delle principali difficoltà che le imprese manifatturiere affrontano oggi è la limitata visibilità dei processi: numerose aziende mancano di strumenti capaci di rappresentare con precisione e in tempo reale quanto avviene quotidianamente nei reparti produttivi. I dati sono frammentati tra fogli Excel, sistemi gestionali non connessi, rapporti manuali e conoscenze implicite degli operatori. Ciò provoca inefficienze, ritardi nelle decisioni e configurazioni non ottimali delle linee.

È proprio questo divario tra realtà operativa e rappresentazione gestionale che evidenzia la necessità di strumenti in grado di colmare il gap informativo. Come sottolineano Wang et al. (2022), in assenza di un modello digitale coerente, le decisioni operative vengono frequentemente basate sull'esperienza, approccio che funziona in ambienti stabili ma diventa problematico in sistemi complessi, dinamici o con domanda variabile.

Il comparto agroalimentare, che include anche il caso pratico esaminato in questo studio, rappresenta un esempio significativo di queste problematiche. È infatti un settore contraddistinto da:

- marcata stagionalità,
- impiego massiccio di forza lavoro,
- alta variabilità delle materie prime,
- limiti rigorosi di tempo e capacità produttiva,
- esigenza di assicurare massima freschezza,
- processi operativi misti (manuali e automatizzati).

Studiosi come Moyano-Fuentes & Sacristán-Díaz (2012) e Centobelli et al. (2020) evidenziano come l'agroalimentare sia tra i settori con maggiore instabilità operativa, dove le variazioni nella disponibilità del personale, nelle rese produttive e nei difetti delle materie prime possono causare notevoli fluttuazioni nei tempi di lavorazione e nella capacità

produttiva giornaliera.

Un caso specifico documentato nella letteratura riguarda l'industria del confezionamento di prodotti freschi: piccole modifiche nel numero di lavoratori disponibili, nell'organizzazione delle linee o nel tipo di prodotto possono determinare variazioni del 20-30% nella capacità oraria (García et al., 2021). Ciò dimostra quanto sia fondamentale disporre di strumenti per anticipare il comportamento delle linee e adottare decisioni ottimali sull'allocazione delle risorse.

La ragione principale che spinge le aziende verso soluzioni digitali avanzate è quindi la necessità di prendere decisioni migliori e più tempestive, in un contesto dove i metodi convenzionali risultano inadeguati. L'analisi manuale è dispendiosa in termini di tempo, non consente di valutare numerose configurazioni alternative e non considera adeguatamente la complessità dei vincoli operativi. Inoltre, l'esperienza degli operatori, sebbene essenziale, non è sempre sufficiente quando aumenta il numero di variabili o quando l'ambiente operativo subisce cambiamenti significativi.

È qui che emergono le motivazioni fondamentali del "perché":

1. Perché aumenta la complessità?

Perché i sistemi produttivi sono attualmente più dinamici, variabili e interconnessi rispetto al passato (Lee et al., 2015).

2. Perché i metodi tradizionali non sono più sufficienti?

Perché non permettono di esaminare migliaia di possibili combinazioni di risorse, turni, vincoli e configurazioni.

3. Perché è necessario un approccio digitale avanzato?

Perché solo strumenti basati su dati e modelli predittivi consentono decisioni ottimali in tempi brevi (Addo-Tenkorang & Helo, 2016).

4. Perché occorre integrare simulazione e ottimizzazione?

Perché i processi contemporanei evolvono troppo rapidamente per essere gestiti con metodi rigidi o basati esclusivamente sull'esperienza.

Un esempio citato da BMW (2021) illustra come, attraverso modelli digitali e ottimizzazione, sia possibile diminuire del 30% il tempo necessario per riequilibrare le linee di montaggio dopo variazioni nei modelli prodotti. Similmente, Airbus impiega modelli digitali per simulare migliaia di configurazioni di linee prima di implementare modifiche reali, riducendo costi e rischi decisionali (Airbus Digital Twin Program, 2020).

Anche Siemens (2020) evidenzia come l'implementazione di modelli digitali e processi di ottimizzazione nelle proprie catene di montaggio abbia consentito un incremento della

produttività del 20-25%.

Tali casi non illustrano solamente i successi nel settore industriale, ma sottolineano come le problematiche delle grandi imprese siano analoghe - in proporzione - a quelle che affrontano le PMI: variabilità, incertezza e necessità di ottimizzazione.

Nell'analisi condotta durante questo tirocinio, l'impresa agroalimentare gestisce:

- linee produttive multiple con differenti capacità,
- costi di funzionamento disomogenei,
- personale operativo che varia tra i diversi turni e giorni,
- esigenze produttive con scadenze definite,
- processi con produttività differenziata, parzialmente automatizzati e parzialmente manuali.

In queste circostanze, determinare la configurazione ideale delle linee non è possibile attraverso un approccio intuitivo.

Ciascuna scelta — quantità di operatori per linea, selezione delle linee da attivare, distribuzione dei carichi lavorativi — impatta direttamente su:

- rendimento orario,
- spese complessive,
- utilizzo delle risorse umane,
- capacità di soddisfare gli ordini.

In assenza di supporti quantitativi, tali decisioni risultano complesse, rischiose e frequentemente non ottimali (Zhang et al., 2020).

L'azienda del caso studio, come molte realtà simili, si trova nella condizione di dover prendere decisioni operative ogni giorno, con dati variabili e vincoli stringenti.. Considerare tutte le possibili alternative senza un modello digitale risulta virtualmente impossibile e porta generalmente a decisioni prudenti, che favoriscono la continuità piuttosto che l'efficienza. Tuttavia, nell'attuale ambiente competitivo, efficienza e adattabilità rappresentano elementi cruciali per la sopravvivenza sul mercato.

È precisamente questa necessità — ottimizzare le configurazioni produttive, migliorare la trasparenza dei processi, utilizzare più efficacemente i dati — che rappresenta il motivo principale di questo studio.

Lo scopo non è introdurre tecnologia fine a sé stessa, ma offrire strumenti decisionali pratici, fondati su dati e modelli, in grado di perfezionare il processo produttivo concreto.

1.3 Architettura e implementazione del Digital Twin

L'architettura del Digital Twin costituisce un elemento fondamentale sia negli studi scientifici che nelle applicazioni industriali, fungendo da struttura portante in cui dati, modelli e algoritmi collaborano sinergicamente per rappresentare, analizzare e ottimizzare i sistemi fisici (Tao et al., 2019; Fuller et al., 2020). Contrariamente ai tradizionali modelli statici, il Digital Twin si basa su un'architettura intrinsecamente dinamica, concepita per preservare una costante coerenza informativa tra realtà e simulazione. Per questo motivo, vari studiosi evidenziano come il valore del Digital Twin non derivi esclusivamente dalla sua componente di modellazione, ma dalla capacità della sua architettura di incorporare continuamente dati, simulazioni, funzioni di monitoraggio e algoritmi intelligenti (Boschert & Rosen, 2016; Jones et al., 2020).

Un modello teorico particolarmente affermato è quello dei tre domini, inizialmente formulato da Tao e Zhang (2019) e successivamente elaborato da Qi e Tao (2018). In base a questa configurazione, il Digital Twin si suddivide in:

- Spazio fisico (Physical Space) – dove funzionano macchinari, linee produttive, operatori e sensori.
- Spazio virtuale (Virtual Space) – formato da modelli numerici, simulazioni, rappresentazioni parametriche e modelli comportamentali.
- Spazio di connessione (Connection Space) – che assicura il continuo trasferimento di dati tra dimensione reale e virtuale.

Questa suddivisione in tre parti è attualmente largamente accettata poiché riassume efficacemente il funzionamento del Digital Twin : i dati si muovono dall'ambiente fisico a quello virtuale, vengono processati attraverso modelli e algoritmi per poi tornare al sistema reale come intuizioni, suggerimenti o interventi di controllo (Kritzinger et al., 2018). Tale concezione supera definitivamente l'idea del modello digitale come entità isolata, integrandolo in un ciclo cyber-fisico ininterrotto.

Diversi studiosi hanno esteso questa struttura sottolineando come il Digital Twin non rappresenti un "oggetto singolo" ma un ecosistema composto da vari livelli funzionali. Boschert & Rosen (2016) propongono un'architettura stratificata che comprende modelli geometrici, fisico-matematici, comportamentali e sistemi di monitoraggio. In quest'ottica, ciascun livello contribuisce a rappresentare un aspetto specifico del sistema, generando una rappresentazione

multi-dominio che integra simulazione meccanica, processi energetici, dinamica dei materiali, fenomeni stocastici e comportamenti operativi.

Un apporto particolarmente significativo alla descrizione dell'architettura proviene da Negri et al. (2017), che mettono in luce la natura modulare e scalabile del Digital Twin. Secondo questi autori, esso può essere implementato a diversi livelli di dettaglio, dal singolo componente al processo completo, dalla cella produttiva al reparto fino all'intero stabilimento. Questa modularità permette di sviluppare architetture anche molto articolate mantenendo un alto grado di flessibilità, requisito fondamentale nei sistemi caratterizzati da variabilità operativa, come quelli esaminati in questo tirocinio.

Un ulteriore elemento architetture essenziale è la piattaforma dati, componente che secondo Grieves & Vickers (2017) rappresenta "il tessuto connettivo che consente al gemello digitale di esistere". Questa piattaforma ha la funzione di acquisire dati eterogenei da sensori, PLC, MES, ERP, fogli Excel e altre fonti aziendali, standardizzarli e renderli accessibili a modelli e algoritmi. Rasheed et al. (2020) evidenziano come la qualità dei dati costituisca uno dei fattori determinanti per l'efficacia del Digital Twin: in assenza di un'architettura dati robusta, il modello digitale non può aggiornarsi né riflettere accuratamente lo stato del sistema.

Numerose ricerche recenti presentano architetture a più livelli che permettono di dividere funzioni e compiti all'interno del Digital Twin (Minerva et al., 2022; Kritzinger et al., 2018). I livelli più comunemente identificati includono:

- Data Layer – responsabile della raccolta, pulizia, armonizzazione e archiviazione dei dati;
- Model Layer – contenente modelli geometrici, simulativi, fisici e data-driven;
- Service Layer – che coordina funzioni di monitoraggio, analisi predittiva, simulazione e ottimizzazione;
- Application Layer – orientato al supporto decisionale, alla visualizzazione dei risultati e all'integrazione con i sistemi di controllo.

Questa suddivisione è essenziale per capire come ciascun elemento dell'architettura influisca sul funzionamento globale del gemello digitale. Aiuta inoltre a localizzare l'implementazione degli algoritmi intelligenti, che costituiscono un elemento distintivo rispetto ai tradizionali sistemi di simulazione (Kapteyn et al., 2020).

In questo contesto si inserisce la tabella presente nel paragrafo, che riveste un'importanza

fondamentale nell'elaborato. Essa riassume i vari livelli architetturali, le loro funzioni, i tipi di dati utilizzati e il grado di interazione tra realtà fisica e digitale. Non ha una funzione meramente estetica, ma strutturale: consente di visualizzare sistematicamente le connessioni tra i componenti del Digital Twin e di comprendere come dati, modelli e algoritmi si distribuiscano nei diversi strati. La tabella evidenzia anche il punto centrale della tesi: gli algoritmi come componente integrale dell'architettura, non come semplice elemento aggiuntivo.

La creazione di un Digital Twin necessita anche di una fase di definizione degli obiettivi, come evidenziato da Leng et al. (2021). Prima di progettare la struttura, occorre definire quali fenomeni rappresentare, quali indicatori monitorare e quali decisioni supportare. Solo così si può determinare il livello di dettaglio dei modelli, la frequenza di aggiornamento dei dati e il grado di autonomia desiderato.

Il processo implementativo segue diverse fasi interconnesse:

- identificazione degli asset e dei processi da modellare.

Secondo Tao et al. (2019), la prima fase consiste nell'individuare con precisione quali elementi del sistema fisico debbano essere rappresentati digitalmente, definendo perimetro, variabili critiche e obiettivi funzionali del gemello digitale. Gli autori sottolineano che una definizione errata dell'asset comporta la realizzazione di un modello incompleto o non rappresentativo

- raccolta e analisi delle fonti dati

Lee et al. (2015) evidenziano che la qualità del Digital Twin dipende direttamente dalla disponibilità, affidabilità e granularità dei dati raccolti dal sistema fisico. L'identificazione delle sorgenti informative, dei sensori e dei parametri misurabili rappresenta un passaggio fondamentale per costruire un gemello digitale coerente.

- progettazione dei modelli e dei flussi informativi

Secondo Grieves & Vickers (2017), la modellazione del gemello richiede la definizione della struttura logica, dei modelli fisico-matematici, dei modelli data-driven e delle modalità di scambio informativo tra mondo fisico e virtuale. La progettazione del modello è il cuore concettuale del Digital Twin.

- integrazione con i sistemi aziendali

Negri et al. (2017) sottolineano che la fase di integrazione rappresenta una delle più critiche, poiché comporta la connessione tra il gemello digitale e sistemi quali MES,

ERP, SCADA, PLM e piattaforme IoT. L'interoperabilità e la standardizzazione dei protocolli sono condizioni essenziali per garantire continuità informativa

- validazione del Digital Twin

Kapteyn et al. (2020) indicano che la validazione è necessaria per assicurare che il modello digitale rispecchi con accuratezza il comportamento reale del sistema fisico. La validazione può essere condotta tramite dati storici, test in ambiente controllato o confronto continuo con performance reali.

- utilizzo operativo, con cicli di aggiornamento continuo

Jones et al. (2020) affermano che il Digital Twin diventa realmente efficace solo quando viene impiegato operativamente attraverso un ciclo continuo di aggiornamento e apprendimento. Il gemello digitale deve evolvere nel tempo insieme al sistema fisico, incorporando nuovi dati, eventi e condizioni operative.

Nel contesto industriale, molti casi pratici dimostrano l'importanza cruciale dell'architettura per il successo del Digital Twin. Siemens utilizza un'architettura multilivello che combina CAD, PLM, MES e algoritmi di ottimizzazione per migliorare la pianificazione produttiva (Siemens, 2020). BMW impiega un Digital Twin modulare per modificare rapidamente le linee di assemblaggio in caso di cambi di modello (BMW Manufacturing Report, 2021). Airbus adotta una struttura analoga per analizzare colli di bottiglia e simulare numerosi scenari operativi prima di implementare cambiamenti reali (Airbus Digital Twin Program, 2020).

Questi casi illustrano chiaramente un principio fondamentale: l'architettura non è un semplice dettaglio tecnico, ma l'elemento che permette la vera funzione del gemello digitale, ovvero la capacità di apprendere dai dati, rappresentare accuratamente la realtà e fornire consigli ottimizzati. Come sottolineano Madni & Madni (2019), è proprio nella struttura architeturale che risiede il potenziale del Digital Twin di evolversi verso sistemi cognitivi, capaci di integrare algoritmi avanzati di simulazione, previsione e decisione.

È proprio questa transizione — dall'architettura ai meccanismi decisionali — che introduce naturalmente l'argomento del paragrafo successivo: il ruolo degli algoritmi intelligenti. Se l'architettura definisce il funzionamento del gemello digitale, sono gli algoritmi a determinarne le capacità: prevedere, apprendere, ottimizzare, supportare le decisioni. Per questo motivo, comprendere l'architettura è essenziale per capire il contributo decisivo degli algoritmi nell'ambito del Digital Twin.

Elemento	Descrizione tecnico-funzionale	Autori di riferimento	Esempi industriali reali	Ruolo nei processi decisionali e negli algoritmi
Entità fisica (Physical Entity)	Macchina, impianto o prodotto reale da cui originano i dati. È il punto di partenza del ciclo informativo.	Grieves (2014); Kritzinger et al. (2018); Tao et al. (2019)	Linee di assemblaggio automobilistiche (BMW, Toyota); turbine GE	Fornisce dati grezzi necessari per modelli predittivi, manutenzione, anomaly detection.
Modello virtuale (Digital Model)	Rappresentazione numerica dettagliata che replica geometria, comportamento e parametri fisici.	Boschert & Rosen (2016); Jones et al. (2020)	Airbus – simulazioni strutturali; Siemens NX per linee di produzione	Supporta simulazioni what-if, previsione performance, ottimizzazione layout e parametri.
Flusso bidirezionale dei dati (Data Connection)	Aggiornamento continuo tra fisico e digitale tramite IoT, edge computing e cloud.	Qi & Tao (2018); Rasheed et al. (2020)	Digital Factory Siemens; sistemi SCADA avanzati	Consente aggiornamento real time, basi per RL e algoritmi adattivi.
Piattaforma di analisi e simulazione	Motore di calcolo che integra modelli FEM, simulazioni discrete-evento, AI e ML.	Negri et al. (2017); Min et al. (2019); Fantozzi et al. (2025)	General Electric Predix; Bosch Digital Twin Suite	Implementa predizioni, ottimizzazioni, scheduling intelligente, rilevamento anomalie.
Interfaccia utente (User Interface)	Strumenti grafici per operatori e manager: KPI,	Hepworth & Church (2023); Zhang et al.	Siemens WinCC; ABB Ability	Permette decision-making rapido,

Dashboard)	allarmi, simulazioni (2022) visuali.	validazione scenari, supervisione e controllo.
-------------------	---	---

Nota: la struttura proposta è coerente con le classificazioni di Kritzinger et al. (2018), Boschert & Rosen (2016) e con il modello concettuale dei Digital Twin-Driven Manufacturing Systems (DTMS) presentato da Tao et al. (2019).

1.4 Ruolo del Digital Twin e integrazione con gli algoritmi intelligenti

Il funzionamento del Digital Twin nei moderni sistemi di produzione può essere compreso solo esaminando approfonditamente il ruolo degli algoritmi intelligenti che ne costituiscono il centro operativo. Attraverso questi elementi computazionali, sviluppa capacità predittive, prescrittive e adattive, diventando uno strumento fondamentale per il processo decisionale in ambienti industriali complessi. Nonostante l'architettura del Digital Twin fornisca la struttura base in cui si integrano dati, modelli e processi, sono gli algoritmi che permettono al sistema digitale di interpretare la realtà fisica, prevedere eventi futuri, ottimizzare l'allocazione delle risorse e adattarsi all'evoluzione del sistema reale, come evidenziato da importanti studi nella letteratura internazionale (Rasheed et al., 2020; Leng et al., 2021; Madni & Madni, 2019).

L'implementazione degli algoritmi trasforma il Digital Twin da una semplice piattaforma di rappresentazione avanzata a un vero motore cognitivo capace di apprendere dai dati, simulare scenari alternativi e identificare strategie operative ottimali. Come sottolineato da Tao et al. (2019), gli algoritmi sono l'elemento che consente al gemello digitale di superare i limiti dei tradizionali modelli statici, permettendo la creazione di sistemi produttivi veramente intelligenti e adattivi. Nell'attuale contesto industriale, caratterizzato da alta variabilità, molteplici vincoli e incertezza strutturale (Ivanov & Dolgui, 2020), il ruolo degli algoritmi nel Digital Twin diventa ancora più significativo: diventano essenziali non solo per prevedere il comportamento del sistema, ma anche per ottimizzare continuamente le decisioni operative, affrontando problemi di pianificazione, allocazione delle risorse, configurazione delle linee e gestione di scenari produttivi complessi (Zhuang et al., 2021; Zhang et al., 2020).

L'utilizzo degli algoritmi consente di interpretare l'enorme quantità di dati generati dai sistemi industriali, trasformando informazioni eterogenee in conoscenza operativa utile e immediatamente applicabile. Come indicato da Lee et al. (2015), il valore della digitalizzazione non sta solo nella raccolta dei dati, ma nella capacità di estrarne significato, identificare modelli e utilizzare queste informazioni per prendere decisioni solide. Nel Digital Twin, questa capacità è resa possibile da tre principali funzioni algoritmiche: predizione, ottimizzazione e adattamento continuo.

La funzione predittiva, analizzata in numerosi studi (Rasheed et al., 2020; Putra et al., 2022), permette di anticipare fenomeni come guasti, rallentamenti, ritardi produttivi, saturazione delle linee e deterioramento delle prestazioni. Gli algoritmi di machine learning e modellazione statistica permettono di identificare segnali deboli che precedono comportamenti anomali del sistema, offrendo un importante vantaggio competitivo nelle attività di manutenzione, controllo qualità e pianificazione. Secondo IBM (2021), i Digital Twin dotati di modelli predittivi riducono del 30% le anomalie non rilevate e migliorano significativamente le prestazioni complessive dei sistemi produttivi.

La seconda area funzionale riguarda la capacità del Digital Twin di ottimizzare il funzionamento del sistema, grazie all'uso di algoritmi matematici e metaeuristici in grado di esplorare numerose configurazioni alternative e identificare quelle più vantaggiose in termini di costi, efficienza, capacità produttiva e rispetto dei vincoli operativi. La letteratura riconosce che modelli come linear programming, integer programming e constraint programming sono efficaci in contesti strutturati (Bertsimas & Tsitsiklis, 1997), mentre le metaeuristiche sono particolarmente utili in contesti complessi, altamente variabili o caratterizzati da ampi spazi di ricerca (Talbi, 2009; Abdellaoui et al., 2022). Questo è particolarmente vero nei sistemi produttivi come quelli analizzati in questo tirocinio, dove le possibili combinazioni di linee, operatori e capacità orarie rendono impossibile una valutazione manuale. A questo proposito, casi studio come quelli di Siemens (2020) e BMW (2021) mostrano come l'integrazione tra Digital Twin e algoritmi di ottimizzazione permetta di migliorare la produttività delle linee tra il 10% e il 30%.

Una terza funzione cruciale degli algoritmi riguarda la capacità del Digital Twin di adattarsi nel tempo. L'adozione di algoritmi di reinforcement learning consente di creare sistemi capaci di apprendere dalle proprie esperienze, migliorando progressivamente la qualità delle decisioni grazie alla continua interazione tra simulazione e realtà (Sutton & Barto, 2018; Madni & Madni, 2019). Questo approccio è particolarmente utile in contesti caratterizzati da forte variabilità, come il settore agroalimentare o la produzione mista manuale-automatica. Studi industriali come quelli di Toyota (2022) e General Electric (2018) mostrano che l'uso di algoritmi adattivi

nei Digital Twin consente miglioramenti significativi nella gestione dei flussi e nella previsione dei carichi di lavoro.

Oltre alle tre funzioni principali, gli algoritmi svolgono anche un ruolo essenziale nella sincronizzazione digitale, filtrando il rumore nei dati, gestendo l'incertezza e stimando stati non direttamente osservabili del sistema fisico. Approcci probabilistici e metodi bayesiani, come dimostrato da Rashid et al. (2022), sono ampiamente utilizzati per garantire che il Digital Twin rifletta accuratamente lo stato reale del sistema anche quando i dati sono incompleti o disturbati. In questo modo, gli algoritmi funzionano come mediatori intelligenti che mantengono coerente la relazione tra mondo fisico e virtuale, assicurando che il gemello digitale sia sempre aggiornato, affidabile e utilizzabile per decisioni critiche.

Numerosi esempi industriali confermano l'importanza dell'integrazione tra Digital Twin e algoritmi intelligenti. Airbus utilizza algoritmi evolutivi per ottimizzare i processi di assemblaggio e migliorare l'identificazione dei colli di bottiglia (Airbus, 2020). BMW impiega algoritmi predittivi per anticipare variazioni nelle linee di montaggio (BMW Manufacturing Report, 2021). Siemens implementa metodologie di machine learning nella piattaforma MindSphere per ottimizzare la configurazione delle linee in tempo reale (Siemens, 2020). Questi casi evidenziano un concetto fondamentale: un Digital Twin privo di algoritmi mancherebbe della capacità di apprendere, prevedere, ottimizzare e supportare decisioni complesse. Risulterebbe un modello digitale sofisticato, ma senza intelligenza. Il vero potenziale del gemello digitale si manifesta quando incorpora un sistema algoritmico coerente, solido e capace di valorizzare i dati acquisiti. Questo elemento risulta determinante anche nel contesto aziendale di questo tirocinio, dove le operazioni quotidiane — quali la configurazione delle linee, la distribuzione del personale e l'analisi della produttività oraria — necessitano di valutare numerose variabili e possibili scenari. L'implementazione di algoritmi nel gemello digitale permette di analizzare velocemente innumerevoli alternative, offrendo indicazioni concrete e ottimizzate per la gestione delle risorse. Gli algoritmi diventano così un ausilio decisionale essenziale, capaci di convertire una complessità umanamente ingestibile in un procedimento organizzato e data-driven. Gli studi accademici confermano che l'efficienza di un Digital Twin dipende significativamente dalla selezione e qualità degli algoritmi impiegati (Leng et al., 2021; Zhuang et al., 2021). Per questo motivo, la fase successiva di questo studio diventa cruciale: esaminare dettagliatamente e confrontare le varie categorie algoritmiche integrabili in un Digital Twin per risolvere problematiche di ottimizzazione produttiva. Quest'analisi non è un semplice approfondimento tecnico, ma rappresenta il fondamento metodologico per identificare gli approcci più idonei al caso pratico di questo tirocinio. Nel prossimo capitolo saranno esaminate sistematicamente le principali tipologie di algoritmi —

modelli matematici, metaeuristiche, tecniche di machine learning e metodologie di reinforcement learning — evidenziandone differenze strutturali, vantaggi, limitazioni, requisiti di dati e ambiti applicativi. Questo percorso è fondamentale per comprendere non solo il funzionamento dei diversi algoritmi, ma anche il loro contributo all'interno di un Digital Twin finalizzato all'ottimizzazione dei processi produttivi. L'intento sarà determinare, basandosi sulla letteratura e sull'analisi comparativa, quali strategie algoritmiche risultino più efficaci e appropriate rispetto agli obiettivi aziendali, stabilendo così le basi per l'intera componente applicativa del lavoro.

Metodologia e stato dell'arte sugli algoritmi per il Digital Twin

2.1 Approccio metodologico

L'esame approfondito degli algoritmi nell'ambito del Digital Twin necessita di un approccio metodologico estremamente articolato, capace di armonizzare con maestria il rigore scientifico, la profondità concettuale e una spiccata sensibilità verso le concrete necessità operative che caratterizzano il panorama industriale contemporaneo. La sempre più accentuata complessità che contraddistingue i moderni sistemi di produzione, congiuntamente all'imprescindibile esigenza di amministrare voluminose quantità di dati eterogenei, ha reso fondamentale l'adozione di una strategia metodologica che sappia integrare armoniosamente i preziosi contributi provenienti dalle discipline dell'Intelligenza Artificiale, dell'Operations Research e dei sofisticati sistemi cyber-fisici (Negri et al., 2017; Tao et al., 2018; Jones et al., 2020). L'itinerario metodologico che abbiamo scelto di percorrere in questo capitolo si fonda sulla concezione innovativa secondo cui il Digital Twin non rappresenta semplicemente una mera replica virtuale, bensì costituisce una sofisticata piattaforma decisionale intelligente all'interno della quale modelli, dati e algoritmi interagiscono sinergicamente per orientare e sostenere il perfezionamento incessante dei processi industriali (Grieves & Vickers, 2017; Boschert & Rosen, 2016).

La fase iniziale della mia metodologia è stata meticolosamente dedicata alla circoscrizione dell'ambito analitico, attraverso un'accurata e sistematica revisione della letteratura scientifica disponibile, condotta esplorando approfonditamente database accademici di primaria importanza quali Scopus, ScienceDirect e SpringerLink, applicando rigorosi criteri di ricerca incentrati su termini chiave specifici come "Digital Twin optimization", "algorithmic frameworks for manufacturing", "AI-driven Digital Twin" e "intelligent decision systems" (Kritzinger et al., 2018; Leng et al., 2021). Questo scrupoloso procedimento mi ha consentito di individuare e mappare le principali correnti di ricerca concernenti l'applicazione algoritmica nel contesto del Digital Twin, operando una netta distinzione tra le diverse tipologie di approcci: deterministici, stocastici, evolutivi e quelli fondati sui principi dell'apprendimento automatico (Qi & Tao, 2018; Benavides et al., 2022). Il mio intento primario è stato quello di edificare un solido fondamento conoscitivo sul quale poter successivamente innestare un'analisi comparativa caratterizzata da coerenza interna e robustezza scientifica.

La metodologia che ho adottato incorpora, inoltre, gli elementi distintivi delle systematic literature reviews proposte da Kitchenham & Charters (2007), secondo le quali il processo di selezione delle fonti bibliografiche deve necessariamente attenersi a criteri rigorosi di pertinenza tematica, eccellenza qualitativa e significatività temporale. Per tale ragione, la mia revisione ha accordato particolare preferenza ai contributi scientifici pubblicati nel corso dell'ultimo decennio, in quanto essi rappresentano indubbiamente lo stato più aggiornato e all'avanguardia dell'evoluzione concettuale del Digital Twin e delle sofisticate tecniche di ottimizzazione basate sull'Intelligenza Artificiale (Tao et al., 2019; Zhang et al., 2021). Ciononostante, abbiamo ritenuto opportuno includere nella nostra analisi anche alcuni lavori fondamentali di natura seminale — quali Grieves (2014), Rosen et al. (2015) e Kritzinger et al. (2018) — ritenuti assolutamente imprescindibili per acquisire una comprensione approfondita delle radici teoriche e concettuali del fenomeno in esame.

Una volta delineato con precisione il corpus teorico di riferimento, ho proceduto all'elaborazione di un modello metodologico strutturato, fondato su cinque criteri analitici principali, accuratamente selezionati in piena conformità con quanto proposto nelle autorevoli pubblicazioni di Tao et al. (2018), Galli et al. (2021) e Pronost & Lambert (2024):

1. Tipologia di dati necessari (Shin et al., 2020; Florescu et al., 2024).
2. Grado di autonomia decisionale (Sutton & Barto, 2018; Qi & Tao, 2018).
3. Orizzonte temporale della decisione (Gendreau & Potvin, 2019).

4. Scalabilità e complessità computazionale (Leng et al., 2021; Zhang et al., 2021).
5. Robustezza rispetto all'incertezza (Benavides et al., 2022; Thramboulidis et al., 2020).

Questi criteri non solo emergono nella letteratura internazionale, ma riflettono anche le esigenze operative dei sistemi industriali, in cui le decisioni devono essere prese rapidamente, spesso in presenza di variabilità elevata e informazioni incomplete (Thiede et al., 2021; Panetto et al., 2019). Essi costituiscono dunque l'asse portante che guida l'intera analisi degli algoritmi svolta nel capitolo.

Criterio di analisi	Descrizione	Rilevanza per il Digital Twin
Tipologia di dati richiesti	Valuta quantità, qualità e struttura dei dati necessari al funzionamento dell'algoritmo.	Determina la fattibilità dell'implementazione in contesti caratterizzati da dati completi o parziali.
Autonomia decisionale	Misura la capacità dell'algoritmo di generare soluzioni e aggiornare le decisioni senza intervento umano diretto.	Consente di valutare il livello di intelligenza e automazione del Digital Twin.
Orizzonte temporale della decisione	Analizza l'idoneità dell'algoritmo a supportare decisioni strategiche, tattiche o operative.	Permette di comprendere la capacità di risposta a scenari statici o dinamici.
Scalabilità e complessità computazionale	Valuta il comportamento dell'algoritmo all'aumentare della dimensione del problema e del numero di variabili.	È fondamentale nei sistemi produttivi complessi con numerose risorse e vincoli.
Robustezza all'incertezza	Analizza la capacità dell'algoritmo di mantenere prestazioni soddisfacenti in presenza di variabilità, rumore o dati incompleti.	Consente di valutare l'affidabilità del Digital Twin in contesti industriali reali.

I criteri riportati nella Tabella sono stati utilizzati come riferimento per l'analisi comparativa delle diverse famiglie algoritmiche esaminate nel presente lavoro. L'obiettivo è stato valutare le

caratteristiche operative, i vantaggi e i limiti di ciascun approccio, evidenziandone l'idoneità all'integrazione all'interno di un Digital Twin per l'ottimizzazione dei processi produttivi


La revisione della letteratura è stata condotta mediante la consultazione dei principali database scientifici internazionali, tra cui Scopus, ScienceDirect e SpringerLink. La ricerca è stata finalizzata all'individuazione di contributi relativi al Digital Twin, all'ottimizzazione dei processi produttivi e agli algoritmi intelligenti applicati ai sistemi manifatturieri.

Le principali parole chiave utilizzate sono state: Digital Twin optimization, Digital Twin manufacturing ,Intelligent decision systems ,AI-driven Digital Twin ,Machine Learning for manufacturing ,Reinforcement Learning in production systems,Production optimization algorithms

Sono stati privilegiati gli articoli pubblicati negli ultimi dieci anni, integrando tuttavia alcuni contributi fondamentali per la definizione teorica del Digital Twin e delle principali metodologie di ottimizzazione. Successivamente è stata effettuata una selezione sulla base della pertinenza rispetto agli obiettivi della ricerca, escludendo gli studi non direttamente collegati all'ottimizzazione dei sistemi produttivi mediante Digital Twin.

Famiglia algoritmica	Numero studi	Percentuale
Modelli matematici (LP, MILP, CP)	18	25,4%
Metaeuristiche ed euristiche	16	22,5%
Machine Learning	21	29,6%
Reinforcement Learning	16	22,5%
Totale	71	100%

La distribuzione degli studi selezionati evidenzia una crescente attenzione della comunità scientifica verso l'applicazione di algoritmi intelligenti nei Digital Twin industriali. In particolare, Machine Learning e Reinforcement Learning rappresentano una quota significativa della letteratura più recente, confermando la progressiva evoluzione dei Digital Twin verso sistemi sempre più autonomi e data-driven. Allo stesso tempo, i modelli matematici e le metaeuristiche continuano a svolgere un ruolo rilevante nei problemi di ottimizzazione produttiva, grazie alla loro capacità di fornire soluzioni efficaci in presenza di vincoli operativi complessi.



Distribuzione degli studi selezionati per famiglia algoritmica.

2.2 Stato dell'arte per famiglie di algoritmi

Nel corso degli ultimi anni, l'importanza e la centralità degli algoritmi nell'amplificazione delle potenzialità del Digital Twin hanno attirato un'attenzione sempre maggiore all'interno della comunità scientifica internazionale. Gli studiosi del settore identificano questi sofisticati strumenti computazionali come elementi assolutamente imprescindibili nel processo di trasformazione del Digital Twin, che evolve da un semplice e basilare modello descrittivo a un complesso e articolato sistema cognitivo e decisionale di avanguardia. Numerosi e autorevoli ricercatori evidenziano con particolare enfasi come risulti praticamente impossibile comprendere appieno la natura e le funzionalità del Digital Twin contemporaneo senza un'analisi approfondita e sistematica delle diverse famiglie algoritmiche che ne alimentano e potenziano le capacità predittive, prescrittive e adattive (Tao et al., 2018; Boschert & Rosen, 2016; Jones et al., 2020). L'implementazione sinergica e coordinata di tecniche matematiche avanzate, approcci metaeuristici innovativi e sofisticati algoritmi di intelligenza artificiale costituisce, senza alcun dubbio, un prerequisito fondamentale e assolutamente necessario affinché il Digital Twin possa efficacemente supportare i processi di pianificazione strategica, ottimizzazione operativa e monitoraggio continuo e capillare dei sistemi produttivi moderni (Negri et al., 2017; Fuller et al., 2020).

La letteratura specialistica mette chiaramente in luce come il progressivo e inarrestabile aumento della complessità nei contesti industriali contemporanei — caratterizzato da cicli produttivi estremamente compressi, variabilità sempre più accentuata, crescenti richieste di

personalizzazione e una sempre più profonda integrazione con sistemi cyber-fisici avanzati — abbia inevitabilmente guidato e accelerato l'evoluzione dei modelli algoritmici verso approcci significativamente più flessibili, adattivi e guidati dai dati (Kritzinger et al., 2018; Madni & Madni, 2019; Leng et al., 2021). In modo particolare, le approfondite ricerche condotte da Zhang et al. (2021) e Gabor et al. (2020) illustrano con straordinaria chiarezza come il Digital Twin necessiti di algoritmi particolarmente sofisticati, capaci di elaborare e analizzare enormi volumi di dati eterogenei, gestire efficacemente condizioni di incertezza e ambiguità, simulare scenari estremamente complessi e multidimensionali, e adattarsi dinamicamente e in tempo reale alle mutevoli condizioni operative. Questa evoluzione tecnologica ha portato gli esperti a identificare e classificare almeno quattro principali e distinte famiglie algoritmiche: i modelli matematici deterministici tradizionali, le innovative metaeuristiche evolutive, i sofisticati algoritmi di machine learning e le avanzate tecniche di reinforcement learning, ciascuna delle quali presenta caratteristiche, ruoli, limitazioni e requisiti operativi profondamente differenti e specifici (Bibby & Skauge, 2018; Cimino et al., 2019).

Gli algoritmi non sono semplicemente un'aggiunta, ma rappresentano l'essenza del funzionamento del Digital Twin, in quanto dotano il modello virtuale della capacità di imparare dal sistema fisico e di influenzare attivamente le sue decisioni operative. Come notato da Qi & Tao (2018), l'unione tra Digital Twin e algoritmi intelligenti permette di evolvere dalla semplice simulazione alla simulazione cognitiva, in cui il sistema può prevedere le conseguenze delle proprie azioni e ottimizzare autonomamente le prestazioni. Questo approccio è attualmente considerato uno dei pilastri fondamentali del Digital Twin-Driven Smart Manufacturing (Du et al., 2020; Fantozzi et al., 2025).

Studi aggiuntivi dimostrano come le varie famiglie di algoritmi soddisfino diverse necessità industriali: i modelli matematici offrono precisione e verificabilità (Bertsimas & Tsitsiklis, 1997), le metaeuristiche consentono di affrontare problemi non lineari e poco strutturati (Dorigo & Stützle, 2004), il machine learning permette di ricavare conoscenza da dati complessi e multidimensionali (Goodfellow et al., 2016; Touckia et al., 2023), mentre il reinforcement learning apporta capacità di decisione autonoma in contesti dinamici (Sutton & Barto, 2018). Le analisi sistematiche di Minerva et al. (2022), Krishnan et al. (2023) e Griva et al. (2021) sottolineano anche un aumento nell'uso di approcci ibridi, che integrano modelli deterministici con algoritmi evolutivi o tecniche di apprendimento automatico per migliorare solidità, scalabilità e velocità di risposta.

Complessivamente, queste evidenze mostrano che comprendere lo stato dell'arte degli algoritmi applicati al Digital Twin è fondamentale non solo per illustrare le tecnologie disponibili oggi, ma anche per stabilire i criteri di selezione che orientano l'implementazione del Digital Twin in

ambienti industriali complessi. La sezione successiva esamina dettagliatamente le quattro principali famiglie algoritmiche presenti nella letteratura scientifica, tracciandone l'evoluzione, i campi di applicazione e le principali opportunità emerse negli anni recenti.

2.2.1 Modelli matematici: la razionalità dell'ottimizzazione classica

Gli algoritmi basati su modelli matematici costituiscono il fondamento dell'ottimizzazione industriale. Tali metodologie si basano sulla descrizione del sistema produttivo attraverso equazioni e vincoli, con l'obiettivo di massimizzare o minimizzare una funzione di costo. Risultano particolarmente vantaggiosi in contesti dove le variabili di processo sono note e stabili, e dove la produzione segue schemi ripetitivi e ben definiti, come accade nei settori automotive o alimentare (Negri et al., 2017).

Il vantaggio principale dei modelli matematici, come la Linear Programming (LP) o la Mixed Integer Linear Programming (MILP), consiste nella loro capacità di fornire una soluzione ottimale verificabile e matematicamente garantita, come sottolineato dalla letteratura classica sull'ottimizzazione (Dantzig, 1963; Nemhauser & Wolsey, 1988; Bertsimas & Tsitsiklis, 1997). Questi approcci sono particolarmente efficaci quando il problema produttivo può essere espresso attraverso vincoli lineari e funzioni obiettivo ben definite, condizione che li rende uno strumento fondamentale nella pianificazione della produzione e nella gestione delle risorse (Pinedo, 2016; Jans & Degraeve, 2007). I modelli LP e MILP vengono ampiamente impiegati per determinare la sequenza ottimale delle operazioni e per allocare in modo efficiente materiali, macchinari e operatori, garantendo il rispetto di vincoli di capacità, disponibilità delle risorse, tempi di consegna e obiettivi di costo (Chen et al., 2013; Melo et al., 2006). La loro applicazione è documentata in numerosi settori industriali, dai sistemi manifatturieri discreti alle produzioni continua, dove tali modelli si dimostrano robusti e affidabili nel supportare decisioni critiche.

Ad esempio, in una linea di assemblaggio, un modello MILP può aiutare a bilanciare i carichi di lavoro tra le diverse postazioni, minimizzando i tempi morti, riducendo i colli di bottiglia e garantendo un flusso costante dei materiali lungo l'intero processo (Becker & Scholl, 2006; Boysen et al., 2007). Studi empirici mostrano che l'uso del MILP nel line balancing permette di ottenere miglioramenti significativi nell'efficienza complessiva del sistema, soprattutto nei contesti ad alta variabilità o con cicli produttivi complessi (Pastor & Corominas, 2010; Hwang et al., 2018).

Dal punto di vista dell'industrializzazione, l'uso di modelli deterministici ci consente di passare

dalla pianificazione basata sull'esperienza a un'ottica quantitativa e quantificabile. Tuttavia, la loro rigidità rappresenta un limite nei contesti più complessi o variabili, dove i dati non sono sempre disponibili in forma precisa e dove la flessibilità decisionale diventa cruciale. Per questo motivo, negli stabilimenti moderni e digitalizzati, questi modelli sono frequentemente accompagnati o sostituiti da metodologie più flessibili, in grado di adattarsi a condizioni in continuo mutamento (Tao et al., 2018).

Un elemento frequentemente trascurato concerne l'importanza strategica, e non meramente operativa, dei modelli matematici nell'ambito aziendale. La loro architettura formale consente, infatti, una rappresentazione estremamente precisa e metodica delle interconnessioni esistenti tra risorse disponibili, tempistiche operative, limitazioni industriali e gerarchie decisionali, assicurando così un grado di comprensibilità che continua a rimanere essenziale persino nei contesti produttivi caratterizzati da elevata digitalizzazione (Negri et al., 2017). Tale peculiarità assume particolare rilevanza nei contesti di industrializzazione progredita, dove la chiarezza intrinseca delle soluzioni matematiche facilita notevolmente il compito dirigenziale nell'identificazione inequivocabile dei fattori che esercitano maggiore influenza sull'efficienza complessiva, guidando conseguentemente le scelte relative agli investimenti, alle modifiche progettuali e alle decisioni di carattere strategico.

Un ulteriore apporto di notevole importanza riguarda l'implementazione dei modelli matematici quale fondamento comparativo all'interno degli ecosistemi produttivi che si avvalgono della tecnologia Digital Twin. Grazie alla loro intrinseca natura deterministica, questi modelli offrono un parametro di confronto solido e affidabile per la valutazione qualitativa delle soluzioni elaborate mediante algoritmi di natura più adattiva, quali le metaeuristiche o le metodologie di apprendimento automatico. Come brillantemente evidenziato nella ricerca di Galli et al. (2021), l'integrazione di un modello matematico permette un'analisi considerevolmente più dettagliata delle divergenze tra le soluzioni teoricamente ottimali e quelle effettivamente implementate attraverso algoritmi basati sui dati, promuovendo così un'integrazione decisamente più consapevole tra metodologie tradizionali e approcci intelligenti innovativi. In tale prospettiva, il modello matematico si trasforma in un autentico "piano di equilibrio" che consente al Digital Twin di investigare configurazioni alternative mantenendo, al contempo, piena coerenza con i vincoli fisici e le limitazioni produttive del mondo reale.

In conclusione, la sempre maggiore complessità delle reti produttive e delle catene di approvvigionamento multi-stabilimento ha posto in primo piano la necessità di sviluppare modelli matematici capaci di gestire ottimizzazioni su scala estesa, frequentemente strutturate mediante tecniche di decomposizione o approcci di tipo gerarchico. Questi sofisticati modelli consentono un efficace coordinamento decisionale tra diversi impianti, linee produttive o

dipartimenti, garantendo piena armonia tra gli obiettivi specifici locali e quelli generali dell'organizzazione. Come acutamente osservato da Tao & Qi (2018), l'efficienza delle architetture produttive intelligenti si fonda anche sulla straordinaria capacità dei modelli matematici di fornire una struttura unificante che mantiene in perfetto allineamento l'intero sistema, prevenendo potenziali conflitti decisionali e assicurando un utilizzo ottimale delle risorse disponibili a qualsiasi livello della catena di approvvigionamento.

Aspetto	Sintesi
Obiettivo	Trovare l'ottimo esatto nel rispetto dei vincoli.
Punti di forza	Rigore matematico, trasparenza, soluzioni verificabili.
Limiti	Scalabilità limitata; richiedono dati completi e strutturati.
Quando usarli nel Digital Twin	Pianificazione, scheduling deterministico, analisi dei vincoli.
Requisiti	Struttura dati affidabile; descrizione formale del problema.

2.2.2 Euristiche e metaeuristiche: la flessibilità come valore industriale

Le metaeuristiche rappresentano un'evoluzione naturale rispetto ai modelli matematici classici. Si tratta di algoritmi capaci di esplorare rapidamente un ampio spazio di soluzioni, individuando configurazioni efficienti anche quando il problema è troppo complesso per essere risolto in modo esatto. Tra le più utilizzate vi sono i Genetic Algorithms (GA), la Particle Swarm Optimization (PSO) e la Ant Colony Optimization (ACO), tecniche che traggono ispirazione da fenomeni naturali come l'evoluzione biologica, il comportamento collettivo degli animali o i processi di auto-organizzazione (Florescu et al., 2024).

Nel contesto industriale, questi metodi sono fondamentali per risolvere problemi di scheduling, bilanciamento delle linee, configurazione dei layout produttivi o ottimizzazione dei parametri macchina, come ampiamente evidenziato in numerosi contributi scientifici (Talbi, 2009; Blum & Roli, 2003; Gendreau & Potvin, 2019). Le metaeuristiche sono infatti particolarmente adatte

per affrontare problemi caratterizzati da elevata complessità combinatoria e variabilità operativa, tipici delle linee di produzione moderne e dei sistemi manifatturieri flessibili (Florescu et al., 2024; Galli et al., 2021).

Ad esempio, in un impianto di confezionamento, un algoritmo genetico può individuare la sequenza di produzione che riduce al minimo i tempi di cambio formato, una tipologia di problema ampiamente affrontata dalla letteratura nell'ambito del sequencing e del setup time optimization (Gen & Cheng, 2000; Tamaki et al., 1996). Gli studi mostrano che i Genetic Algorithms sono particolarmente efficaci per ridurre i tempi di attrezzaggio e migliorare la produttività complessiva della linea senza modificare la struttura dell'impianto, grazie alla loro capacità di esplorare rapidamente grandi spazi di soluzioni (Holland, 1992; Deb, 2001).

Allo stesso modo, un algoritmo PSO può regolare in tempo reale le velocità di una linea di imbottigliamento per minimizzare i colli di bottiglia, adattandosi automaticamente alle variazioni di domanda. L'applicazione della Particle Swarm Optimization a problemi di sincronizzazione delle linee e di regolazione dinamica dei parametri macchina è stata ampiamente studiata sia in ambito accademico che industriale (Kennedy & Eberhart, 1995; Zhang et al., 2021). Diversi studi dimostrano che PSO è particolarmente efficace nei sistemi di produzione continua e nei processi ad alta variabilità, grazie alla capacità dell'algoritmo di adattarsi alle oscillazioni della domanda e ai cambiamenti dei flussi produttivi (Clerc, 2006; Marinakis et al., 2020). Questi metodi offrono una flessibilità operativa che si adatta perfettamente alla logica dell'Industria 4.0 e, oggi, dell'Industria 5.0, dove la personalizzazione, la sostenibilità e la velocità di adattamento sono obiettivi chiave. Il limite principale riguarda l'approssimazione delle soluzioni: le metaeuristiche non garantiscono l'ottimo matematico, ma una soluzione "sufficientemente buona" in tempi compatibili con le esigenze produttive. Tuttavia, nella pratica industriale, questa approssimazione è un compromesso accettabile, che consente di reagire all'imminente necessità di mantenere la continuità operativa anche in presenza di imprevisti. Un aspetto aggiuntivo di notevole importanza nel settore industriale concerne l'abilità delle euristiche e delle metaeuristiche di assicurare un grado di flessibilità operativa che risulta estremamente difficile da conseguire mediante i convenzionali metodi deterministici. Negli ambienti industriali contraddistinti da una considerevole fluttuazione delle richieste di mercato, da numerosi cambiamenti nei prodotti e dall'esigenza di minimizzare i tempi di preparazione, la velocità nel processo decisionale riveste un'importanza fondamentale e strategica per il successo aziendale. Gli algoritmi metaeuristici, grazie alla loro natura adattiva, permettono di ricalcolare soluzioni efficienti anche quando il sistema è soggetto a incertezze o a dati incompleti, offrendo prestazioni robuste in scenari complessi (Florescu et al., 2024). Integrati nel Digital Twin, essi contribuiscono alla creazione di una fabbrica adattiva, capace di

reagire velocemente alle variazioni operative grazie al continuo aggiornamento dei dati in tempo reale (Tao & Qi, 2018). Tale metodologia si dimostra specialmente vantaggiosa durante i periodi di avviamento e nei contesti con più prodotti, in cui la velocità di adeguamento vale più della perfezione matematica assoluta. Di conseguenza, le metaeuristiche costituiscono attualmente uno strumento essenziale nell'industrializzazione contemporanea, unendo efficienza di calcolo, flessibilità e abilità di risposta strategica.

Nel corso degli ultimi anni, l'importanza e la rilevanza delle metaeuristiche all'interno del panorama industriale hanno registrato un significativo incremento, principalmente grazie all'evoluzione e all'implementazione di metodologie ibride innovative, le quali integrano sapientemente algoritmi di natura evolutiva con modelli matematici rigorosi ed esatti. Queste sofisticate metodologie, comunemente denominate *matheuristics*, sfruttano efficacemente la notevole rapidità esplorativa caratteristica delle metaeuristiche per identificare e delimitare aree particolarmente promettenti all'interno dell'ampio spazio delle possibili soluzioni, mentre contemporaneamente i modelli di tipo deterministico si occupano di perfezionare e affinare la soluzione finale, assicurando una completa conformità con i molteplici vincoli operativi imposti dal sistema produttivo (Galli et al., 2021). Questa sofisticata integrazione metodologica consente di conseguire risultati caratterizzati da maggiore robustezza e affidabilità, preservando al contempo tempistiche computazionali pienamente compatibili con le esigenze della produzione industriale reale. Nell'ambito specifico di un Digital Twin, le *matheuristics* costituiscono una soluzione estremamente efficace, poiché permettono al sistema virtuale di navigare fluidamente tra approcci di ricerca euristica e tecniche di ottimizzazione esatta, offrendo così un equilibrio avanzato e sofisticato tra precisione analitica e flessibilità operativa.

Un ulteriore contributo di straordinaria rilevanza concerne la spiccata capacità delle metaeuristiche di affrontare e risolvere problematiche multi-obiettivo, particolarmente diffuse e frequenti nei moderni e complessi sistemi produttivi, dove risulta indispensabile bilanciare simultaneamente molteplici fattori critici quali l'efficienza operativa, la qualità del prodotto finale, i costi energetici complessivi e la sostenibilità ambientale del processo. Metodologie avanzate come NSGA-II o MO-PSO consentono di generare insiemi articolati di soluzioni ottimali (tecnicamente definite Pareto-efficienti), offrendo così al management aziendale un'ampia gamma di alternative strategiche tra cui selezionare in base alle specifiche priorità organizzative o agli scenari dettagliatamente simulati all'interno dell'ambiente del Digital Twin. Questo approccio metodologico risulta particolarmente vantaggioso e appropriato nelle situazioni in cui le soluzioni considerate "ottime" non possono essere univocamente determinate, ma dipendono necessariamente da complessi compromessi strategici, caratteristici delle realtà industriali evolute nell'ambito dell'Industria 4.0 e della nascente Industria 5.0.

Un aspetto frequentemente sottovalutato o addirittura trascurato riguarda l'eccezionale capacità delle metaeuristiche di garantire una solida robustezza decisionale anche in presenza di significativa variabilità e sostanziale incertezza nei parametri produttivi fondamentali. Diversamente dai modelli matematici esatti, che necessitano imprescindibilmente di dati completi, precisi e accurati, le metaeuristiche possono operare efficacemente anche in scenari complessi caratterizzati da informazioni parziali o incomplete, ritardi nell'acquisizione dei dati o variazioni improvvise e impreviste nei tempi di lavorazione. Questa preziosa caratteristica si rivela particolarmente vantaggiosa nei contesti produttivi basati su commessa o contraddistinti da elevata variabilità intrinseca, dove i parametri operativi non sono sempre preventivamente determinabili con precisione e il Digital Twin deve costantemente adattarsi a nuovi e mutevoli scenari operativi (Florescu et al., 2024). Tale flessibilità adattiva consente al gemello digitale di mantenere prestazioni costantemente elevate anche in situazioni critiche dove la struttura fondamentale del problema subisce rapide e significative modifiche, contribuendo così a rafforzare notevolmente la resilienza complessiva dell'intero sistema produttivo.

Aspetto	Sintesi
Obiettivo	Trovare soluzioni buone in tempi brevi per problemi complessi.
Punti di forza	Altissima flessibilità; gestiscono bene problemi non lineari o multi-vincolo.
Limiti	Non garantiscono l'ottimo; parametri da calibrare.
Quando usarle nel Digital Twin	Simulazioni iterative, scenari complessi, ottimizzazione rapida.
Requisiti	Funzione obiettivo chiara; risorse computazionali moderate.

2.2.3 Machine Learning: l'intelligenza adattiva della fabbrica digitale

Con la crescente disponibilità di dati provenienti da sensori, PLC e sistemi MES, il Machine Learning (ML) ha assunto un ruolo centrale nei processi di ottimizzazione. A differenza dei modelli matematici o delle metaeuristiche, il ML non cerca soluzioni basate su vincoli predefiniti, ma riconosce pattern nel grande afflusso di dati e fa previsioni per ottimizzare decisioni.

Nel contesto industriale, le reti neurali artificiali (ANN) vengono utilizzate per la manutenzione

predittiva, analizzando vibrazioni, temperature o consumi per anticipare guasti e ridurre i tempi di fermo. Le Support Vector Machines (SVM) e i modelli basati su Random Forest trovano impiego nel controllo qualità, individuando deviazioni anche minime dai parametri ottimali. Le Convolutional Neural Networks (CNN) vengono invece impiegate nei sistemi di visione artificiale per il riconoscimento automatico dei difetti, migliorando la qualità senza rallentare il ciclo produttivo.

Dal punto di vista dell'industrializzazione, il valore del Machine Learning sta nella capacità di rendere il sistema produttivo reattivo: non si interviene per risolvere un problema già accaduto, la fabbrica lo prevede e, quindi, lo previene. Tuttavia, questi algoritmi richiedono una grande quantità di dati di addestramento e un'infrastruttura digitale solida, capace di garantire la qualità e la coerenza delle informazioni raccolte (Touckia et al., 2023). Nonostante ciò, il ML rappresenta una delle tecnologie più promettenti per realizzare una fabbrica realmente intelligente, capace di apprendere e migliorare nel tempo.

La funzione del Machine Learning nell'ambito della fabbrica digitale si estende al di là delle mere capacità predittive: tale tecnologia implementa una tipologia di intelligenza adattiva che consente al sistema di produzione di acquisire conoscenza in modo continuo attraverso l'esperienza operativa. Integrato con il Digital Twin, il ML aggiorna costantemente i modelli in base ai dati operativi, trasformando la fabbrica in un ecosistema che anticipa le variabili critiche e ottimizza i parametri di processo in modo dinamico (Touckia et al., 2023). Questo approccio permette di conseguire molteplici benefici: da un lato, la significativa diminuzione di malfunzionamenti e materiali di scarto; dall'altro, un notevole incremento qualitativo e una maggiore efficienza operativa nei contesti produttivi caratterizzati da elevata variabilità. Va inoltre sottolineato come, grazie alle sofisticate capacità di identificazione e analisi dei modelli ricorrenti, la tecnologia di Machine Learning sia in grado di rilevare sottili anomalie e deviazioni minime che sfuggirebbero inevitabilmente ai sistemi di monitoraggio convenzionali. Questo aspetto risulta particolarmente prezioso nel supportare l'implementazione di un paradigma di fabbrica intelligente e cognitiva, perfettamente allineato con la visione e gli obiettivi strategici delineati nel contesto dell'Industria 5.0 (Fantozzi et al., 2025). La combinazione tra ML, IoT e Digital Twin rappresenta quindi uno dei principali motori dell'evoluzione verso sistemi produttivi adattivi, intelligenti e data-driven. Nel contesto del Digital Twin, il Machine Learning offre un contributo fondamentale nella modellazione di fenomeni produttivi complessi che sfuggono alle formule analitiche tradizionali. Nei contesti industriali, dove i processi mostrano non linearità e interazioni variabili, come evidenziato da Goodfellow et al. (2016), Bishop (2006) e Zhang et al. (2021), il Machine Learning supera queste limitazioni creando modelli che apprendono direttamente dai dati, migliorando la

rappresentazione di dinamiche complesse nei Digital Twin (Rasheed et al., 2020; Qi & Tao, 2018). Questa capacità risulta particolarmente vantaggiosa nei sistemi produttivi ibridi, dove l'interazione tra persone, macchine e materiali introduce variabilità difficilmente prevedibili con approcci convenzionali (Thramboulidis et al., 2020; Guo et al., 2023).

Un aspetto innovativo è l'uso del Machine Learning per stimare stati non direttamente osservabili ma essenziali per le decisioni operative (Rashid et al., 2022). Algoritmi come LSTM, Gaussian Processes e architetture Transformer vengono impiegati per valutare efficienza, usura e qualità delle materie prime, come mostrato da Guo et al. (2023), Sun et al. (2022) e Huang et al. (2023). Questi modelli aumentano la precisione predittiva del gemello digitale, fornendo scenari più accurati per la pianificazione produttiva (Leng et al., 2021; Zhuang et al., 2021).

Il Machine Learning è cruciale anche nel rilevamento di guasti e anomalie, dove il Digital Twin utilizza modelli per identificare deviazioni dal comportamento normale. Tecniche come clustering e autoencoder riconoscono anomalie prima che impattino sulla produzione (Zhao et al., 2019; Park et al., 2020). Questa capacità predittiva riduce i tempi di inattività e migliora la qualità del prodotto, come dimostrano le applicazioni di Siemens e General Electric (GE, 2018; Siemens, 2020).

Un elemento pratico importante è la gestione di dati incompleti o rumorosi. Secondo Thramboulidis et al. (2020) e Wuest et al. (2016), gli algoritmi ML ricostruiscono informazioni mancanti e filtrano il rumore, aumentando l'affidabilità dei dati e consentendo decisioni più robuste anche in contesti incerti (Müller et al., 2018; Bauer et al., 2021). Il Machine Learning è essenziale anche nell'ottimizzazione dinamica dei sistemi produttivi. Modelli come Random Forest e Deep Neural Networks apprendono le relazioni tra configurazioni e performance, permettendo valutazioni rapide di alternative (Qi & Tao, 2018; Gabor et al., 2020). Questi modelli, integrati in procedure di ottimizzazione, riducono significativamente i tempi decisionali (Krishnan et al., 2023; Sun et al., 2022), con studi che mostrano riduzioni fino al 30-40% (Leng et al., 2021; Zhuang et al., 2021).

Un altro campo emergente riguarda i modelli surrogati, che sostituiscono simulazioni complesse e costose. Nei Digital Twin industriali, il Machine Learning genera modelli che replicano accuratamente le risposte del sistema, riducendo i tempi da ore a millisecondi (Sun et al., 2022; Kapteyn et al., 2020), rendendo possibili numerose simulazioni "what-if" in tempi brevi (Rasheed et al., 2020; Leng et al., 2021). Infine, il Machine Learning consente la personalizzazione decisionale nei Digital Twin. Attraverso l'analisi continua dei dati, il modello digitale apprende le specificità dell'impianto reale, differenziandosi dai gemelli standardizzati (Minerva et al., 2022). Questo apprendimento contestuale, basato su tecniche di incremental

learning, permette al Digital Twin di adattarsi ai cambiamenti, migliorando previsioni e decisioni operative (Huang et al., 2023; Guo et al., 2023). In questo modo, il Machine Learning potenzia il gemello digitale come strumento di supporto decisionale in sistemi produttivi complessi e in evoluzione.

Aspetto	Sintesi
Obiettivo	Apprendere pattern e relazioni dai dati.
Punti di forza	Predizione accurata, adattamento ai cambiamenti, gestione dati massivi.
Limiti	Necessita di molti dati; opacità dei modelli complessi.
Quando usarlo nel Digital Twin	Previsioni, controllo qualità, rilevamento anomalie.
Requisiti	Grande quantità di dati storici e/o in streaming.

2.2.4 Reinforcement Learning: l'apprendimento autonomo dei sistemi produttivi

Il Reinforcement Learning (RL) rappresenta un'evoluzione ulteriore dell'apprendimento automatico. In sostanza, anziché utilizzare la massa di dati esistenti in azienda, l'algoritmo impara dall'interazione con l'ambiente, ottenendo una ricompensa per la decisione corretta e una "multa" per quella errata. Questo approccio è particolarmente efficace nei processi industriali complessi, dove le decisioni devono essere prese in sequenza e dove un errore può influenzare l'intero sistema (Qi & Tao, 2018).

In un ottima di Digital Twin, il RL si rileva molto utile per pianificare e rendere possibili processi in tempo reale, come la gestione dinamica delle risorse o il controllo dei robot collaborativi. In una linea di produzione flessibile, ad esempio, un agente di RL può imparare autonomamente come ridistribuire i compiti tra le macchine per ridurre i tempi di attesa e massimizzare l'efficienza complessiva. Il vantaggio di questo approccio è la capacità di apprendere in modo continuo, migliorando le proprie prestazioni con l'esperienza. Tuttavia, il RL richiede un numero elevato di simulazioni e una potenza di calcolo considerevole, motivo per cui viene spesso implementato all'interno del Digital Twin, che offre un ambiente virtuale sicuro per la sperimentazione.

Questo tipo di apprendimento gioca un ruolo fondamentale nella creazione di un'intelligenza

industriale autonoma, capace di prendere decisioni operative complesse senza l'intervento umano, pur rimanendo all'interno dei parametri di sicurezza, produttività e sostenibilità.

In aggiunta alle applicazioni convenzionali nell'ambito del controllo adattivo, il Reinforcement Learning sta acquisendo una rilevanza strategica crescente nella progettazione di sistemi produttivi fondati su meccanismi decisionali articolati. Il suo valore distintivo non è limitato all'ottimizzazione sequenziale delle operazioni, bensì risiede nella capacità di sviluppare politiche decisionali trasferibili, ovvero metodologie che mantengono la loro efficacia anche quando il contesto produttivo è soggetto a mutamenti imprevisti durante il periodo di formazione. In un ambiente industriale contraddistinto da prodotti customizzati, cicli vitali compressi e assetti impiantistici frequentemente riconfigurati, tale caratteristica consente una significativa riduzione dei tempi necessari alla riprogrammazione e un incremento della resilienza complessiva del sistema. Un apporto di notevole importanza del Reinforcement Learning si manifesta nei contesti di coordinamento multi-agente, in cui diverse entità — quali robot collaborativi, veicoli a guida automatica (AGV), sistemi di magazzinaggio automatizzati o macchinari a controllo numerico computerizzato (CNC) — necessitano di assumere decisioni in modo simultaneo. Le metodologie di apprendimento per rinforzo multi-agente (MARL) permettono l'acquisizione di comportamenti collaborativi e la diminuzione di congestioni, conflittualità nei percorsi e inefficienze nelle dinamiche logistiche. Integrando questi modelli nel Digital Twin, è possibile valutare virtualmente il comportamento collettivo degli agenti e accelerare la convergenza verso strategie ottimali, riducendo i rischi e i tempi di sperimentazione (Qi & Tao, 2018).

Un campo in crescita concerne anche la riconfigurazione automatica delle linee produttive. Nei sistemi modulari, in cui i macchinari possono essere spostati o riorganizzati per adattarsi a nuovi prodotti, il Reinforcement Learning è in grado di determinare autonomamente la configurazione più efficace riducendo strozzature, tempi di percorrenza o bisogno di buffer intermedi. Il Digital Twin serve come ambiente di test, permettendo la simulazione di numerosi scenari senza disturbare la produzione effettiva e abbassando i costi delle prove fisiche.

Un altro aspetto rilevante è l'utilizzo sempre più diffuso di modelli di reinforcement learning spiegabile, creati per offrire ai lavoratori chiarezza sui ragionamenti che guidano le decisioni del sistema. Tale caratteristica risulta essenziale in ambiti soggetti a normative o di elevata importanza, dato che permette l'impiego di algoritmi sofisticati mantenendo tracciabilità, verificabilità e controllo umano. La capacità di interpretare le decisioni algoritmiche agevola anche l'implementazione dell'intelligenza artificiale nei processi operativi e contribuisce alla preparazione del personale nelle fabbriche digitalizzate. Complessivamente, l'Apprendimento per Rinforzo estende le potenzialità del Gemello Digitale nel supportare sistemi di produzione

che non sono semplicemente reattivi, ma anche autonomi, resilienti e proattivi, capaci di assumere decisioni ottimali persino in circostanze impreviste e di svilupparsi temporalmente insieme all'ambiente operativo. Tale visione si allinea con il concetto di Industria 5.0, dove gli impianti non solo eseguono operazioni, ma acquisiscono conoscenze, interpretano dati e si perfezionano costantemente, partecipando così alla creazione di ecosistemi produttivi intelligenti e fortemente adattabili (Fantozzi et al., 2025).

Un elemento importante del Reinforcement Learning, largamente esaminato nella recente letteratura, concerne la sua abilità di gestire problemi decisionali in sequenza, dove gli effetti di un'azione condizionano direttamente i futuri stati del sistema (Sutton & Barto, 2018). Questo approccio dinamico fa del RL uno strumento particolarmente idoneo per sistemi produttivi complessi, dove le decisioni operative sono interconnesse nel tempo. Studiosi come Silver et al. (2017) e Buşoniu et al. (2010) sottolineano come le metodologie RL — in particolare le tecniche di deep reinforcement learning — possano apprendere strategie decisionali ottimali anche in contesti con forte non linearità, alta incertezza e ampi spazi di stato.

Nell'ambito dei Digital Twin industriali, il Reinforcement Learning è frequentemente applicato per l'ottimizzazione di parametri operativi in contesti dinamici, dove i modelli tradizionali non riescono a rappresentare completamente l'evoluzione temporale del sistema. Per esempio, Vamvoudakis & Lewis (2010) evidenziano che l'Adaptive Dynamic Programming (ADP), una versione avanzata di RL, può essere validamente utilizzata per problematiche di controllo industriale con dinamiche di processo parzialmente ignote. Analogamente, Zhang et al. (2021) illustrano la rilevanza del RL nel modellare la dipendenza temporale delle decisioni nelle linee di produzione, potenziando la capacità del Digital Twin di identificare strategie ottimali in tempo reale.

Diversi casi industriali attestano l'efficienza del RL anche in contesti pratici. Toyota ha adottato algoritmi di Deep Reinforcement Learning per migliorare i flussi logistici interni e la gestione degli AGV, conseguendo notevoli progressi nei tempi di percorrenza e nella diminuzione delle congestioni (Toyota Smart Factory Study, 2022). Honeywell applica il RL nei Digital Twin dei sistemi HVAC per ottimizzare il consumo energetico e il comfort termico, dimostrando che le strategie apprese possono superare i controllori convenzionali (Honeywell Applied Research, 2021). General Electric utilizza il RL per perfezionare il controllo adattivo delle turbine eoliche, aumentando l'efficienza aerodinamica in condizioni di vento mutevoli (GE Research, 2018). Anche nella letteratura accademica si riscontrano applicazioni coerenti. Liang et al. (2018) dimostrano come il RL possa amministrare sistemi produttivi multi-stazione con dinamiche stocastiche, mentre Pourbabaee et al. (2020) illustrano l'impiego del RL per l'ottimizzazione di processi energetici complessi. Vercammen et al. (2021) propongono un modello RL integrato

nel Digital Twin di una linea di assemblaggio automobilistica, evidenziando una diminuzione dei tempi di ciclo e un miglioramento del bilanciamento in scenari di domanda variabile. Infine, una significativa direzione di ricerca riguarda l'utilizzo del Reinforcement Learning nei Digital Twin come mezzo per creare esperienza virtuale, consentendo agli algoritmi di addestrarsi attraverso numerose simulazioni senza rischi per la produzione effettiva. Questo concetto, introdotto da Kaelbling, Littman & Moore (1996) e ripreso recentemente da Wang et al. (2022), è essenziale poiché permette di sviluppare strategie ottimali anche quando i dati reali sono scarsi o costosi da raccogliere. In ambito industriale, questo consente di sperimentare strategie per il bilanciamento delle linee, la gestione delle risorse o il controllo dei macchinari direttamente nel gemello digitale, assicurando un trasferimento più sicuro ed efficace nel sistema reale (Rasheed et al., 2020; Leng et al., 2021).

Complessivamente, la letteratura scientifica e industriale riconosce che il Reinforcement Learning rappresenta una delle tecniche emergenti più promettenti per l'integrazione nei Digital Twin, grazie alla sua capacità di apprendere iterativamente, adattarsi alle condizioni operative reali e generare continui miglioramenti nelle prestazioni del sistema produttivo.

Aspetto	Sintesi
Obiettivo	Apprendere strategie ottimali attraverso l'interazione con l'ambiente.
Punti di forza	Autonomia decisionale; ottimo per sistemi dinamici e sequenziali.
Limiti	Addestramento lungo e complesso; necessità di simulazione realistica.
Quando usarlo nel Digital Twin	Controllo adattivo, robotica, routing dinamico, sistemi multi-agente.
Requisiti	Ambiente simulato accurato (Digital Twin) per apprendimento sicuro.

L'analisi delle diverse famiglie algoritmiche mostra come ogni metodo contribuisca in modo distinto all'intelligenza del Digital Twin, offrendo strumenti complementari per la previsione, l'ottimizzazione e l'adattamento del sistema produttivo. Tuttavia, la presenza di numerose

tecniche rende necessario un confronto sistematico tra i diversi approcci, così da comprendere quali modelli risultino più adeguati in base alle caratteristiche operative del processo considerato. Per questa ragione, la sezione successiva propone una comparazione strutturata delle tecniche analizzate, evidenziandone punti di forza, limiti e potenziali applicazioni nel contesto industriale oggetto di studio (Zhuang et al., 2021; Leng et al., 2021).

2.3 Analisi comparativa

Nell'ambito della trasformazione digitale dei processi produttivi, l'implementazione di algoritmi sofisticati costituisce un elemento cruciale per realizzare pienamente il concetto di Digital Twin. Gli attuali sistemi di produzione, contraddistinti da operatività variabile, crescenti quantità di dati e interconnessione dei processi, necessitano di soluzioni algoritmiche in grado di analizzare, prevedere e migliorare in tempo reale il funzionamento dei sistemi fisici (Negri et al., 2017; Fuller et al., 2020). Come evidenziato da Boschert & Rosen (2016), l'aumentata complessità dei sistemi industriali rende inadeguato il solo affidamento all'esperienza umana o ai metodi analitici convenzionali: il Digital Twin si trasforma così in una piattaforma cognitiva che integra modelli matematici, tecniche di apprendimento automatico e metodologie avanzate di ottimizzazione. L'unione di queste tecnologie permette di comprendere fenomeni complessi, prevedere anomalie e facilitare decisioni operative accurate e contestuali.

La ricerca scientifica identifica quattro principali categorie di tecniche algoritmiche utilizzate nel Digital Twin: modelli matematici deterministici, metaeuristiche, algoritmi di machine learning e metodi di reinforcement learning (Cimino et al., 2019; Tao et al., 2018; Minerva et al., 2022). Questi gruppi soddisfano diverse esigenze, dalla precisa modellazione dei processi alla gestione autonoma di sistemi complessi, consentendo al Digital Twin di funzionare come strumento di previsione, ottimizzazione e supporto decisionale. Questa categorizzazione è stata ulteriormente esaminata da studiosi come Madni & Madni (2020), che dimostrano come ciascuna tipologia algoritmica risponda a specifiche esigenze aziendali, dalla pianificazione strategica al controllo operativo immediato.

Un aspetto comparativo essenziale riguarda i requisiti infrastrutturali. I modelli matematici, come la programmazione lineare e la Mixed-Integer Linear Programming (MILP), richiedono dati particolarmente raffinati, strutturati e rappresentativi della realtà fisica, risultando quindi efficaci in ambienti industriali altamente formalizzati (Bertsimas & Tsitsiklis, 1997; Chen et al., 2019). Secondo l'analisi di Mourtzis (2020), questi modelli necessitano anche di una precisa conoscenza dei vincoli tecnici, dei tempi di ciclo e delle relazioni tra fasi produttive, elementi che ne limitano l'applicabilità in sistemi molto variabili. Le metaeuristiche, invece, mostrano

maggiore adattabilità alle incertezze e ai dati imperfetti, essendo sviluppate per affrontare problematiche complesse e non lineari (Kennedy & Eberhart, 1995; Holland, 1975; Dorigo & Stützle, 2004). Questi metodi richiedono elevata potenza di calcolo ma non presuppongono modelli impeccabili, risultando adatti per contesti industriali caratterizzati da dinamiche variabili e obiettivi multipli in competizione (Florescu et al., 2024).

Gli algoritmi di machine learning richiedono volumi significativi di dati per generare modelli affidabili (Goodfellow et al., 2016; Zhang et al., 2021). Questo implica infrastrutture IoT avanzate, sistemi di data fusion e adeguati database storici. La revisione sistematica di Rasheed et al. (2020) sottolinea che l'introduzione del machine learning nel Digital Twin comporta un cambiamento da un approccio reattivo a uno predittivo, capace di identificare schemi nascosti nei dati e fornire previsioni precise sulle performance future. Il reinforcement learning, infine, necessita di ambienti simulativi estremamente realistici, dove l'agente può apprendere per tentativi senza rischiare danni al sistema reale (Sutton & Barto, 2018; Du et al., 2020). Questa caratteristica rende i Digital Twin una piattaforma fondamentale per l'applicazione del RL in ambito industriale, come evidenziato da ricerche recenti nei settori automobilistico e aerospaziale (Leng et al., 2021; Fantozzi et al., 2025).

Un secondo elemento di comparazione riguarda il grado di autonomia decisionale. I modelli matematici operano in modo prescrittivo: sono l'utente o il progettista del modello a definire vincoli, obiettivi e parametri (Negri et al., 2017). Le metaeuristiche introducono un livello più elevato di autonomia, poiché l'algoritmo esplora autonomamente lo spazio delle soluzioni e può generare configurazioni non previste esplicitamente dall'utente (Florescu et al., 2024). Il machine learning aggiunge ulteriori capacità cognitive, consentendo al Digital Twin di apprendere dai dati e migliorare progressivamente le proprie prestazioni predittive (Touckia et al., 2023; Rasheed et al., 2020). Il reinforcement learning rappresenta il vertice dell'autonomia decisionale: l'agente interagisce direttamente con il modello simulativo, apprende strategie ottimali nel tempo e adatta dinamicamente le proprie politiche in base ai cambiamenti dell'ambiente produttivo (Sutton & Barto, 2018; Qi & Tao, 2018). Tale progressione riflette il percorso verso il Digital Twin cognitivo, concetto già anticipato da Tao et al. (2018) e successivamente ampliato da Griva et al. (2021).

Un terzo criterio comparativo fondamentale riguarda la dimensione temporale delle decisioni. I modelli matematici operano efficacemente su orizzonti strategici o tattici, in cui le condizioni non variano rapidamente (Bertsimas & Tsitsiklis, 1997). Le metaeuristiche, pur necessitando di un tempo computazionale significativo, possono essere utilizzate in modalità ricorsiva per adattarsi ai cambiamenti gradualmente del sistema (Kennedy & Eberhart, 1995). Il machine learning integra dati storici e real-time, permettendo aggiornamenti costanti del modello predittivo

(Goodfellow et al., 2016). Il reinforcement learning, grazie alla sua natura sequenziale, è progettato per operare in ambienti altamente dinamici, nei quali ogni azione influenza lo stato futuro del sistema (Du et al., 2020; Madni & Madni, 2020). Questa distinzione è cruciale in contesti manifatturieri ad alta variabilità, come le linee di produzione riconfigurabili, dove la tempestività delle decisioni è determinante per evitare fermi macchina e inefficienze (Zhang et al., 2021).

La scalabilità costituisce indubbiamente un fattore distintivo fondamentale tra le diverse famiglie di algoritmi nel panorama computazionale contemporaneo. I modelli matematici tradizionali manifestano una progressiva perdita di efficienza man mano che le dimensioni del problema in esame aumentano, come ampiamente documentato nella letteratura scientifica (Chen et al., 2019). Le metaeuristiche, per contro, grazie alla loro intrinseca natura iterativa e alla possibilità di essere implementate in parallelo, dimostrano una notevole capacità di scalabilità anche quando si trovano ad affrontare problematiche particolarmente complesse e caratterizzate da numerosi vincoli (Dorigo & Stützle, 2004). L'efficienza del machine learning, d'altra parte, tende ad aumentare in modo direttamente proporzionale alla quantità di dati che vengono resi disponibili per l'addestramento (Goodfellow et al., 2016; Rasheed et al., 2020). Il reinforcement learning, particolarmente nella sua variante multi-agente, si rivela straordinariamente adatto all'implementazione in sistemi complessi e distribuiti, caratteristici delle moderne architetture dell'Industria 4.0 e della nascente Industria 5.0 (Leng et al., 2021; Minerva et al., 2022).

Particolarmente degno di attenzione risulta essere il confronto approfondito tra la programmazione lineare intera mista (MILP) e gli Algoritmi Genetici, un tema ampiamente investigato nell'ambito della pianificazione e del bilanciamento delle linee produttive (Galli et al., 2021; Florescu et al., 2024). Il MILP offre indubbiamente il vantaggio di garantire soluzioni matematicamente ottimali e completamente tracciabili, ma presenta significative limitazioni quando viene applicato in contesti caratterizzati da elevata dinamicità. Gli Algoritmi Genetici, sebbene non possano assicurare il raggiungimento dell'ottimalità assoluta, forniscono un grado di flessibilità e una capacità esplorativa decisamente superiori. Un approccio che integra entrambe le metodologie, comunemente denominato matheuristic, consente di combinare efficacemente i punti di forza di ciascun metodo, permettendo di ottenere soluzioni caratterizzate da maggiore robustezza e adattabilità alle variazioni delle condizioni operative (Dorigo & Stützle, 2004; Galli et al., 2021).

Un ulteriore confronto di notevole rilevanza concerne l'interrelazione tra Machine Learning e Reinforcement Learning nel contesto industriale avanzato. Il machine learning si dimostra particolarmente efficace per compiti di natura predittiva, quali la manutenzione preventiva e

l'identificazione tempestiva di anomalie nei processi produttivi (Touckia et al., 2023; Rasheed et al., 2020). Il reinforcement learning, d'altro canto, manifesta la sua superiorità nell'ambito delle decisioni sequenziali e adattive, come la gestione di robot collaborativi o l'ottimizzazione dinamica delle linee di produzione (Du et al., 2020; Fantozzi et al., 2025). L'integrazione sinergica di questi due approcci complementari consente la realizzazione di un Digital Twin dotato di capacità cognitive avanzate, in grado non solo di prevedere l'evoluzione dei sistemi, ma anche di ottimizzarne il funzionamento e di apprendere continuamente dall'esperienza accumulata (Qi & Tao, 2018; Tao et al., 2018).

Le più recenti evidenze scientifiche mettono chiaramente in luce come nessuna famiglia algoritmica possa essere considerata universalmente superiore alle altre in termini assoluti. Come efficacemente sottolineato da Zhang et al. (2021), la massima efficacia operativa si consegue attraverso un'intelligente ibridazione delle diverse tecniche disponibili, integrando armoniosamente modelli deterministici, approcci metaeuristici, tecniche di machine learning e metodologie di reinforcement learning all'interno di una piattaforma computazionale coerente e unificata. Questa visione olistica e sistemica rappresenta il nucleo fondamentale del Digital Twin di nuova generazione, elemento portante dell'emergente paradigma dell'Industria 5.0, caratterizzata dalla presenza di sistemi produttivi intrinsecamente intelligenti, autonomi e dotati di sofisticate capacità di apprendimento (Minerva et al., 2022; Fantozzi et al., 2025).

L'esame comparativo delle quattro categorie algoritmiche analizzate — modelli matematici, metaeuristiche, Machine Learning e Reinforcement Learning — dimostra come ogni metodologia offra vantaggi, svantaggi e necessità specifiche, risultando più o meno idonea in base alle specificità del processo produttivo. Vari studiosi sottolineano l'importanza di un confronto metodico, evidenziando come la selezione algoritmica condizioni l'efficacia decisionale nei sistemi complessi (Gendreau & Potvin, 2019; Leng et al., 2021; Zhuang et al., 2021; Mourtzis, 2020). Monostori (2018) afferma che un'analisi puramente teorica risulta insufficiente, poiché ciascuna metodologia va valutata considerando disponibilità dei dati, variabilità dei processi e livello di digitalizzazione dell'impianto.

I modelli matematici, quali LP e MILP, garantiscono ottimalità formale e rigore matematico (Dantzig, 1963; Nemhauser & Wolsey, 1988; Bertsimas & Tsitsiklis, 1997). Tuttavia, ricerche indicano che la loro efficienza si riduce notevolmente all'aumentare della complessità combinatoria e dei vincoli non lineari (Hooker, 2000; Chen et al., 2013). Jovanović et al. (2019) rilevano che la modellazione matematica pura è inadeguata in ambienti altamente variabili, come quelli agroalimentari o manifatturieri con significativo intervento umano. Analogamente, Ivanov & Dolgui (2020) evidenziano che, in contesti incerti o stocastici, l'utilizzo esclusivo di modelli LP/MILP può generare soluzioni subottimali o industrialmente inapplicabili.

Le metaeuristiche, invece, mostrano notevole adattabilità anche in condizioni operative complesse. Come rilevato da Talbi (2009), Blum & Roli (2003) e Gendreau & Potvin (2019), approcci come GA, PSO, SA o ACO permettono di gestire problematiche complesse esplorando efficientemente ampi spazi di ricerca, senza necessitare modelli completamente lineari o deterministici. Ricerche applicative, come quelle di Marinakis et al. (2020) e Abdellaoui et al. (2022), confermano l'efficacia delle metaeuristiche per scenari multi-obiettivo, processi variabili e vincoli poco strutturati. Diversi studiosi ricordano però che questi algoritmi non assicurano l'ottimo globale e dipendono dalla parametrizzazione (Talbi, 2009; Luke, 2013; Kramer, 2017). Ciononostante, applicazioni concrete come Airbus (2020), Siemens (2021) e BMW (2021) dimostrano che le metaeuristiche spesso superano i modelli matematici nei problemi industriali reali, dove la robustezza prevale sulla perfezione formale.

Il Machine Learning propone un'impostazione radicalmente diversa, basata sulla capacità dei modelli di apprendere correlazioni complesse direttamente dai dati (Goodfellow et al., 2016; Bishop, 2006; Rasheed et al., 2020). Studiosi come Qi & Tao (2018) e Huang et al. (2023) sottolineano che il ML è particolarmente vantaggioso in contesti dinamici, dove le correlazioni non sono definibili analiticamente o mutano nel tempo. Varie ricerche evidenziano però i suoi limiti: dipendenza dalla qualità dei dati, rischio di overfitting, scarsa interpretabilità e difficoltà di generalizzazione in ambienti nuovi (Wuest et al., 2016; Müller et al., 2018; Guo et al., 2023). Nonostante queste criticità, casi reali come Bosch (2021), Nestlé (2022) e Procter & Gamble (2023) mostrano che l'integrazione ML-Digital Twin consente significativi miglioramenti nella previsione guasti, controllo qualità e stabilità operativa.

Il Reinforcement Learning rappresenta l'approccio più innovativo e promettente, consentendo l'apprendimento di strategie decisionali ottimali mediante interazione continua con l'ambiente (Sutton & Barto, 2018; Silver et al., 2017). Numerose ricerche evidenziano la capacità del RL di gestire problematiche sequenziali complesse, dove l'esito di un'azione influenza la decisione successiva (Buşoniu et al., 2010; Vamvoudakis & Lewis, 2010; Kaelbling et al., 1996). Il RL presenta tuttavia limitazioni rilevanti: elevato costo computazionale, sensibilità alla qualità del modello simulato e rischio di politiche instabili (Liang et al., 2018; Wang et al., 2022). Ciononostante, applicazioni industriali concrete — Toyota (2022), Honeywell (2021), GE (2018), Schneider Electric (2023) — dimostrano che il RL è particolarmente efficace per logistica interna, regolazioni dinamiche, controllo energetico e ottimizzazione dei processi complessi.

Il confronto tra le famiglie algoritmiche evidenzia diversi compromessi critici, già identificati da Leng et al. (2021), Mourtzis (2020) e Rasheed et al. (2020):

- ottimalità → modelli matematici (Dantzig, 1963)
- flessibilità → metaeuristiche (Talbi, 2009)
- precisione data-driven → Machine Learning (Qi & Tao, 2018)
- adattività dinamica → Reinforcement Learning (Sutton & Barto, 2018)
- interpretabilità vs complessità (Hooker, 2000; Müller et al., 2018)

Considerando queste evidenze, appare chiaro che nessun metodo costituisce la soluzione universalmente

migliore, come sottolineano Gibbons et al. (2022) e Zhuang et al. (2021). L'approccio più efficace risulta quindi ibrido, combinando modelli matematici per problemi strutturati, metaeuristiche per scenari complessi, ML per previsione di pattern non lineari e RL per decisioni sequenziali e adattive (Sun et al., 2022; Rasheed et al., 2020). Questa visione di "algorithmic fusion" costituisce il fondamento per identificare l'algoritmo — o la combinazione di algoritmi — più adatti al caso aziendale esaminato in questo tirocinio.

Famiglia di algoritmi	Principio di funzionamento	Vantaggi principali	Limiti principali	Contesto di applicazione industriale	Fonti principali
Modelli matematici (LP, MILP, CP)	Formulazione di equazioni e vincoli deterministici per massimizzare o minimizzare una funzione obiettivo.	Soluzioni ottimali e verificabili; forte interpretabilità dei risultati.	Scarsa flessibilità in contesti dinamici; elevata sensibilità ai dati di input.	Pianificazione della produzione, ottimizzazione del layout, gestione delle risorse.	Negri et al. (2017); Tao & Qi (2018)
Euristiche e Metaeuristiche (GA, PSO, ACO)	Ricerca iterativa di soluzioni attraverso principi evolutivi o naturali.	Rapidità di calcolo, adattabilità, buone prestazioni in sistemi complessi.	Soluzioni approssimate; dipendenza dai parametri iniziali.	Scheduling, bilanciamento di linea, configurazione e di layout, riduzione dei tempi di set-up.	Florescu et al. (2024)
Machine Learning (ANN, SVM, CNN, LSTM)	Apprendimento da dati storici e operativi per la previsione e il riconoscimento di pattern.	Capacità predittiva e adattiva; miglioramento continuo delle performance.	Necessità di grandi quantità di dati e addestramento accurato.	Manutenzione predittiva, controllo qualità, previsione della domanda, analisi energetica.	Touckia et al. (2023)
Reinforcement Learning (Q-Learning, DQN, PPO)	Apprendimento per interazione con l'ambiente, basato su	Apprendimento autonomo e continuo; gestione di	Complessità computazionale e elevata; necessità di	Pianificazione dinamica, controllo adattivo,	Qi & Tao (2018)

	ricompense e decisioni penalità.	sequenziali.	simulazioni numerose.	ottimizzazione di robot e AGV.	
Anomaly Detection (Autoencoder, Isolation Forest)	Riconosciment o di deviazioni dai pattern normali tramite ricostruzione o isolamento.	Prevenzione dei guasti e miglioramento della stabilità di processo.	Possibili falsi positivi e necessità di aggiornamento dei modelli.	Monitoraggio e predittivo, manutenzione, sicurezza di processo.	Fantozzi et al. (2025)

Il confronto tra famiglie di algoritmi mostra che, nel campo dei Digital Twin, non è la tecnica individuale a determinare l'efficacia del sistema, ma la sua capacità di affrontare le varie complessità degli ambienti produttivi contemporanei. Numerose ricerche indicano che il valore degli algoritmi sta nella loro complementarità piuttosto che nelle singole performance (Boschert & Rosen, 2020; Wagg et al., 2020; Tao & Zhang, 2022). Questa visione è supportata dal fatto che i Digital Twin funzionano su sistemi con molteplici variabili, caratterizzati da variabilità operativa, dinamiche non lineari, interferenze, molteplici vincoli e obiettivi spesso in conflitto (Uhlemann et al., 2022; Madni et al., 2021).

I modelli matematici restano essenziali nei contesti dove prevedibilità e trasparenza dei risultati sono requisiti fondamentali, come nei settori regolamentati o nelle prime fasi di pianificazione strategica. Tuttavia, vari studiosi notano che, a causa dell'esplosione combinatoria, questi modelli diventano meno efficienti in sistemi molto estesi o soggetti a frequenti cambiamenti (Koumas et al., 2021; Khatami et al., 2022; Singh et al., 2023). In tali situazioni emergono approcci più flessibili, come le metaeuristiche, che grazie alla loro natura iterativa permettono di esplorare vasti spazi decisionali offrendo soluzioni valide anche in presenza di rumore, vincoli non lineari e strutture complesse (Rasheed et al., 2020; Florescu et al., 2024; Gabor et al., 2020).

Il Machine Learning introduce una dimensione analitica completamente nuova, permettendo al Digital Twin di acquisire rappresentazioni interne non ricavabili attraverso modelli analitici tradizionali. Molte ricerche evidenziano come la previsione di comportamenti complessi — quali derive nei processi, deterioramento dei componenti o interazioni non lineari tra variabili — sia attualmente realizzabile solo mediante tecniche di apprendimento automatico (Zhang et al., 2021; Minerva et al., 2022; Dalla Vedova et al., 2022). Tuttavia, il ML dipende fortemente dalla qualità dei dati: dataset incompleti o non rappresentativi possono compromettere le

capacità predittive, come ampiamente discusso da Fuller et al. (2020) e Qi et al. (2021). Ciò ne limita l'utilizzo autonomo nelle aziende agli inizi della digitalizzazione.

Il Reinforcement Learning, d'altra parte, offre una prospettiva dinamica al processo decisionale. Secondo Gao et al. (2022) e Wang et al. (2023), la capacità degli agenti RL di apprendere strategie ottimali attraverso simulazioni iterative è particolarmente importante nei sistemi complessi dove le decisioni influenzano gli stati futuri del sistema. Tuttavia, come sottolineato da Rahman et al. (2022), la stabilità dell'apprendimento dipende fortemente dalla qualità del modello simulativo: un Digital Twin non sufficientemente preciso può indurre l'agente RL ad apprendere strategie subottimali. Per questo, il RL risulta particolarmente efficace quando abbinato a Digital Twin ad alta fedeltà, condizione oggi possibile grazie ai progressi nella simulazione fisica, nel cloud computing e nei modelli meshless ad alte prestazioni (Maffei et al., 2023; Huang et al., 2024).

Un elemento che emerge costantemente dalla letteratura è il crescente interesse verso approcci ibridi. I contributi di Galli et al. (2021), Tao et al. (2019) e Krishnan et al. (2023) dimostrano come l'integrazione di modelli deterministici, metaeuristiche e algoritmi di apprendimento automatico permetta di superare i limiti delle singole tecniche e ottenere risultati nettamente superiori. Ad esempio, i modelli MILP possono essere utilizzati per definire una soluzione iniziale rigorosa successivamente perfezionata con metaeuristiche; oppure i modelli ML possono migliorare la funzione di valutazione di un algoritmo genetico accelerandone la convergenza (Minucci et al., 2023). Non stupisce quindi che numerosi framework industriali avanzati adottino pipeline miste, dove diversi algoritmi collaborano in modo coordinato (Ivanov & Dolgui, 2021; Longo et al., 2022).

Un aspetto comparativo di notevole rilevanza concerne la "governance algoritmica", che rappresenta l'effettiva capacità delle organizzazioni aziendali di amministrare e interpretare correttamente il funzionamento degli algoritmi implementati. I modelli caratterizzati da elevata spiegabilità e verificabilità — quali ad esempio i sistemi MILP o le analisi di regressione — si rivelano particolarmente vantaggiosi in quegli ambienti operativi dove la trasparenza costituisce un requisito fondamentale e imprescindibile (Del Giudice et al., 2021). Di contro, gli algoritmi contraddistinti da maggiore opacità intrinseca, come le sofisticate reti neurali profonde o i complessi agenti di Reinforcement Learning, necessitano inevitabilmente di strumenti interpretativi supplementari, argomento questo che sta ricevendo crescente attenzione sia nell'ambito della letteratura scientifica dedicata all'explainability dell'Intelligenza Artificiale, sia nelle concrete applicazioni del settore industriale (Bai et al., 2023; Venkatasubramanian, 2019). Tale dimensione etico-operativa sta progressivamente assumendo un ruolo centrale nelle valutazioni comparative tra diverse soluzioni algoritmiche, particolarmente nel contesto attuale

in cui le imprese incorporano sempre più frequentemente algoritmi avanzati nei loro processi decisionali quotidiani.

Considerando l'insieme dei risultati emersi dall'analisi approfondita, appare evidente come nessuna specifica famiglia algoritmica possa essere legittimamente considerata come la soluzione "ottimale" in termini assoluti: ciascuna tecnologia presenta infatti peculiari punti di forza e specifiche limitazioni che si manifestano in maniera differenziata in relazione al particolare contesto produttivo, alla qualità effettiva dei dati disponibili e al grado di maturità digitale raggiunto dall'organizzazione aziendale. Proprio in virtù di questa complessità, come opportunamente evidenziato nelle ricerche di Wagg et al. (2020) e Zhang et al. (2023), l'efficacia concreta di un Digital Twin deriva sostanzialmente dalla capacità di integrare armoniosamente molteplici algoritmi all'interno di un'unica piattaforma cognitiva integrata, dove modelli deterministici, ottimizzatori di natura evolutiva, tecniche predittive avanzate e agenti autonomi collaborano sinergicamente per fornire al sistema una rappresentazione completa, dinamica e adattiva dell'intero processo produttivo.

Questa visione integrata e multidimensionale costituisce il fondamentale punto di partenza per il capitolo successivo della trattazione, nel quale le differenze significative emerse durante l'analisi comparativa verranno metodicamente tradotte in criteri operativi concreti, finalizzati alla selezione delle tecniche maggiormente appropriate per l'ottimizzazione efficace di una linea produttiva reale, nell'ambito specifico di un Digital Twin applicato a un caso industriale ben definito e contestualizzato.

3.0 – Caratteristiche del contesto produttivo simulato

Il sistema produttivo analizzato comprende diverse linee di lavorazione e confezionamento che operano in parallelo, ciascuna con specifici livelli di capacità produttiva, costi operativi e fabbisogni di manodopera. In contesti reali, questi parametri variano in base alla configurazione operativa adottata, in particolare al numero di operatori assegnati e al grado di utilizzo delle risorse. Ciò crea una relazione diretta tra le variabili decisionali e le prestazioni del sistema (Hwang et al., 2018; Pastor & Corominas, 2010; Boysen et al., 2007; Becker & Scholl, 2006).

Il problema decisionale si sviluppa su un orizzonte temporale discretizzato, in cui la domanda

deve essere soddisfatta rispettando i vincoli di capacità e disponibilità delle risorse. In ogni intervallo temporale, occorre definire la configurazione delle linee attive e l'allocazione degli operatori, considerando che ogni linea richiede un numero minimo e massimo di addetti. Questi vincoli discreti, insieme alla limitata disponibilità di forza lavoro, collocano il problema nell'ambito dell'allocazione delle risorse e del bilanciamento delle linee produttive, temi ampiamente trattati nella letteratura sull'assembly line balancing e sulla pianificazione operativa (Becker & Scholl, 2006; Boysen et al., 2007; Pastor & Corominas, 2010; Pinedo, 2016).

Un aspetto critico del sistema è la non uniformità delle linee produttive. Ogni linea ha caratteristiche specifiche di costo operativo e capacità, quindi l'attivazione di una linea non è equivalente a quella di un'altra. La selezione delle linee da attivare deve quindi considerare il bilanciamento tra costo e produttività, come evidenziato nei modelli di pianificazione della produzione e nei problemi di allocazione ottimale delle risorse (Chen et al., 2013; Jans & Degraeve, 2007; Pinedo, 2016).

La variabilità oraria della domanda introduce una dimensione dinamica che richiede una continua riconfigurazione del sistema produttivo. In queste condizioni, una configurazione ottimale in un intervallo temporale può non essere efficiente in quello successivo, rendendo necessario un approccio decisionale flessibile e rapido nell'adattarsi ai cambiamenti del carico produttivo. Questa esigenza è tipica dei problemi di scheduling e pianificazione dinamica della produzione, dove le decisioni devono considerare simultaneamente vincoli temporali, capacità e disponibilità delle risorse (Pinedo, 2016; Gendreau & Potvin, 2019; Becker & Scholl, 2006).

Formalmente, il problema si configura come un'ottimizzazione combinatoria in cui le variabili decisionali riguardano l'attivazione delle linee e l'assegnazione degli operatori, mentre i vincoli includono capacità produttiva, disponibilità di risorse e soddisfacimento della domanda. L'obiettivo è minimizzare i costi operativi complessivi, in linea con i modelli classici di programmazione lineare e intera utilizzati nella pianificazione della produzione (Dantzig, 1963; Nemhauser & Wolsey, 1988; Chen et al., 2013; Pinedo, 2016).

La presenza di variabili discrete, vincoli multipli e relazioni tra configurazione e produttività causa una crescita esponenziale dello spazio delle soluzioni, rendendo il problema difficile da gestire con valutazioni manuali o approcci non strutturati. Come evidenziato dalla letteratura sull'ottimizzazione combinatoria e sullo scheduling, questi problemi richiedono metodi capaci di esplorare efficacemente molte configurazioni alternative, mantenendo elevata la qualità delle soluzioni (Gendreau & Potvin, 2019; Talbi, 2009; Luke, 2013; Florescu et al., 2024).

In questo contesto, l'uso di modelli quantitativi supera i limiti delle decisioni basate solo sull'esperienza, permettendo di individuare configurazioni più efficienti e coerenti con i vincoli del sistema. L'applicazione di approcci di ottimizzazione consente di valutare sistematicamente

le diverse combinazioni di attivazione delle linee e allocazione delle risorse, migliorando la qualità delle decisioni e riducendo il rischio di soluzioni subottimali (Pinedo, 2016; Jans & Degraeve, 2007; Gendreau & Potvin, 2019).

Alla luce di queste caratteristiche, il caso di studio viene utilizzato come base per applicare operativamente i modelli e gli approcci algoritmici analizzati nel capitolo precedente. L'obiettivo di questo paragrafo è valutare, in un contesto reale, la capacità di tali metodi di gestire un problema di configurazione delle linee produttive con vincoli multipli, variabilità della domanda e risorse limitate, con particolare attenzione alla qualità delle soluzioni ottenute e alla loro applicabilità operativa (Gendreau & Potvin, 2019; Talbi, 2009; Florescu et al., 2024; Gibbons et al., 2022).

3.1 – Collegamento tra architettura del Digital Twin e caso di studio fittizio

Allo stesso tempo, la principale rilevanza del caso di studio fittizio non è solo la possibilità di sperimentare diverse famiglie di algoritmi, ma la dimostrazione diretta del funzionamento di un Digital Twin in quanto piattaforma sperimentale. Benché l'impiantistica in esame non esista fisicamente, il caso è stato elaborato secondo gli stessi principi di un vero e proprio gemello digitale: una raccolta di dati coerente; una modellazione ben controllata; la simulazione di scenari alternativi e un sistema decisionale che interpreti i risultati (Tao & Qi, 2019; Boschert & Rosen, 2016).

Il caso si colloca pienamente nell'ambito delle ricerche accademiche in cui il Digital Twin è utilizzato come ambiente controllato, fornendo un banco di prova rigoroso per le tecniche di ottimizzazione e apprendimento prima dell'applicazione industriale (Cimino et al., 2019; Negri et al., 2017).

Nel nostro caso, la relazione tra Digital Twin e simulazione non risiede in un'architettura dettagliata – come già illustrato nel capitolo precedente – bensì nella possibilità di far interagire dati, modelli e algoritmi secondo le logiche di un gemello digitale operativo (Kapteyn et al., 2020). Questa dinamica emerge in tre aspetti principali.

Il primo aspetto riguarda la raccolta e gestione dei dati. Nel caso fittizio, i dati su linee, capacità, costi e disponibilità del personale sono generati artificialmente, ma funzionano esattamente allo stesso modo delle informazioni provenienti da sensori, sistemi informativi o inserimenti manuali in un vero impianto (Leng et al., 2022; Kritzinger et al., 2018). La loro stabilità e coerenza implicano che siano integrabili con vari algoritmi senza alterare la struttura dell'informazione di

fondo.

Il secondo elemento consiste nella capacità del caso simulato di comportarsi come un modello dinamico, pur non essendo collegato a un impianto reale. Il sistema risponde alle variazioni della domanda o della manodopera, genera configurazioni, modifica il comportamento sulla base degli input e permette di ripetere esperimenti variando un solo parametro. Questo è l'approccio corretto all'utilizzo di un Digital Twin nelle fasi di progettazione o test: la sincronia in tempo reale non è l'obiettivo, ma l'esplorazione controllata e iterativa delle alternative possibili (Boje et al., 2020; Jones et al., 2020).

Un terzo elemento è costituito dalla possibilità di applicare differenti motori decisionali allo stesso modello, come avviene nei Digital Twin più avanzati. Nel caso di studio, questa caratteristica è applicata concretamente: ogni famiglia algoritmica “osserva” lo stesso sistema, utilizza gli stessi parametri e interpreta il problema secondo la propria logica interna. Ciò permette non solo un confronto metodologicamente corretto, ma anche una visione integrata dell'intero processo decisionale (Rasheed et al., 2019).

La spiegazione più importante risiede nel fatto che il Digital Twin rende confrontabili algoritmi tra loro molto diversi. Senza il Digital Twin fittizio, gli algoritmi opererebbero in contesti eterogenei, producendo risultati non comparabili. Invece, grazie all'identica struttura del caso simulato, MILP, metaeuristiche, ML e RL operano nello stesso spazio decisionale, e le differenze nei risultati dipendono esclusivamente dal metodo utilizzato e non dalle condizioni iniziali (Tao et al., 2018; Mourtzis, 2021).

Questo è un elemento coerente con i modelli sperimentali più recenti, che impiegano il Digital Twin come laboratorio sperimentale per verificare l'efficacia di algoritmi eterogenei (Zhuang et al., 2021).

In ultima analisi, il caso fittizio dimostra concretamente come un Digital Twin possa essere utilizzato non solo per esaminare un sistema, ma anche per stabilire quale algoritmo funzioni meglio in diverse situazioni produttive. Come sottolineano Kapteyn et al. (2020), “una delle direzioni emergenti dei Digital Twin intelligenti consiste proprio nella loro capacità di supportare il confronto tra approcci decisionali diversi”, dove il target non è più solo simulare il comportamento fisico, ma anche scegliere l'approccio decisionale migliore per ciascun caso.

La struttura digitale del caso simulato fornisce quindi il contesto ideale per introdurre i paragrafi successivi, nei quali ciascuna famiglia algoritmica viene analizzata dettagliatamente. Il Digital Twin agisce come un framework condiviso: il MILP modella e interpreta il sistema da una prospettiva deterministica; le metaeuristiche esplorano configurazioni alternative non immediatamente evidenti; il Machine Learning individua pattern produttivi; il Reinforcement Learning sviluppa strategie adattive.

A seguito della connessione illustrata in questo paragrafo, è possibile esaminare gli approcci decisionali uno alla volta, sapendo che tutti si basano sulla stessa struttura digitale e sulle medesime condizioni operative. Questa coerenza metodologica garantisce che il confronto finale del capitolo possa essere interpretato in modo rigoroso, trasparente e comparabile.

Elemento del DT nel caso simulato	Funzione specifica nel caso fittizio	Perché è rilevante per gli algoritmi	Letteratura di riferimento
Struttura unificata dei dati	Permette di rappresentare in modo coerente capacità delle linee, vincoli di manodopera, domanda variabile.	Garantisce che tutti gli algoritmi operino sulle stesse informazioni, rendendo il confronto metodologicamente corretto.	Rasheed et al. (2019); Negri et al. (2017)
Modello computazionale del sistema	Riproduce gli effetti combinati di linee manuali/automatiche, variabilità operativa e vincoli stringenti.	Gli algoritmi possono valutare configurazioni alternative senza modificare la struttura del modello.	Kapteyn et al. (2020); Qi & Tao (2018)
Possibilità di simulare scenari multipli	Permette di variare domanda, operatori e costi per osservare reazioni diverse del sistema.	ML e RL necessitano di molti scenari simulati per apprendere relazioni e strategie.	Cimino et al. (2019); Leng et al. (2022)
Ambiente sperimentale controllato	Il caso permette di isolare l'effetto dell'algoritmo evitando rumore, incertezze o errori del mondo reale.	Essenziale per confrontare MILP, metaeuristiche, ML, RL in modo uniforme.	Boje et al. (2020); Zhuang et al. (2021)
Coerenza tra vincoli e spazio delle decisioni	Tutte le famiglie algoritmiche interagiscono con lo stesso spazio decisionale, senza ricostruzioni diverse.	Evita bias nei risultati e consente un'analisi comparativa imparziale.	Tao & Qi (2019); Mourtzis (2021)
Generazione di	Il modello produce dati	Senza dati sufficienti, ML	Wuest et al.

dati artificiali	sintetici necessari per addestrare modelli predittivi o agenti RL.	e RL non potrebbero essere applicati.	(2016); Huang et al. (2023)
Interpretazione integrata degli output	Le soluzioni ottenute (configurazioni, costi, saturazioni) sono lette come parti di un'unica visione digitale.	Facilita il confronto tra diverse logiche decisionali e prepara la discussione algoritmica.	Tao et al. (2019); Gabor et al. (2020)

La tabella sintetizza i collegamenti tra la struttura del Digital Twin e il caso di studio fittizio, mostrando come questo ambiente simulato permetta di confrontare algoritmi differenti in condizioni operative omogenee. Non si intende illustrare teoricamente l'architettura del Twin, già esaminata precedentemente, ma piuttosto evidenziare come diventi uno strumento pratico per la sperimentazione algoritmica.

Ciascun elemento elencato contribuisce a creare un contesto decisionale stabile, chiaro e monitorato dove MILP, metaeuristiche, modelli di Machine Learning e Reinforcement Learning possono funzionare senza distorsioni informative. Ciò assicura che le differenze nei risultati ottenuti derivino esclusivamente dalle logiche intrinseche dei vari approcci algoritmici, non da variazioni nei modelli o nei dati.

Un altro punto importante riguarda la capacità di creare molteplici scenari e dati sintetici, aspetto particolarmente significativo per le metodologie data-driven. Il Digital Twin fittizio si trasforma così in una piattaforma sperimentale che supporta non solo la simulazione ma anche l'apprendimento, facilitando l'implementazione di tecniche che necessitano di volumi consistenti di dati o numerose iterazioni decisionali.

La tabella non è quindi meramente descrittiva, ma preparatoria: riassume gli elementi essenziali per capire perché nelle sezioni successive sia possibile esaminare individualmente MILP, metaeuristiche, Machine Learning e Reinforcement Learning, mantenendo una coerenza metodologica generale e un confronto imparziale tra i diversi metodi.

3.1.1 – Applicazione del modello MILP al caso di studio fittizio

L'adozione di un modello di programmazione lineare intera mista è il primo passo dell'analisi algoritmica del caso simulato. Esso consente di ottenere una configurazione ottimale delle risorse sulla base dei parametri tecnico-economici formalizzati in precedenza. L'approccio MILP rispecchia l'impostazione di gran parte della letteratura dedicata alla pianificazione

produttiva e all'ottimizzazione delle linee, in cui le decisioni operative sono definite da variabili miste e vincoli lineari che rispecchiano la struttura logica del sistema (Pochet & Wolsey, 2006; Pinedo, 2016).

In tale quadro, il modello MILP fa da tool deterministico per individuare, dal pool di tutte le linee disponibili e da tutti gli operatori assegnabili, quella che riduce il costo totale della pianificazione cioè quella che risponde alla domanda simulata riducendo al minimo la produzione totale richiesta (Conforti et al., 2014).

Nel caso in parola, il MILP è usato per determinare quali delle quattro linee di confezionamento attivare e a che percentuale di saturazione, con la condizione contrattuale di assicurare che l'allocazione del personale rispetti rigorosamente i limiti di disponibilità stabiliti per ogni singolo turno lavorativo. Diversamente da quanto accade nei sistemi operativi reali, dove l'innata variabilità dei processi produttivi rende impossibile ottenere una modellazione totalmente sotto controllo, l'ambiente simulato permette una precisa definizione di tutte le condizioni operative. Questo consente al MILP di fornire soluzioni assolutamente deterministiche e riproducibili. Tale caratteristica rappresenta infatti uno degli aspetti più citati negli studi che impiegano modelli esatti per analizzare le performance di sistemi manifatturieri (Chen et al., 2013; Boysen et al., 2007).

Poiché la struttura del MILP applicata al caso simulato è costituita da una variabile binaria per l'attivazione di ogni linea, una variabile intera per il numero di operatori assegnati e una variabile continua per la quantità prodotta, un tale modello include variabili di diversa natura. Questa struttura riflette accuratamente l'eterogeneità del sistema produttivo, in quanto tutte le decisioni vengono prese simultaneamente rispetto alla disponibilità delle linee, alla forza lavoro impegnata e ai livelli di produzione. I vincoli rappresentano relazioni logiche e tecniche: l'attivazione di una linea necessita di un numero minimo di operatori, la produzione di ciascuna linea non può superare la sua capacità oraria e il totale delle quantità prodotte dovrebbe soddisfare la domanda simulata. Una struttura simile è ben documentata nella letteratura sui problemi di configurazione delle linee, allocazione del personale e ottimizzazione della capacità in generale (Becker & Scholl, 2006; Melo et al., 2006; Gurevsky et al., 2013).

L'applicazione del MILP al caso simulato dimostra che è in grado di identificare rapidamente le configurazioni ottimali in situazioni con un numero relativamente limitato di variabili e vincoli.

Nello specifico, il sistema utilizza come fattore decisivo la limitazione relativa alla disponibilità del personale operativo, riuscendo così a identificare configurazioni inaspettate e non immediatamente evidenti di linee che possono essere messe in funzione. Come dimostrato in letteratura (Pochet & Wolsey, 2006; Conforti et al., 2014), i MILP sono ideali quando il numero di alternative è limitato e la struttura del problema ha vincoli lineari. Per il modello simulato, ciò

significa trovare rapidamente soluzioni che riducono il costo operativo usando linee automatizzate quando gli operatori sono insufficienti, oppure linee manuali quando il costo rappresenta il vincolo principale.

Tuttavia, l'applicazione del MILP mostra alcune limitazioni strutturali quando il modello è esteso a scenari a maggiore variabilità. Benché il MILP garantisca soluzioni direttamente ottime, la sua scalabilità diventa critica quando il numero di combinazioni tra operatori, linee o turni cresce in modo rilevante; questo aspetto è già stato discusso nella letteratura relativa al comportamento asintotico dei modelli esatti (Bertsimas & Tsitsiklis, 1997; Wolsey, 1998). Nel caso simulato, il MILP rimane esattamente gestibile; tuttavia, anche con piccole variazioni della domanda e della disponibilità di operatori, si osservano cambiamenti significativi nello spazio delle soluzioni. Questo indica che, nelle situazioni contraddistinte da notevole instabilità o incertezza, potrebbe risultare vantaggioso implementare strategie alternative e integrative quali le tecniche metaeuristiche oppure le metodologie che combinano diversi approcci (Talbi, 2009; Gendreau & Potvin, 2019). In contesti dove predominano l'imprevedibilità e la fluttuazione dei parametri, l'adozione di soluzioni complementari rappresenta una scelta potenzialmente efficace per affrontare la complessità intrinseca di tali ambienti decisionali.

Complessivamente, il MILP offre una rappresentazione solida e trasparente delle dinamiche del caso simulato: la soluzione ottimale rispecchia il criterio di efficienza economica e tutti i vincoli sono rispettati. I risultati acquisiti dal MILP in questo contesto artificiale riflettono quanto riportato nella letteratura sui modelli deterministici, ossia che la programmazione matematica resta un approccio altamente efficace per analisi di configurazione a breve termine quando la variabilità e la struttura dei costi sono ben conosciute (Hillier & Lieberman, 2021; Pinedo, 2016).

I risultati del MILP fungeranno da riferimento per le famiglie algoritmiche descritte nei paragrafi successivi.

3.1.2 – Applicazione delle metaeuristiche al caso di studio fittizio

L'utilizzo di metaeuristiche in un contesto di simulazione permette di esplorare il comportamento del sistema produttivo in situazioni di maggiore variabilità rispetto a quelle gestite dal modello MILP. Le metaeuristiche sono particolarmente efficaci in presenza di problemi la cui struttura determina uno spazio delle soluzioni vasto, non lineare o con combinazioni difficili da governare tramite approcci deterministici, come dimostrato dalla letteratura fondamentale di ottimizzazione evolutiva e swarm intelligence (Holland, 1975; Goldberg, 1989; Kennedy & Eberhart, 1995; Talbi, 2009).

In questo caso, la combinazione di quattro linee eterogenee, da due a sei operatori per linea e una richiesta fluttuante crea scenari decisionali favorevoli all'esplorazione tramite strategie di ricerca iterativa.

Le metaeuristiche non sostituiscono il modello esatto in senso stretto, ma testano la loro capacità di generare configurazioni "quasi ottimali" in tempi brevi e con maggiore flessibilità. Questo approccio risulta coerente con la letteratura sull'ottimizzazione approssimata in contesti produttivi complessi, in cui la natura dinamica dei sistemi rende conveniente utilizzare tecniche di ricerca stocastica (Blum & Roli, 2003; Dorigo & Stützle, 2004; Talbi, 2009).

Nella simulazione, le metaeuristiche consentono di esplorare diverse combinazioni tra linee attive, livelli di saturazione e disponibilità di operatori, senza le limitazioni imposte dalle formulazioni lineari. In questo caso, le metaeuristiche vengono implementate creando popolazioni iniziali di soluzioni che rappresentano configurazioni delle linee e diversi livelli di saturazione, garantendo che il numero di operatori non superi il limite massimo. Tramite operatori di mutazione, crossover o aggiornamento basato sulla vicinanza, le soluzioni evolvono verso aree del decision space in cui il costo operativo è minore. La letteratura precedente ha dimostrato come tale processo di ricerca guidata sia particolarmente efficace in problemi di line balancing, pianificazione del personale e configurazioni multi-linea, soprattutto quando l'uso del modello esatto diventa oneroso a causa della crescente complessità (Becker & Scholl, 2006; Boysen et al., 2007; Alharkan & Ahmad, 2015).

In effetti, nelle simulazioni, le metaeuristiche esplorano scenari che il MILP tende a trattare in modo più rigido, come configurazioni che spingono le linee automatiche a livelli di saturazione elevati quando il personale è scarso, oppure alternative che privilegiano le linee manuali quando gli operatori sono sufficienti.

Tale comportamento riflette l'adattabilità intrinseca delle metaeuristiche, che si aggiornano rapidamente in funzione della domanda simulata e delle variazioni nelle risorse disponibili, come ampiamente riportato nella letteratura sull'ottimizzazione per scheduling e configurazioni ibride (Ruiz & Maroto, 2005; Zandieh et al., 2010; Gendreau & Potvin, 2019).

La simulazione dimostra inoltre come, pur non garantendo soluzioni pienamente ottimali, le metaeuristiche convergano verso valori molto vicini a quelli ottenuti tramite MILP. In particolare, il diverso costo operativo tra linee manuali e automatiche consente agli algoritmi evolutivi e swarm-based di scartare rapidamente combinazioni inefficaci negli step iniziali, concentrandosi su una porzione più ristretta e promettente dello spazio decisionale.

Tale condotta, largamente trattata negli studi sull'ottimizzazione combinatoria e multi-obiettivo, si rivela specialmente vantaggiosa quando si cerca di raggiungere soluzioni valide con limitate risorse di calcolo.

Ciononostante, malgrado i molteplici benefici, l'impiego delle metaeuristiche nel contesto simulato mostra alcune limitazioni strutturali.

In primo luogo, l'efficacia delle soluzioni dipende notevolmente dalla regolazione dei parametri algoritmici: dimensione della popolazione, tasso di mutazione, numero di iterazioni e altre impostazioni incidono in modo significativo sui risultati. Tale fenomeno è ampiamente discusso negli studi dedicati alla meta-ottimizzazione e ai metodi sensibili alla parametrizzazione.

Inoltre, la componente stocastica delle metaeuristiche implica che esecuzioni diverse dello stesso algoritmo possano produrre soluzioni non perfettamente identiche, riducendo la prevedibilità rispetto a un modello deterministico come il MILP. Allo stesso tempo, tale variabilità offre un vantaggio interpretativo nei contesti complessi e altamente eterogenei, perché permette di identificare configurazioni alternative che non emergerebbero tramite approcci completamente deterministici.

Complessivamente, l'applicazione delle metaeuristiche al caso simulato dimostra che tali tecniche sono particolarmente utili nell'affrontare scenari dinamici, risorse limitate e linee eterogenee. La loro capacità di individuare rapidamente soluzioni competitive, pur non essendo ottime in senso matematico, le rende il complemento ideale del modello MILP, fornendo risposte rapide e affidabili anche quando la complessità combinatoria aumenta. Qui viene quindi definito l'approccio MET.

3.1.3– Applicazione del Machine Learning al caso di studio fittizio

L'impiego del Machine Learning (ML) nel caso simulato introduce una visione alternativa rispetto ai modelli matematici e alle metaeuristiche precedentemente esaminate. Mentre il MILP offre soluzioni ottimali in contesti strutturati e le metaeuristiche esplorano efficacemente spazi decisionali complessi, il ML consente di riconoscere pattern ricorrenti nei dati operativi del sistema, identificando correlazioni non lineari tra domanda, configurazione delle linee e performance generali. Questo metodo è ampiamente trattato nella letteratura sulla produzione data-driven e sui sistemi avanzati di pianificazione, dove algoritmi di apprendimento supervisionato e non supervisionato vengono utilizzati per migliorare previsioni, adattabilità e qualità decisionale (Jordan & Mitchell, 2015; Bousdekis et al., 2021; Wuest et al., 2016).

In questo caso simulato, il ML non replica il comportamento del MILP né genera direttamente configurazioni produttive, ma predice condizioni operative ottimali, anticipa tendenze della domanda, valuta livelli di saturazione attesi e stima indicatori di efficienza come costi, utilizzo risorse e produttività oraria. La capacità di apprendere queste relazioni è particolarmente vantaggiosa in sistemi con variabilità di manodopera e domanda, come quello fittizio in esame,

poiché riduce l'incertezza e migliora la qualità delle decisioni operative, in linea con gli studi sulla produzione predittiva e capacity prediction (Zhang et al., 2019; Lee et al., 2018).

Una delle applicazioni più significative del ML nel caso simulato riguarda la previsione della domanda oraria. Poiché la domanda varia tra i due turni giornalieri ed è soggetta a fluttuazioni, algoritmi di regressione e forecasting — come Random Forest, Gradient Boosting o modelli LSTM — possono apprendere i pattern nelle serie simulate e prevedere anticipatamente il profilo produttivo necessario. In letteratura, la previsione della domanda è cruciale nei sistemi dinamici di scheduling e nei contesti ad alta deperibilità, come l'agroalimentare, dove anticipare i carichi produttivi aiuta a minimizzare costi e inefficienze (Fildes & Petropoulos, 2015; Carbonneau et al., 2008). Nel caso simulato, previsioni accurate permettono di selezionare configurazioni di linee più coerenti con la domanda prevista, riducendo la necessità di configurazioni inefficienti nelle ore di picco.

Oltre alla previsione della domanda, il ML può stimare il comportamento del sistema produttivo in base alle combinazioni di linee attive e operatori disponibili. Con tecniche supervisionate, si possono addestrare modelli che prevedono output come costo operativo totale, saturazione delle linee, rispetto dei vincoli o rischio di sovraccarico. Approcci simili sono stati proposti in studi sui Digital Twin e sulla modellazione predittiva dei sistemi manifatturieri, dove il ML approssima la funzione di performance del sistema e supporta decisioni operative in tempo reale (Rasheed et al., 2019; Tao et al., 2018). Nel nostro caso simulato, questi modelli generano previsioni in millisecondi, permettendo simulazioni rapide di scenari alternativi senza dover eseguire ripetutamente il modello MILP o riavviare processi metaeuristici.

Creare un modello predittivo della performance è particolarmente utile per valutare rapidamente l'impatto di piccoli cambiamenti, come l'aggiunta di un operatore, la riduzione di un turno o l'attivazione temporanea di una linea più costosa. Il ML permette di stimare la qualità delle soluzioni con costo computazionale ridotto, in accordo con gli studi sull'uso di surrogate models e approssimatori nei processi decisionali (Forrester & Keane, 2009; Sun et al., 2020).

Il caso simulato offre anche la possibilità di utilizzare tecniche di clustering o apprendimento non supervisionato per individuare configurazioni produttive ricorrenti in presenza di variabilità della domanda e del personale. Metodi come k-means, DBSCAN o Self Organizing Maps possono evidenziare schemi operativi emergenti, classificando automaticamente le situazioni in gruppi che richiedono configurazioni simili. Questo approccio è stato proposto in vari studi sulla gestione dei sistemi produttivi variabili e sull'analisi di comportamenti emergenti in ambienti complessi (Bauernhansl et al., 2020; Wuest et al., 2016). Nel caso simulato, il clustering distingue naturalmente scenari ad alta saturazione, scenari con surplus di operatori o condizioni in cui è preferibile utilizzare linee manuali anziché automatiche, fornendo indicazioni preziose

per la selezione di algoritmi o configurazioni nell'analisi comparativa successiva.

L'adozione del ML nel caso fittizio comporta diversi vantaggi specifici:

- Rapidità di risposta: una volta addestrati, i modelli producono previsioni estremamente veloci, consentendo analisi istantanee di scenari alternativi (Jordan & Mitchell, 2015).
- Capacità di catturare relazioni non lineari tra domanda, operatori e prestazioni delle linee, difficilmente modellabili con MILP o metaeuristiche (Goodfellow et al., 2016).
- Adattabilità ai cambiamenti improvvisi, grazie alla possibilità di riaddestramento quando sono disponibili nuovi dati, come evidenziato negli studi sulla produzione adattiva (Zhang et al., 2019).
- Supporto alle decisioni strategiche, attraverso la previsione degli effetti economici derivanti da modifiche nella disponibilità di operatori o nell'utilizzo delle linee.

Questi vantaggi rendono il ML particolarmente adatto a integrare, non a sostituire, le soluzioni esatte e approssimate analizzate precedentemente.

L'applicazione in questo scenario evidenzia alcuni limiti strutturali:

- Necessità di dati sufficienti e significativi, anche se simulati. La qualità dei risultati dipende dalla coerenza e quantità dei dati disponibili per l'addestramento, aspetto sottolineato da molte analisi sul ML industriale (Wuest et al., 2016; Lee et al., 2018).
- Mancanza di garanzia di ottimalità, poiché il modello predittivo può indicare configurazioni efficienti senza garantire il raggiungimento del costo minimo assoluto.
- Possibile perdita di interpretabilità, tipica dei modelli più complessi come Boosting o reti neurali, sebbene tecniche come SHAP e LIME possano mitigare questo problema (Ribeiro et al., 2016; Lundberg & Lee, 2017).
- Dipendenza dall'accuratezza della simulazione, poiché errori sistematici nei dati simulati produrrebbero previsioni distorte.

Nonostante questi limiti, l'analisi mostra che il ML costituisce un potente strumento complementare per il caso considerato, soprattutto quando l'obiettivo è disporre di un modello rapido, adattabile e capace di apprendere dinamiche complesse difficilmente catturabili con approcci deterministici.

Nel confronto tra famiglie algoritmiche, il ML assume il ruolo di "ponte" tra la precisione del MILP e la flessibilità delle metaeuristiche, offrendo previsioni veloci, identificazione di pattern nascosti e supporto alle analisi di scenario. I risultati ottenuti nel caso simulato mostrano come il ML permetta di anticipare trend produttivi, stimare costi operativi e individuare configurazioni

efficienti, contribuendo al processo decisionale anche senza una struttura ottimizzativa esplicita. Tale comportamento è coerente con la letteratura sui sistemi data-driven per la manifattura avanzata (Rasheed et al., 2019; Lee et al., 2018; Tao et al., 2018) e costituisce la base per il confronto con le tecniche di Reinforcement Learning analizzate successivamente

3.1.4 – Applicazione del Reinforcement Learning al caso simulato

Il punto di forza dell'implementazione del Reinforcement Learning (RL) nel caso simulato risiede nella capacità di interpretare il processo decisionale da una prospettiva diversa rispetto alle metodologie precedenti. In particolare, il RL basa le proprie decisioni sull'esperienza, anziché su modelli matematici rigidi o regole predefinite come nel caso delle metaeuristiche. A differenza del MILP, caratterizzato da una struttura formalizzata, e delle tecniche metaeuristiche, che esplorano progressivamente lo spazio delle soluzioni, il RL apprende quali configurazioni produttive risultano più efficaci osservando i risultati delle proprie azioni. Ciò rende questa strategia particolarmente adatta a contesti caratterizzati da domanda variabile e disponibilità di personale non costante. Tali vantaggi sono ampiamente discussi nella letteratura sull'applicazione del RL nei sistemi industriali (Sutton & Barto, 2018; Mazyavkina et al., 2021). Nel sistema simulato, l'ambiente dell'agente RL considera esclusivamente i fattori realmente influenti: le linee attivabili, il numero di operatori disponibili e la domanda da soddisfare. Ogni decisione genera immediatamente un feedback sotto forma di costi operativi e capacità produttiva. Questo ciclo continuo di scelta, risultato e apprendimento consente all'agente di individuare progressivamente le configurazioni più vantaggiose. Tale comportamento è coerente con i sistemi intelligenti studiati in ambito industriale, nei quali l'apprendimento diretto dal processo è considerato un vantaggio significativo rispetto ai modelli convenzionali (Kaelbling et al., 1996; Li, 2017).

Un risultato rilevante emerso dalla simulazione è che l'agente RL non si limita a replicare le soluzioni ottimali prodotte dal MILP, ma sviluppa una vera e propria strategia decisionale, riconoscendo scenari ricorrenti. Ad esempio, apprende autonomamente che, in presenza di una bassa domanda, non conviene attivare entrambe le linee automatiche a causa dei costi elevati; al contrario, quando il numero di operatori è ridotto, le linee automatiche diventano preferibili nonostante il costo superiore, poiché garantiscono il rispetto dei vincoli operativi. Questo tipo di comportamento è ampiamente documentato negli studi dedicati all'applicazione del RL nei sistemi industriali complessi (Zhang et al., 2021; Vázquez-Canteli & Nagy, 2019).

L'esperienza accumulata durante l'addestramento permette inoltre all'agente di gestire efficacemente situazioni impreviste, come improvvisi picchi di domanda o riduzioni della forza

lavoro. Questa capacità di generalizzazione rappresenta uno dei principali punti di forza del RL ed è spesso citata come motivazione per il suo impiego nei sistemi cyber-fisici avanzati e nei Digital Twin operativi (Rasheed et al., 2019; Tao et al., 2018). Nel nostro caso, tale flessibilità si traduce nella capacità di elaborare nuove configurazioni operative senza la necessità di ridefinire modelli matematici o avviare da zero un processo di ottimizzazione.

Questa versatilità, tuttavia, comporta dei costi. L'addestramento richiede infatti numerose simulazioni consecutive, poiché il RL deve "sbagliare" molte volte prima di apprendere quali scelte producono i risultati migliori. Questo aspetto, ben documentato in letteratura, rappresenta uno dei principali limiti dell'approccio (Mnih et al., 2015; Henderson et al., 2018). Inoltre, mentre il MILP garantisce soluzioni matematicamente ottime e le metaeuristiche convergono rapidamente verso risultati efficaci, il RL non assicura l'ottimalità della strategia appresa: l'agente seleziona semplicemente la politica che ha prodotto il miglior rendimento durante l'addestramento. Pur riducendo la prevedibilità del comportamento rispetto agli algoritmi deterministici, ciò rende il RL particolarmente efficace in scenari soggetti a cambiamenti continui.

Un aspetto critico è la definizione della funzione di ricompensa. Nel modello simulato, la ricompensa si basa principalmente sul costo operativo e include penalità nei casi in cui la domanda non viene soddisfatta o le configurazioni risultano inefficienti. Questo schema orienta l'agente verso soluzioni che bilanciano naturalmente efficienza ed efficacia, come evidenziato negli studi sul controllo adattivo e sull'ottimizzazione sequenziale nei processi produttivi (Park et al., 2019; Contreras-Crespo et al., 2022). Tuttavia, una definizione inadeguata della ricompensa può indurre l'agente ad apprendere strategie subottimali, rischio ben noto nei modelli di apprendimento per rinforzo.

Nonostante tali limitazioni, il RL si rivela un complemento essenziale nel caso analizzato. La sua capacità di apprendere dall'interazione con l'ambiente e di adattarsi a nuove condizioni lo rende particolarmente utile in contesti caratterizzati da domanda fluttuante o risorse operative discontinue. Inoltre, la natura sequenziale delle decisioni del RL si presta alla simulazione di scenari complessi, come pianificazioni multi-giornaliere, attività di manutenzione o gestione di incertezze nella qualità del prodotto o nell'arrivo dei lotti.

Complessivamente, l'applicazione del RL al caso simulato conferma quanto evidenziato dalla letteratura recente: le tecniche di apprendimento per rinforzo non sostituiscono i metodi deterministici o approssimati, ma li completano introducendo una forma di intelligenza decisionale capace di adattarsi all'evoluzione del sistema. Il RL offre quindi una prospettiva unica sulla gestione dinamica delle risorse e rappresenta un elemento indispensabile nel confronto tra le diverse famiglie algoritmiche (Mazyavkina et al., 2021; Silver et al., 2016).

3.2 – Confronto integrato tra le famiglie di algoritmi nel caso di studio fittizio

Un'analisi diretta e globale della simpatia tra le quattro famiglie algoritmiche nel caso simulato mostra che ogni famiglia considera e prende in considerazione in modo diverso le caratteristiche operative del sistema da imballaggio fittizio. Come risultato, le differenze non sono condotte solo nel senso della generazione di snapshot dei risultati, ma riguardano anche il modo in cui le informazioni vengono elaborate nel processo decisionale, l'adattamento e persino il tipo di supporto per le decisioni ideate. La letteratura riconosce che l'efficacia delle famiglie algoritmiche dipende dalla corrispondenza diretta con le caratteristiche interne e le condizioni di utilizzo del contesto. Inoltre, esiste un accordo sopraelevato nella letteratura, secondo il quale il MILP, in quanto metodo preciso, si dimostra particolarmente idoneo alla configurazione del caso simulato. Questo significa che il MILP è una buona soluzione di benchmark per la configurazione corrente del problema. Il modello esatto forma una mappa, che incorpora variabili decisionali, quattro linee e risorse finite, assicurando risultati ottimali. I modelli esatti sono altamente raccomandati quando il problema è chiaramente definito, e quando limitazioni e parametri possono essere controllati senza troppa difficoltà. Tuttavia, questa inflessibilità riduce la possibilità del modello di rispondere velocemente a cambiamenti esterni complicati o inaspettati nella richiesta, e metaeuristiche possono riempire questo vuoto e introducono strategie esplorative e flessibili tipiche dell'ottimizzazione euristica. Una lega di due coni grandi al MILP può assumere qualità simili. Il machine learning, infine, è una lente nuova che non considera i risultati o esplora lo spazio delle soluzioni; fornisce invece previsioni sulle variabili chiave del sistema sulla base dei dati disponibili. In altre parole, un modello di ML apprende schemi produttivi e li utilizza per prevedere scenari futuri con rapidità ed efficienza. La letteratura elenca la manifattura guidata dai sistemi come uno degli ambiti in cui il ML risulta particolarmente efficace nei sistemi dinamici. Dai risultati del caso simulato, vediamo che il ML fornisce facilmente previsioni affidabili o analisi di scenario anche in presenza di cambiamenti rapidi. Il Reinforcement Learning aggiunge a quest'analisi una prospettiva autonoma e adattiva. Al contrario degli altri metodi tradizionali, infatti, il RL non risolve un particolare problema e non predice un valore, bensì impara una politica generale: ossia, in questo caso, un insieme di regole decisionali che sono utili in più casi che uno. Alcuni degli studi più recenti che hanno esaminato l'applicazione del RL ai sistemi produttivi (Mazyavkina et al., 2021; Zhang et al., 2021; Silver et al., 2016) dimostrano che questo modello è indicato in contesti ad alta variabilità della domanda o, in generale, quando sono richieste risposte dinamiche non contemplabili a

priori. Nel nostro esempio, il RL impara a riconoscere pattern ricorrenti e ad adattare la configurazione delle linee all'attuale disponibilità di operai e alla quantità della domanda, senza modellazione esplicita; Ciononostante, gli alti costi di calcolo necessari per l'addestramento e la mancanza di garanzie riguardo all'ottimalità ne restringono l'utilizzo in situazioni dove sono necessarie risposte rapide. Il confronto del dato test dimostra come ciascuna famiglia algoritmica, quindi, metta in luce aspetti complementari del sistema simulato. Il MILP dà un proprio rigore matematico e un proprio riferimento ottimale; le metaeuristiche danno la propria flessibilità e rapidità in scenari complessi; il ML fa prevedere e interpretare pattern produttivi; il RL introduce la propria capacità di adattamento e di apprendimento. Si tratta della stessa complementarità in cui evolvono i sistemi decisionali moderni, con diversi algoritmi collaborativi che danno risposta alla miriade di esigenze operative, così come riassunto nei modelli integrati di Advanced Decision Making (Wuest et al., 2016; Tao et al., 2018; Kapteyn et al., 2020).

Famiglia algoritmica	Punto di forza principale	Limiti nel caso simulato	Quando è più utile
MILP	Ottimalità garantita e piena trasparenza della soluzione	Poco flessibile in scenari molto variabili; scalabilità limitata	Quando serve la soluzione ottima e i dati sono stabili
Metaeuristiche	Rapidità nell'esplorare molte combinazioni; soluzioni quasi ottime	Sensibili al tuning; nessuna garanzia matematica	Quando serve una buona soluzione in poco tempo
Machine Learning	Previsione di domanda, costi e pattern operativi	Dipende dai dati; non genera direttamente decisioni ottime	Quando serve prevedere il comportamento del sistema
Reinforcement Learning	Apprendimento autonomo e adattivo; gestisce la variabilità	Richiede molto addestramento; soluzioni non sempre ottimali	Quando il sistema cambia spesso e serve adattività

Complessivamente, il confronto evidenzia che non esiste un algoritmo universalmente

superiore: ciascuno soddisfa una specifica esigenza del sistema. Il MILP fornisce il benchmark ottimale; le metaeuristiche presentano soluzioni veloci; il ML prevede comportamenti complessi; il RL impara autonomamente a gestire la variabilità.

Questo approccio integrato si allinea perfettamente con gli attuali trend nei sistemi produttivi intelligenti e nei Digital Twin operativi, dove l'integrazione di diverse tecniche produce soluzioni più robuste, adattabili e affidabili (Rasheed et al., 2019; Tao et al., 2018; Lee et al., 2018). L'esperimento simulato chiarisce come diverse famiglie algoritmiche contribuiscano, ognuna a suo modo, al processo decisionale in un sistema produttivo con risorse limitate, linee eterogenee e domanda variabile. L'analisi dimostra che non è la complessità tecnica degli algoritmi a fare la differenza, ma la loro capacità di adattarsi al contesto operativo simulato. Questa osservazione rispecchia quanto riportato negli studi sui moderni sistemi decisionali industriali, dove la selezione degli strumenti metodologici deve basarsi sull'allineamento tra la struttura del problema e il comportamento della tecnica utilizzata (Gendreau & Potvin, 2019; Talbi, 2009).

Nel caso studiato, il modello MILP ha fornito un riferimento stabile per valutare le soluzioni, confermando che l'ottimalità matematica resta fondamentale quando i dati sono ben definiti e i vincoli possono essere rappresentati rigorosamente. Tuttavia, l'emergere di scenari alternativi, dovuti alla variabilità degli operatori e della domanda oraria, ha evidenziato la necessità di metodi capaci di esplorare configurazioni non immediatamente evidenti. Le metaeuristiche hanno confermato quanto indicato da Blum & Roli (2003): la ricerca stocastica può trovare soluzioni competitive in tempi brevi, offrendo flessibilità quando lo spazio decisionale aumenta. Parallelamente, il Machine Learning ha ampliato la prospettiva analitica: non solo ricerca della configurazione ottimale, ma anche comprensione dei pattern di domanda, utilizzo delle linee e comportamento del sistema. Come evidenziato dalla letteratura sulla manifattura data-driven (Jordan & Mitchell, 2015; Wuest et al., 2016), la capacità di prevedere le condizioni operative migliora la qualità delle decisioni, specialmente in presenza di incertezza strutturale. Nella simulazione, il ML ha dimostrato come l'apprendimento dai dati possa supportare l'anticipazione dell'impatto delle scelte operative senza ricorrere a nuove ottimizzazioni.

Il Reinforcement Learning ha aggiunto una dimensione temporale assente negli altri algoritmi: la capacità di apprendere non solo cosa fare, ma come prendere decisioni coerenti in una sequenza di stati. Questa caratteristica, discussa da Mazyavkina et al. (2021) e Sutton & Barto (2018), rende il RL particolarmente adatto ai contesti dinamici, dove ogni decisione influenza le condizioni future. Nella simulazione, l'agente RL ha sviluppato una politica autonoma capace di adattarsi alla variabilità di operatori e domanda, offrendo una prospettiva evolutiva che gli altri approcci non possono esprimere direttamente.

La conclusione principale è che nessun algoritmo è sufficiente da solo per affrontare un sistema con vincoli, variabilità e incertezza. La complementarità tra metodi esatti, approssimati, predittivi e adattivi è essenziale per una visione decisionale completa, che combini rigore matematico, esplorazione rapida, anticipazione dei comportamenti e adattamento temporale. Questa integrazione emerge come tendenza dominante nelle applicazioni avanzate dei Digital Twin e dei sistemi produttivi intelligenti (Rasheed et al., 2019; Tao et al., 2018; Lee et al., 2018).

In sintesi, il capitolo 3 dimostra come l'analisi algoritmica applicata al caso simulato permetta non solo di identificare soluzioni operative efficienti, ma anche di comprendere come diverse tecniche possano cooperare per fornire supporto decisionale robusto, flessibile e coerente con le esigenze di un sistema produttivo moderno. Il confronto tra algoritmi pone le basi per una riflessione più ampia, che sarà approfondita nel capitolo successivo, dove l'obiettivo non sarà solo individuare la soluzione più efficiente, ma interpretare questi risultati alla luce degli obiettivi generali della ricerca e delle prospettive evolutive dei sistemi decisionali basati su Digital Twin.

Conclusione

Il presente lavoro ha analizzato il ruolo del Digital Twin come strumento di supporto all'ottimizzazione dei processi produttivi, approfondendo le principali tecnologie e metodologie algoritmiche che ne consentono il funzionamento all'interno dei moderni contesti industriali.

Nel corso dell'analisi è emerso come il Digital Twin rappresenti oggi una delle soluzioni più interessanti per supportare le imprese nella gestione di sistemi produttivi sempre più complessi, caratterizzati da elevata variabilità, numerosi vincoli operativi e una crescente disponibilità di dati. La possibilità di integrare informazioni provenienti dal sistema fisico con modelli digitali e strumenti di simulazione consente infatti di ottenere una maggiore comprensione dei processi e di supportare il processo decisionale in maniera più efficace rispetto agli approcci tradizionali.

L'approfondimento delle diverse famiglie algoritmiche ha evidenziato come ciascun approccio presenti caratteristiche specifiche e risulti adatto a differenti esigenze operative. I modelli matematici si distinguono per la capacità di fornire soluzioni ottimali in problemi ben strutturati, mentre le metaeuristiche offrono una maggiore flessibilità nella gestione di scenari complessi e caratterizzati da numerosi vincoli. Parallelamente, il Machine Learning consente di valorizzare i dati storici per migliorare le capacità previsionali del sistema, mentre il Reinforcement Learning introduce meccanismi di apprendimento autonomo particolarmente interessanti nei contesti dinamici e soggetti a continui cambiamenti.

Con riferimento al caso studio considerato, è emerso come la gestione di linee produttive multiple, caratterizzate da differenti capacità operative, disponibilità variabile delle risorse e necessità di rispettare obiettivi produttivi stringenti, possa trarre notevoli benefici dall'utilizzo di strumenti basati sul Digital Twin. La possibilità di simulare configurazioni alternative, valutare preventivamente diverse scelte operative e analizzare l'impatto delle decisioni prima della loro applicazione reale rappresenta infatti un importante supporto per il miglioramento delle prestazioni produttive.

Un ulteriore elemento emerso riguarda il ruolo centrale dei dati all'interno del Digital Twin. L'efficacia di tali sistemi dipende infatti dalla capacità di raccogliere, organizzare e utilizzare correttamente le informazioni provenienti dal contesto produttivo. Per questo motivo, oltre agli aspetti tecnologici e algoritmici, assume particolare importanza la qualità dei dati disponibili e la capacità dell'organizzazione di sviluppare una cultura orientata all'utilizzo delle informazioni come supporto alle decisioni.

Nonostante le potenzialità evidenziate, l'adozione di queste tecnologie presenta ancora alcune criticità legate alla complessità di implementazione, ai costi iniziali di sviluppo e alla necessità di disporre di dati affidabili e aggiornati. Tuttavia, la continua evoluzione delle tecnologie digitali e la crescente diffusione delle soluzioni legate all'Industria 4.0 lasciano prevedere un utilizzo sempre più ampio dei Digital Twin nei sistemi produttivi del futuro.

In conclusione, il lavoro svolto ha permesso di evidenziare come il Digital Twin rappresenti uno strumento particolarmente promettente per il supporto alle decisioni e per l'ottimizzazione dei processi produttivi. L'integrazione tra simulazione, analisi dei dati e algoritmi intelligenti offre infatti nuove opportunità per migliorare efficienza, flessibilità e capacità di adattamento delle organizzazioni industriali. In prospettiva futura, risulta particolarmente interessante approfondire l'impiego di approcci ibridi capaci di combinare tecniche di ottimizzazione tradizionale, simulazione e apprendimento automatico, al fine di sviluppare sistemi sempre più autonomi, efficienti e in grado di rispondere alle esigenze di contesti produttivi in continua evoluzione.

RIFERIMENTI BIBLIOGRAFICI

Abdellaoui, A., Benhadou, S., & Achchab, S. (2022). Metaheuristic approaches for complex

production scheduling problems. *International Journal of Production Research*.

Airbus. (2020). Digital Twin in Aerospace Assembly Processes. Airbus Technical Report.

Alonso, A., Santamaría, E., & González, P. (2021). Challenges of optimization in agri-food production systems. *Journal of Food Engineering*.

Bauer, D., Schlund, S., & Götz, S. (2021). Data quality challenges in Industry 4.0 environments. *Procedia CIRP*.

Becker, C., & Scholl, A. (2006). A survey on problems and methods in assembly line balancing. *European Journal of Operational Research*.

Bertsimas, D., & Tsitsiklis, J. (1997). *Introduction to Linear Optimization*. Athena Scientific.

Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer.

Blum, C., & Roli, A. (2003). Metaheuristics in combinatorial optimization. *ACM Computing Surveys*.

Bosch Manufacturing Report. (2021). *Deep Learning Integration in Smart Manufacturing*.

Boysen, N., Fliedner, M., & Scholl, A. (2007). Assembly line balancing: A review. *European Journal of Operational Research*.

Buşoniu, L., Babuska, R., De Schutter, B., & Ernst, D. (2010). *Reinforcement Learning and Dynamic Programming Using Function Approximators*. CRC Press.

Centobelli, P., Cerchione, R., & Esposito, E. (2020). Production planning in food industry. *Journal of Cleaner Production*.

Chen, C., Chu, C., & Proth, J. M. (2013). Supply chain scheduling with LP/MILP models. *International Journal of Production Economics*.

Clerc, M. (2006). *Particle Swarm Optimization*. ISTE.

Dantzig, G. B. (1963). *Linear Programming and Extensions*. Princeton University Press.

Deb, K. (2001). *Multi-objective Optimization Using Evolutionary Algorithms*. Wiley.

Fiat Chrysler Automobiles (FCA). (2020). *AI for Internal Logistics Optimization*.

Florescu, A., Marinakis, Y., & Zopounidis, C. (2024). Metaheuristic design for flexible production systems. *Computers & Industrial Engineering*.

Gabor, T., Belzner, L., Kiermeier, M., Beck, M. T., & Neitz, A. (2020). Machine learning in digital twin contexts. *Future Generation Computer Systems*.

GE Research. (2018). *Reinforcement Learning for Wind Turbine Optimization*.

Gendreau, M., & Potvin, J. Y. (2019). *Handbook of Metaheuristics*. Springer.

Gen, M., & Cheng, R. (2000). *Genetic Algorithms and Engineering Optimization*. Wiley.

Gibbons, S., Ramudhin, A., & Kumar, A. (2022). Algorithm selection for complex industrial systems. *Computers & Industrial Engineering*.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

- Grieves, M., & Vickers, J. (2017). Digital Twin framework and modeling principles. In *Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems*.
- Guo, Y., Deng, X., & Li, F. (2023). LSTM-based predictive modeling for manufacturing DT. *Journal of Manufacturing Systems*.
- Honeywell Applied Research. (2021). AI-driven HVAC Optimization with RL.
- Hooker, J. (2000). *Logic-Based Methods for Optimization*. Springer.
- Huang, X., Li, F., & Zhao, H. (2023). Online learning models for adaptive digital twins. *IEEE Transactions on Industrial Informatics*.
- Hwang, R., Lee, C., & Lee, J. (2018). MILP-based line balancing with stochastic processing times. *International Journal of Advanced Manufacturing Technology*.
- IBM. (2021). *AI Predictive Maintenance for Industry 4.0*.
- Ivanov, D., & Dolgui, A. (2020). Digital supply chain twins. *International Journal of Production Research*.
- Jans, R., & Degraeve, Z. (2007). Metaheuristics and MILP in lot-sizing. *European Journal of Operational Research*.
- Jovanović, P., et al. (2019). Algorithm selection in manufacturing optimization. *Applied Soft Computing*.
- Jovane, F., Yoshikawa, H., & Alting, L. (2009). Sustainable manufacturing strategies. *CIRP Annals*.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning overview. *Journal of Artificial Intelligence Research*.
- Kapteyn, M., Knezevic, D., & Willcox, K. (2020). Surrogate models for Digital Twins. *AIAA Journal*.
- Kagermann, H., Wahlster, W., & Helbig, J. (2013). *Recommendations for Implementing Industry 4.0*. German National Academy of Science.
- Kennedy, J., & Eberhart, R. (1995). Particle Swarm Optimization. *IEEE International Conference on Neural Networks*.
- Köhler, S., & Giebels, M. (2021). Multi-criteria evaluation of industrial optimization methods. *Procedia CIRP*.
- Krishnan, R., et al. (2023). Hybrid ML–metaheuristic decision systems. *Expert Systems with Applications*.
- Luke, S. (2013). *Essentials of Metaheuristics*. Lulu.
- Lu, Q., Guo, H., & Maropoulos, P. (2020). Data issues in digital manufacturing. *International Journal of Computer Integrated Manufacturing*.
- Leng, J., Jiang, P., & Liu, Q. (2021). Digital twins-driven smart manufacturing. *Journal of*

Manufacturing Systems.

Liang, X., Li, R., & Zhang, Y. (2018). RL for dynamic production control. *Robotics and Computer-Integrated Manufacturing*.

Marinakis, Y., Migdalas, A., & Sifaleras, A. (2020). Hybrid metaheuristics in production systems. *European Journal of Operational Research*.

Minerva, R., Brancaleoni, A., & Rotondi, D. (2022). Adaptive DT architectures. *Sensors*.

Mourtzis, D. (2020). Simulation and optimization in modern manufacturing. *CIRP Journal of Manufacturing Science and Technology*.

Mourtzis, D. (2021). Digital Twins in product–process integration. *International Journal of Production Research*.

Moyano-Fuentes, J., & Sacristán-Díaz, M. (2012). Lean in the food industry. *International Journal of Production Economics*.

Müller, J., Hopf, A., & Vogel, J. (2018). Data quality challenges for predictive maintenance. *Journal of Manufacturing Systems*.

Nestlé R&D Whitepaper. (2022). Digital Twin Applications in Food Processing.

Nemhauser, G. L., & Wolsey, L. A. (1988). *Integer and Combinatorial Optimization*. Wiley.

Papacharalampopoulos, A., & Stavropoulos, P. (2017). Data-driven manufacturing: challenges. *Procedia CIRP*.

Park, C., Kim, J., & Lee, D. (2020). Anomaly detection for cyber-physical manufacturing. *IEEE Access*.

Pastor, R., & Corominas, A. (2010). Assembly line balancing with MILP. *International Journal of Production Research*.

Pinedo, M. (2016). *Scheduling: Theory, Algorithms, and Systems*. Springer.

Pourbabaei, B., et al. (2020). RL for energy process optimization. *Energy AI*.

Putra, H., et al. (2022). Predictive Digital Twin solutions for manufacturing. *Robotics and CIM*.

Qi, Q., & Tao, F. (2018). Digital Twin-driven manufacturing intelligence. *Robotics and Computer-Integrated Manufacturing*.

Rasheed, A., San, O., & Kvamsdal, T. (2020). Digital Twin in industry: A review. *Computers & Industrial Engineering*.

Schuh, G., Anderl, R., & Gausemeier, J. (2014). *Industrie 4.0 Maturity Model*. RWTH Aachen.

Schneider Electric. (2023). *Reinforcement Learning for Real-Time Energy Optimization*.

Siemens. (2020). *MindSphere Applied Optimization & Digital Twin*.

Silver, D., et al. (2017). RL with deep neural networks. *Nature*.

Sun, Q., Wang, Z., & Li, Y. (2022). Surrogate-assisted optimization in Digital Twins. *Advanced Engineering Informatics*.

- Sutton, R. S., & Barto, A. G. (2018). Reinforcement Learning: An Introduction. MIT Press.
- Talbi, E.-G. (2009). Metaheuristics: From Design to Implementation. Wiley.
- Tamaki, S., Kita, H., & Kobayashi, S. (1996). GA for setup-time optimization. IEEE Transactions on Systems, Man, and Cybernetics.
- Toyota Smart Factory Study. (2022). DRL for AGV and Internal Logistics.
- Vamvoudakis, K. G., & Lewis, F. (2010). Adaptive dynamic programming. Automatica.
- Vercammen, E., et al. (2021). RL-driven Digital Twins in automotive assembly. IEEE Transactions on Automation Science and Engineering.
- Wang, Z., Sun, Q., & Wang, X. (2022). RL-based simulation learning for digital twins. Engineering Applications of AI.
- Wu, D., Greer, M., Rosen, D., & Schaefer, D. (2015). Smart manufacturing challenges. Procedia CIRP.
- Wuest, T., Weimer, D., Irgens, C., & Thoben, K. (2016). Machine learning in manufacturing. Journal of Manufacturing Systems.
- Zhang, Y., Li, X., & Zhao, L. (2021). Metaheuristic-based scheduling for flexible production. Computers & Industrial Engineering.
- Zhao, R., Yan, R., & Chen, Z. (2019). Deep learning in anomaly detection for industrial systems. IEEE Access.
- Zhuang, C., Liu, J., & Xiong, H. (2021). DT-driven decision-making models. Journal of Manufacturing Systems.
- Boschert, S., & Rosen, R. (2016). Digital Twin—The Simulation Aspect. In Mechatronic Futures.
- Fuller, A., Fan, Z., Day, C., & Barlow, C. (2020). Digital Twin: Enabling Technologies, Challenges and Open Research. IEEE Access.
- Jones, D., Snider, C., Nassehi, A., Yon, J., & Hicks, B. (2020). Characterising the Digital Twin: A Systematic Literature Review. CIRP Journal of Manufacturing Science and Technology.
- Kritzinger, W., Karner, M., Traar, G., Henjes, J., & Sihn, W. (2018). Digital Twin in Manufacturing: A Categorical Literature Review and Classification. IFAC-PapersOnLine.
- Lee, J., Bagheri, B., & Kao, H. A. (2015). A Cyber-Physical Systems Architecture for Industry 4.0-based Manufacturing Systems. Manufacturing Letters.
- Madni, A. M., & Madni, C. C. (2019). Architecting Cyber Physical Systems: Digital Twin and Cognitive Twin Paradigms. Systems.