

POLITECNICO DI TORINO

Corso di Laurea Magistrale in Ingegneria Gestionale
Classe LM31 – Percorso Industria 4.0



**“Esplorazione delle sinergie tra l'Intelligenza Artificiale e la modellazione
System Dynamics in ambito supply chain e logistica”**

Relatore

Prof. Giovanni Zenezini

Candidato

Simona Bartolotta
312878

Co-relatore

Prof. Filippo Maria Ottaviani

A.A 2025/2026

Indice

1.	Introduzione.....	4
1.1	Contesto e motivazione.....	5
1.2	Obiettivi della ricerca	7
1.3	Domanda di ricerca	8
1.4	Struttura della tesi	9
2	Background teorico	10
2.1	Introduzione teorica al supply chain management	10
2.1.1	Componenti e processi della Supply Chain	11
2.1.2	Obiettivi del Supply Chain Management	12
2.1.3	Tecnologie digitali e innovazione nella SCM.....	13
2.2	Fondamenti di System Dynamics.....	14
2.2.1	Origini ed evoluzione della System Dynamics	14
2.2.2	Principi teorici della System Dynamics	16
2.2.3	Componenti principali della modellazione System Dynamics	18
2.2.4	Dinamiche tipiche nelle supply chain	20
2.2.5	Vantaggi e limiti della metodologia.....	21
2.3	Fondamenti di Artificial Intelligence e Machine Learning	24
2.3.1	Definizione e classificazioni dell'AI	24
2.3.2	Applicazioni dell'AI e del Machine Learning nella Supply Chain	27
2.3.3	Tecniche di Machine Learning maggiormente impiegate nella supply chain ...	30
2.3.4	Vantaggi e limiti del Machine Learning nella supply chain	33
2.3.5	Conclusioni	36
3	Metodologia di ricerca.....	37
3.1	Descrizione dell'approccio metodologico	37
3.2	Criteri di selezione	39
4	Risultati	41
4.1	Analisi degli articoli selezionati.....	41

4.1.1	Distribuzione temporale	41
4.1.2	Distribuzione geografica	42
4.1.3	Settore di applicazione	43
4.1.4	Analisi delle keywords e degli obiettivi	44
4.1.5	Workflow di integrazione SD-AI/ML e sinergia esplicita.....	47
4.2	Caratteristiche metodologiche	49
4.2.2	Integrazione SD e Random Forest.....	49
4.2.2	Integrazione SD e Fuzzy Logic	54
4.2.3	Integrazione SD e Deep Learning (FNN, CNN)	57
4.2.4	Integrazione SD e Machine Learning (ANN, SVM).....	59
4.2.5	Integrazione SD e Reinforcement Learning	62
5	Discussione e Conclusioni.....	65
5.1	Benefici delle combinazioni SD–AI/ML più diffuse	66
5.2	Tendenze emergenti nell'integrazione SD-AI/ML	69
5.3	Limiti e prospettive future	70
5.4	Conclusioni.....	71
	Bibliografia	72
	Sitografia	77

1. Introduzione

Nel contesto attuale, caratterizzato da elevata complessità, volatilità e interdipendenza tra fenomeni economici, ambientali e sociali, le organizzazioni sono sempre più chiamate a comprendere e governare sistemi dinamici (es. supply chain, gestione rifiuti, energia, risorse idriche). In questo scenario, la System Dynamics rappresenta un approccio consolidato per descrivere feedback, ritardi, non linearità e comportamenti emergenti nel lungo periodo. L'approccio è stato originariamente sviluppato da Jay W. Forrester negli anni '50 e si è progressivamente affermato come strumento di supporto alla comprensione e alla simulazione di sistemi socio-tecnici complessi.

Parallelamente, l'evoluzione dell'Intelligenza Artificiale e del Machine Learning ha reso disponibili strumenti sempre più avanzati per estrarre informazioni dai dati, migliorare la capacità predittiva dei modelli e supportare processi decisionali in contesti caratterizzati da elevata incertezza.

Negli ultimi anni, la letteratura scientifica ha mostrato un crescente interesse verso l'integrazione tra System Dynamics e tecniche di AI e Machine Learning, con l'obiettivo di combinare i vantaggi dei due paradigmi: da un lato la capacità esplicativa e strutturale della SD, dall'altro la capacità predittiva e di apprendimento dai dati tipica dell'AI/ML. Tuttavia, questa convergenza non è priva di criticità: aspetti quali la qualità e la disponibilità dei dati, la calibrazione dei parametri, nonché la validità e la trasferibilità dei risultati rappresentano ancora temi aperti nella letteratura.

La presente tesi si inserisce in questo filone di ricerca, proponendo una lettura strutturata dello stato dell'arte e delle principali modalità di integrazione tra System Dynamics e tecniche di AI/ML.

1.1 Contesto e motivazione

Negli ultimi anni, la crescente complessità dei sistemi organizzativi integrati e l'aumento dell'incertezza operativa hanno reso sempre più rilevante l'adozione di strumenti in grado di supportare decisioni robuste nel tempo. La letteratura evidenzia un interesse crescente verso approcci capaci di combinare la comprensione strutturale dei fenomeni con capacità predittive basate sui dati.

L'analisi condotta è basata su un dataset di articoli scientifici selezionati attraverso una revisione della letteratura, mostra come la System Dynamics (SD) venga impiegata in molteplici domini applicativi e, con frequenza crescente, venga integrata con tecniche di AI e Machine Learning (ML) attraverso workflow ibridi.

Dal punto di vista del settore, il campione analizzato evidenzia una forte presenza di contributi riconducibili agli ambiti della Supply Chain e della logistica, seguiti da settori quali waste management, waste resource management, agriculture, urban management, circular economy. Tale distribuzione suggerisce che l'integrazione tra SD e AI/ML si sviluppi soprattutto in contesti caratterizzati da dinamiche interdipendenti, vincoli operativi e necessità di valutare politiche nel lungo periodo. Particolare rilevanza emerge nei problemi tipici della supply chain e della logistica.

L'analisi per obiettivi, inoltre, conferma che le finalità più ricorrenti degli studi sono Forecasting, Optimization e Decision Support, seguite da Demand Management e Disruption Recovery. Questo risultato è coerente con la natura dei sistemi analizzati: in contesti dinamici la previsione di variabili chiave (come domanda, flussi, tassi o rischi) e l'ottimizzazione delle politiche decisionali (ad esempio politiche di riordino, allocazione delle risorse o gestione della capacità), rappresentano leve fondamentali per migliorare l'efficienza del sistema.

All'interno del campione, emergono numerosi esempi di workflow di integrazione SD-AI/ML, che mostrano come l'AI possa assumere ruoli differenti rispetto alla modellazione dinamica. In particolare, dall'analisi emergono alcune combinazioni ricorrenti:

- SD + Random Forest, utilizzata in diversi studi con finalità sia predittive sia di identificazione di pattern nei dati
- SD + Deep Learning, con applicazioni di reti CNN per il forecasting energetico e modelli RNN/LSTM per sistemi decisionali ibridi
- SD + Reinforcement Learning, impiegata per generare politiche decisionali adattive in supply chain soggette a disruption
- SD + Clustering (K-means) e altre tecniche di data mining per classificare attori o condizioni e supportare analisi predittive.

La presenza di diverse metodologie suggerisce che l'integrazione tra System Dynamics e AI/ML non segua un unico standard, ma che si sviluppa come un insieme di strategie complementari. L'intelligenza artificiale può essere utilizzata per migliorare la componente predittiva dei modelli, stimare parametri, identificare pattern di comportamento oppure ottimizzare politiche decisionali all'interno di ambienti simulativi basati su System Dynamics.

Da un lato, la SD risulta ampiamente utilizzata per comprendere sistemi complessi in diversi settori applicativi, con una presenza significativa nell'ambito della supply chain e della logistica. Dall'altro lato, le tecniche di AI e ML vengono sempre più integrate con la modellazione dinamica per rispondere a obiettivi concreti, suggerendo un approccio metodologico integrato volto a rendere i modelli più accurati, adattivi e utili per il supporto ai processi decisionali.

In questo scenario, è importante approfondire come la SD possa fungere da base strutturale per comprendere le dinamiche della supply chain e, di conseguenza, facilitare l'implementazione di soluzioni AI più efficaci e coerenti con la complessità del sistema analizzato.

1.2 Obiettivi della ricerca

L'obiettivo generale della tesi è analizzare, sulla base della letteratura selezionata, come la SD venga utilizzata per modellare sistemi complessi e in che modo la sua integrazione con tecniche di AI e ML contribuisca a migliorare capacità predittiva dei modelli e il supporto ai processi decisionali, con particolare attenzione alle applicazioni in ambito della supply chain e della logistica.

In coerenza con tale obiettivo generale, la tesi persegue i seguenti obiettivi specifici:

- mappare i principali contesti applicativi presenti nel campione analizzato
- analizzare gli obiettivi ricorrenti degli studi (forecasting, optimization, decision support, disruption recovery e demand management), mettendo in relazione finalità e contesti di applicazione
- classificare le principali combinazioni metodologiche tra System Dynamics e tecniche di AI/ML emerse nel dataset
- evidenziare benefici e criticità riportati negli studi analizzati
- individuare tendenze emergenti e prospettive future dell'integrazione tra System Dynamics e AI/ML.

1.3 Domanda di ricerca

La tesi è guidata dalla seguente domanda di ricerca:

Come può la modellazione System Dynamics essere utilizzata per simulare e comprendere le dinamiche complesse all'interno di una supply chain, e in che modo questa comprensione può facilitare l'implementazione di soluzioni basate sull'AI per migliorarne l'efficienza?

Alla luce delle evidenze emerse dall'analisi del dataset, questa domanda assume particolare rilevanza. Gli obiettivi più frequentemente analizzati nella letteratura — come forecasting e optimization — risultano infatti centrali per il miglioramento delle performance delle supply chain. Inoltre, nel campione analizzato sono presenti diversi approcci avanzati che mostrano come la simulazione basata su System Dynamics possa fungere da ambiente strutturato per progettare, testare e valutare soluzioni basate sull'intelligenza artificiale.

1.4 Struttura della tesi

La tesi è articolata come segue.

Il *Capitolo 2 – Background teorico* introduce i fondamenti della System Dynamics e dell'Intelligenza Artificiale, fornendo i concetti necessari per interpretare le modalità di integrazione osservate nella letteratura.

Il *Capitolo 3 – Metodologia di ricerca* descrive l'approccio adottato per la selezione e l'analisi degli articoli scientifici, esplicitando i criteri di inclusione e le dimensioni di classificazione considerate (contesto, obiettivi, metodologia, risultati, limiti e prospettive future).

Il *Capitolo 4 – Risultati* presenta i risultati dell'analisi del campione, includendo una sintesi degli articoli selezionati, l'analisi delle keywords e degli obiettivi di ricerca, nonché l'analisi delle principali caratteristiche metodologiche e dei workflow tra SD e AI/ML.

Il *Capitolo 5 – Discussione e conclusioni* interpreta i risultati ottenuti, discutendo i benefici delle combinazioni metodologiche più diffuse, le principali tendenze emergenti nella letteratura e i limiti degli studi analizzati, evidenziando infine alcune prospettive di ricerca future e possibili implicazioni per l'adozione di soluzioni di AI nella gestione della supply chain supportate da una comprensione sistemica fornita dalla SD.

Seguono infine Bibliografia e Sitografia, che includono materiali di dettaglio a supporto della trasparenza dell'analisi.

2 Background teorico

2.1 Introduzione teorica al supply chain management

Negli ultimi decenni, la globalizzazione dei mercati, l'innovazione tecnologica e l'aumento della pressione competitiva hanno modificato il modo in cui le imprese organizzano produzione e distribuzione. In questo scenario, è emersa con crescente evidenza la necessità di coordinare non solo le attività interne all'azienda, ma anche le relazioni con fornitori, distributori e clienti. È in questo quadro che si afferma il concetto di Supply Chain Management (SCM), inteso come approccio integrato alla gestione della filiera.

La supply chain può essere definita come l'insieme dei soggetti, delle attività e delle risorse coinvolti nella creazione e nella distribuzione di un prodotto o di un servizio, a partire dai fornitori di materie prime fino ad arrivare al consumatore finale. E' un sistema complesso che comprende tutte le fasi di approvvigionamento, produzione, movimentazione, distribuzione e vendita e le relazioni che si instaurano tra i diversi attori che partecipano a questi processi.

Secondo Mentzer et al. (2001), il Supply Chain Management consiste nel coordinamento strategico e sistematico delle funzioni aziendali, sia all'interno della singola organizzazione sia tra le imprese che fanno parte della stessa catena di fornitura, con l'obiettivo di migliorare le prestazioni complessive nel lungo periodo.

Le aziende hanno iniziato a considerare la filiera come un sistema unitario, nel quale il coordinamento tra fornitori, produttori, distributori e clienti assume un ruolo determinante. Di conseguenza, il Supply Chain Management si occupa non solo dei flussi fisici dei materiali, ma anche dei flussi informativi e finanziari che collegano i diversi soggetti coinvolti.

L'obiettivo principale dello SCM è la creazione di valore lungo l'intera catena di fornitura attraverso l'ottimizzazione dei processi e delle relazioni tra gli attori che ne fanno parte. Questo ha impatto sulla riduzione dei costi operativi, nel miglioramento del livello di servizio offerto al cliente, nella diminuzione dei tempi di consegna e nella maggiore capacità di adattamento ai cambiamenti del mercato. La competizione, quindi, non riguarda più esclusivamente le singole imprese, ma coinvolge reti organizzative sempre più integrate, chiamate a collaborare per soddisfare le esigenze dei consumatori.

2.1.1 Componenti e processi della Supply Chain

La supply chain è costituita da un insieme di attività che consentono di trasformare le materie prime in prodotti o servizi destinati al mercato. Il funzionamento efficace della filiera dipende dalla capacità di coordinare queste attività lungo tutte le fasi del processo produttivo e distributivo.

I processi della supply chain vengono distinti in attività upstream, attività interne e attività downstream. Le attività upstream comprendono le relazioni con i fornitori e l'approvvigionamento delle materie prime, la selezione dei partner commerciali e la gestione degli acquisti.

Le attività interne comprendono invece i processi di trasformazione produttiva, tra cui la pianificazione della produzione, l'assemblaggio, la gestione delle scorte e il controllo della qualità. L'efficienza di queste operazioni influisce sulle prestazioni aziendali, poiché determina il livello di utilizzo delle risorse e la capacità di ridurre sprechi e inefficienze.

Le attività downstream riguardano infine la distribuzione dei prodotti verso il mercato e includono il trasporto, il magazzinaggio, la gestione degli ordini e il servizio post-vendita. In questa fase l'obiettivo principale consiste nel garantire elevati livelli di servizio e tempi di consegna coerenti con le aspettative dei clienti.

Secondo Lambert, Cooper e Pagh (1998), il Supply Chain Management si fonda sull'integrazione di otto processi aziendali fondamentali: Customer Relationship Management, Customer Service Management, Demand Management, Order Fulfillment, Manufacturing Flow Management, Procurement, Product Development and Commercialization e Returns Management.

L'efficace coordinamento di questi processi consente alle organizzazioni di migliorare la comunicazione tra i diversi attori della filiera, aumentare la visibilità delle informazioni e ridurre le inefficienze che potrebbero compromettere le prestazioni complessive della supply chain.

2.1.2 Obiettivi del Supply Chain Management

Il Supply Chain Management mira a creare valore per il cliente e per l'impresa attraverso una gestione integrata ed efficiente dei flussi che attraversano la catena di fornitura. Per raggiungere questo risultato è necessario perseguire una serie di obiettivi collegati tra loro.

Uno degli aspetti più rilevanti riguarda il contenimento dei costi operativi. Una corretta pianificazione delle attività e una maggiore integrazione tra i soggetti coinvolti permettono di ridurre le giacenze di magazzino, ottimizzare i trasporti e utilizzare in modo più efficiente le risorse produttive.

Parallelamente, lo SCM punta a migliorare il livello di servizio offerto al cliente. In mercati caratterizzati da una crescente competitività, la capacità di garantire consegne puntuali, disponibilità dei prodotti e rapidità nella gestione degli ordini rappresenta un importante fattore di differenziazione.

Un altro obiettivo fondamentale è l'aumento della flessibilità organizzativa. Le imprese operano oggi in ambienti caratterizzati da elevata incertezza e da frequenti cambiamenti nelle preferenze dei consumatori. Una supply chain flessibile permette

di adattarsi rapidamente alle variazioni della domanda e di reagire in modo efficace a eventuali imprevisti.

Infine, il Supply Chain Management promuove la collaborazione tra tutti gli attori coinvolti nella filiera. La condivisione delle informazioni, il coordinamento delle attività e la costruzione di relazioni di lungo periodo contribuiscono a ridurre l'incertezza, migliorare l'efficienza complessiva e generare valore per tutti i soggetti partecipanti.

2.1.3 Tecnologie digitali e innovazione nella SCM

Tra le tecnologie più diffuse rientrano i sistemi ERP, che permettono di integrare in un'unica piattaforma le informazioni provenienti dalle diverse funzioni aziendali. In questo modo, le organizzazioni possono disporre di una visione più completa dei processi e migliorare il coordinamento tra le aree operative.

Un ruolo sempre più importante è svolto dall'Internet of Things (IoT), che permette di raccogliere e trasmettere dati in tempo reale attraverso sensori e dispositivi connessi. Questa tecnologia consente di monitorare costantemente merci, veicoli e magazzini, aumentando la visibilità lungo l'intera catena di fornitura.

L'analisi dei Big Data rappresenta un altro fattore di innovazione. La disponibilità di grandi quantità di dati permette alle imprese di sviluppare previsioni più accurate della domanda, identificare inefficienze e supportare decisioni strategiche basate su informazioni aggiornate e affidabili.

Anche l'intelligenza artificiale sta assumendo un ruolo sempre più rilevante nella SCM. Gli algoritmi avanzati consentono di automatizzare numerosi processi operativi, ottimizzare la pianificazione logistica e individuare potenziali criticità prima che si trasformino in problemi concreti.

2.2 Fondamenti di System Dynamics

2.2.1 Origini ed evoluzione della System Dynamics

La System Dynamics (SD) è una metodologia di modellazione e simulazione sviluppata alla fine degli anni Cinquanta da Jay W. Forrester presso il Massachusetts Institute of Technology (MIT). Essa venne concepita per analizzare il comportamento dei sistemi industriali complessi e comprendere le cause delle oscillazioni osservate nelle performance aziendali (Angerhofer & Angelides, 2000; Tako & Robinson, 2012).

L'origine della disciplina era legata all'attività di ricerca svolta da Forrester nell'ambito dell'ingegneria dei sistemi e della teoria del controllo. Il suo interesse era rivolto in particolare allo studio delle organizzazioni industriali, considerate non come insiemi di attività indipendenti, ma come sistemi caratterizzati da relazioni dinamiche tra molteplici componenti. Fenomeni come variazioni della produzione, accumuli di scorte o fluttuazioni della domanda non potevano essere spiegati osservando eventi isolati, ma richiedevano un'analisi delle interazioni tra flussi di materiali, informazioni, capitale e processi decisionali.

Un episodio che contribuì in modo significativo allo sviluppo della metodologia fu la collaborazione tra Forrester e alcuni dirigenti della General Electric. L'azienda era interessata a comprendere le forti oscillazioni occupazionali che si manifestavano in alcuni stabilimenti produttivi. Attraverso le prime simulazioni dinamiche, Forrester dimostrò che le instabilità non erano riconducibili esclusivamente a fattori esterni o alle condizioni del mercato, ma derivavano dalla struttura interna dell'organizzazione, dalle politiche gestionali adottate e dai ritardi presenti nei processi decisionali (Forrester, 1961).

Forrester definì l'Industrial Dynamics come lo studio delle caratteristiche di feedback informativo che governano le attività industriali. Le prestazioni che vengono osservate all'interno di un'organizzazione sono il risultato dell'interazione tra struttura organizzativa, flussi di informazione, processi decisionali e ritardi temporali.

Le dinamiche che emergono nel tempo quindi non sono casuali, ma derivano dalle relazioni causali che collegano le diverse componenti del sistema (Angerhofer & Angelides, 2000; Herdiani et al., 2025).

La metodologia venne formalizzata con la pubblicazione del volume “Industrial Dynamics” nel 1961, considerato ancora oggi uno dei testi fondamentali della disciplina. Parallelamente, il gruppo di ricerca del MIT sviluppò strumenti informatici dedicati alla simulazione dei sistemi dinamici. Tra questi vi furono SIMPLE (Simulation of Industrial Management Problems with Lots of Equations) e, successivamente, DYNAMO (Dynamic Models), realizzato da Phyllis Fox e Alexander Pugh. Questi strumenti resero possibile la costruzione di modelli sempre più complessi e contribuirono alla diffusione della metodologia sia in ambito accademico sia nel mondo manageriale.

A partire dagli anni Sessanta, il campo di applicazione della System Dynamics iniziò ad ampliarsi. Un primo esempio fu rappresentato dal progetto Urban Dynamics, pubblicato nel 1968 e sviluppato da Forrester in collaborazione con John Collins, ex sindaco di Boston. Lo studio applicava i principi della modellazione dinamica all'analisi dei sistemi urbani, evidenziando come fenomeni come crescita demografica, sviluppo economico e pianificazione territoriale fossero il risultato di interazioni complesse tra molte variabili.

Negli anni successivi, la metodologia venne estesa allo studio di problematiche globali. Attraverso il progetto World Dynamics, Forrester sviluppò modelli finalizzati a rappresentare le relazioni tra popolazione, risorse naturali, produzione industriale e ambiente su scala mondiale. Questi lavori contribuirono a dimostrare come la System Dynamics potesse essere utilizzata non soltanto per l'analisi delle organizzazioni, ma anche per lo studio di sistemi sociali, economici e ambientali caratterizzati da elevata complessità.

Nel corso degli anni, la SD si è progressivamente affermata come una delle principali metodologie per l'analisi dei sistemi complessi. Oggi viene applicata in numerosi ambiti, tra cui la pianificazione strategica, la sanità, l'energia, le politiche pubbliche e il supply chain management (Angerhofer & Angelides, 2000; Tako & Robinson, 2012; Khakdaman et al., 2024).

Molto rilevante è l'impiego della System Dynamics nello studio delle supply chain. Le catene di fornitura moderne sono caratterizzate da numerosi attori interconnessi, flussi continui di materiali e informazioni, oltre che da decisioni che producono effetti differiti nel tempo. La SD consente, infatti, di comprendere come le scelte effettuate a livello locale possano influenzare il comportamento complessivo della filiera e generare fenomeni emergenti difficilmente osservabili attraverso approcci tradizionali (Angerhofer & Angelides, 2000; Tako & Robinson, 2012).

2.2.2 Principi teorici della System Dynamics

La System Dynamics si fonda su una concezione dei sistemi secondo cui il comportamento osservato nel tempo deriva dalla struttura interna che collega le diverse variabili. In altre parole, eventi e risultati non vengono interpretati come fenomeni isolati, ma come manifestazioni di processi più profondi generati dalle relazioni esistenti tra gli elementi del sistema. Questo principio distingue la SD da approcci orientati esclusivamente all'analisi di eventi puntuali o di relazioni lineari di causa-effetto.

Alla base della metodologia vi è il concetto di systems thinking, ovvero una modalità di ragionamento che considera il sistema nella sua interezza e fa attenzione alle interdipendenze tra le sue componenti. Secondo questa prospettiva, ogni decisione può produrre effetti che si propagano nel tempo attraverso molteplici percorsi causali, generando conseguenze indirette, ritardate o controintuitive (Khakdaman et al., 2024).

Un elemento centrale della System Dynamics è rappresentato dai meccanismi di feedback. I sistemi complessi sono infatti caratterizzati da relazioni circolari in cui le variabili influenzano reciprocamente la propria evoluzione. Le decisioni adottate in un determinato momento modificano lo stato del sistema e, attraverso processi di retroazione, contribuiscono a influenzare le decisioni future.

La metodologia attribuisce inoltre grande importanza al ruolo dei ritardi temporali. In molti sistemi organizzativi e produttivi esiste un intervallo di tempo tra una

decisione e i suoi effetti concreti. Questi ritardi possono riguardare processi di approvvigionamento, attività produttive, trasmissione delle informazioni o meccanismi di adattamento organizzativo. Anche se vengono spesso trascurati nelle analisi tradizionali, essi rappresentano una delle principali cause di instabilità, oscillazioni e comportamenti inattesi (Angerhofer & Angelides, 2000; Herdiani et al., 2025).

Un altro principio riguarda il concetto di accumulazione. Molti fenomeni che sono osservabili nei sistemi complessi sono il risultato dell'accumulo progressivo di effetti generati nel tempo. Le scorte di magazzino, il capitale investito, la capacità produttiva o il numero di clienti rappresentano esempi di variabili che non cambiano istantaneamente, ma che si modificano gradualmente attraverso processi di accumulazione. La comprensione di questi meccanismi è essenziale per interpretare correttamente l'evoluzione del sistema e prevederne il comportamento futuro.

Inoltre, la presenza simultanea di feedback, ritardi e processi di accumulazione rende i sistemi complessi non lineari. Ciò significa che piccole variazioni in determinate condizioni possono produrre effetti molto rilevanti, mentre interventi apparentemente significativi possono avere conseguenze limitate o addirittura opposte a quelle previste. Per questo motivo, la System Dynamics fa particolare attenzione all'identificazione delle strutture causali che governano il comportamento del sistema, piuttosto che alla sola osservazione degli eventi.

Nel supply chain management, questi principi assumono una rilevanza particolare. Le catene di fornitura sono infatti caratterizzate da numerosi attori che prendono decisioni sulla base di informazioni spesso incomplete e con effetti che si manifestano soltanto dopo determinati intervalli temporali. La presenza di ritardi, accumulazioni e feedback può generare fenomeni come oscillazioni delle scorte, variazioni della capacità produttiva o amplificazione della domanda lungo la filiera. Attraverso la modellazione di questi meccanismi, la System Dynamics consente di comprendere le cause delle dinamiche osservate e di valutare l'impatto di differenti politiche gestionali.

2.2.3 Componenti principali della modellazione System Dynamics

La System Dynamics si basa su un insieme di elementi concettuali e matematici che consentono di rappresentare la struttura di un sistema e di simularne l'evoluzione nel tempo. Tra le componenti fondamentali rientrano gli stock, i flow, i feedback loop, i ritardi temporali e le variabili ausiliarie, che insieme permettono di descrivere le relazioni tra le diverse parti del sistema e di comprenderne il comportamento dinamico (Rodriguez et al., 2021; Khakdaman et al., 2024; Herdiani et al., 2025).

Gli stock sono le variabili che accumulano risorse nel tempo e che descrivono lo stato del sistema in un determinato momento, possono assumere forme diverse a seconda del contesto analizzato. Nella supply chain essi possono rappresentare le scorte di magazzino, il work in progress, il numero di ordini arretrati, la capacità produttiva disponibile o il volume di prodotti destinati al recupero e al riciclo. Poiché gli stock incorporano gli effetti delle decisioni e degli eventi passati, vengono spesso definiti come la "memoria" del sistema (Angerhofer & Angelides, 2000).

La variazione degli stock dipende dai flow, ovvero dai flussi che ne determinano l'aumento o la diminuzione. I flow descrivono il movimento di materiali, informazioni o altre risorse all'interno del sistema. In una catena di fornitura possono corrispondere ai ritmi di produzione, spedizione, vendita, approvvigionamento o gestione dei resi. L'interazione continua tra stock e flow costituisce il meccanismo attraverso cui il sistema evolve nel tempo, generando le dinamiche osservabili.

Dal punto di vista formale, la relazione tra stock e flow può essere espressa mediante equazioni differenziali che descrivono la variazione degli stock come differenza tra flussi in entrata e flussi in uscita.

In modo equivalente, il livello dello stock può essere interpretato come il risultato dell'accumulazione dei flussi netti nel corso del tempo.

Possiamo vedere come le condizioni presenti in un dato momento siano il risultato di processi sviluppatisi nel tempo e non esclusivamente di eventi recenti. Gli stock introducono inoltre una forma di inerzia nel sistema, poiché il loro contenuto può

modificarsi soltanto attraverso i flussi che li alimentano o li svuotano (Sterman, 2000).

Un ruolo importante è svolto anche dai feedback loop, ovvero dai cicli di retroazione che collegano tra loro le variabili del sistema. Attraverso tali meccanismi, gli effetti di una determinata azione possono ritornare sul sistema stesso, influenzando decisioni e comportamenti successivi. La presenza di feedback rappresenta uno degli aspetti distintivi della System Dynamics e costituisce il principale elemento che differenzia i sistemi dinamici da semplici sequenze lineari di causa-effetto.

I feedback possono assumere natura rinforzante (reinforcing loops) oppure bilanciante (balancing loops). I primi generano processi cumulativi che tendono ad amplificare il cambiamento iniziale. Un esempio è la crescita di una popolazione: un aumento del numero di individui determina un incremento delle nascite che, a sua volta, alimenta ulteriormente la crescita della popolazione stessa (Sterman, 2000). In assenza di vincoli, tali dinamiche possono produrre andamenti di tipo esponenziale.

I cicli bilancianti operano invece in direzione opposta, cercando di riportare il sistema verso una condizione di equilibrio o verso un obiettivo prestabilito. Nelle supply chain, un esempio è rappresentato dalle politiche di gestione delle scorte: quando il livello di inventario si riduce al di sotto di una soglia desiderata, vengono effettuati nuovi ordini che contribuiscono a ristabilire il livello target (Angerhofer & Angelides, 2000).

Un'altra componente della metodologia è costituita dai ritardi temporali (delays). In molti sistemi organizzativi esiste un intervallo di tempo tra il momento in cui viene presa una decisione e quello in cui i suoi effetti diventano osservabili. Nelle supply chain questi ritardi possono riguardare i tempi di approvvigionamento, la produzione, il trasporto, la trasmissione delle informazioni o l'elaborazione degli ordini. La loro presenza può alterare il comportamento del sistema, generando oscillazioni, instabilità e risultati inattesi (Tako & Robinson, 2012; Herdiani et al., 2025).

Inoltre, i modelli di System Dynamics includono variabili ausiliarie, parametri e funzioni matematiche che consentono di rappresentare regole decisionali, vincoli operativi e relazioni specifiche tra le variabili.

Dal punto di vista della rappresentazione grafica, il processo di modellazione viene sviluppato attraverso due strumenti. In una prima fase si ricorre ai Causal Loop Diagrams (CLD), che consentono di identificare le principali relazioni di causa-effetto e i cicli di feedback presenti nel sistema. Successivamente, le relazioni vengono tradotte negli Stock and Flow Diagrams (SFD), che introducono una rappresentazione quantitativa delle variabili e permettono di effettuare simulazioni numeriche del comportamento del sistema nel tempo (Rodriguez et al., 2021; Herdiani et al., 2025).

2.2.4 Dinamiche tipiche nelle supply chain

La supply chain costituisce uno degli ambiti in cui la System Dynamics ha trovato maggiore applicazione. La presenza di molteplici attori interconnessi, la circolazione continua di materiali e informazioni, i ritardi nei processi decisionali e le numerose relazioni di feedback rendono le catene di fornitura sistemi particolarmente complessi da analizzare attraverso approcci tradizionali (Angerhofer & Angelides, 2000; Tako & Robinson, 2012).

Tra i fenomeni maggiormente studiati in letteratura vi è il bullwhip effect, ovvero l'amplificazione progressiva della variabilità della domanda lungo i diversi livelli della filiera. Piccole oscillazioni nella domanda proveniente dal mercato finale possono trasformarsi in variazioni molto più accentuate negli ordini trasmessi ai fornitori situati a monte della catena. Questo fenomeno può essere generato da molti fattori, tra cui ritardi informativi, previsioni inaccurate, politiche di riordino non coordinate e comportamenti opportunistici da parte degli attori coinvolti (Angerhofer & Angelides, 2000; Tako & Robinson, 2012).

Un'altra area di applicazione riguarda la gestione delle scorte. Le decisioni relative ai livelli di inventario dipendono da molteplici fattori, tra cui domanda prevista, lead time, costi di mantenimento e obiettivi di servizio. Anche se queste decisioni sono generalmente finalizzate a garantire la disponibilità dei prodotti, la loro interazione con ritardi e informazioni incomplete può generare fenomeni di sovra scorta, carenze di inventario o oscillazioni dei livelli di magazzino (Angerhofer & Angelides, 2000).

Inoltre, le stime della domanda futura influenzano direttamente le decisioni di approvvigionamento, produzione e distribuzione, i risultati ottenuti modificano le aspettative degli operatori e incidono sulle previsioni successive. Si crea così un processo circolare in cui le decisioni attuali contribuiscono a definire le condizioni future del sistema. La System Dynamics consente di analizzare questi meccanismi nel medio e lungo periodo, evidenziando gli effetti delle diverse politiche previsionali sulle performance della supply chain (Tako & Robinson, 2012).

Negli ultimi anni, è stata dedicata particolare attenzione anche allo studio della resilienza delle catene di fornitura. Infatti, eventi come la pandemia di COVID-19, le crisi geopolitiche e le interruzioni dei trasporti internazionali hanno evidenziato la vulnerabilità delle reti globali di approvvigionamento. La System Dynamics è stata utilizzata per analizzare la capacità delle supply chain di adattarsi a shock improvvisi e recuperare condizioni operative stabili.

2.2.5 Vantaggi e limiti della metodologia

A differenza di approcci che si concentrano su singoli processi o su specifiche funzioni aziendali, la SD consente di rappresentare simultaneamente attori, flussi, politiche decisionali e relazioni causali, evidenziando le connessioni che esistono tra le diverse componenti del sistema (Rodriguez et al., 2021; Khakdaman et al., 2024). Questo permette di superare una lettura frammentata dei problemi e di comprendere come determinate criticità possono emergere dall'interazione tra molteplici fattori piuttosto che da una singola causa identificabile.

Un altro vantaggio riguarda la capacità della metodologia di analizzare fenomeni dinamici che si sviluppano nel tempo. Molti problemi tipici delle supply chain, come le oscillazioni delle scorte, il bullwhip effect o le difficoltà di recupero dopo una disruption, sono il risultato di processi che coinvolgono feedback e ritardi temporali difficilmente osservabili attraverso strumenti statici di analisi. In questi contesti, la simulazione dinamica consente di ricostruire le relazioni che generano questi comportamenti e di comprenderne le cause (Angerhofer & Angelides, 2000; Tako & Robinson, 2012).

Inoltre, la metodologia attraverso la costruzione di modelli simulativi consente di valutare in anticipo gli effetti di strategie alternative senza intervenire direttamente sul sistema reale. Ciò permette di confrontare diversi scenari operativi, testare nuove politiche gestionali e analizzare possibili conseguenze indesiderate prima della loro implementazione effettiva.

Un aspetto che spesso viene evidenziato in letteratura riguarda la flessibilità della System Dynamics nella rappresentazione di fattori difficilmente quantificabili. Oltre alle variabili operative, i modelli possono includere elementi come le percezioni manageriali, regole decisionali, obiettivi strategici e vincoli organizzativi. Questo consente di integrare dimensioni qualitative e quantitative all'interno di un'unica struttura analitica, ampliando le possibilità di applicazione della metodologia a problemi strategici e di policy (Angerhofer & Angelides, 2000; Tako & Robinson, 2012).

La letteratura evidenzia anche alcune limitazioni. Una delle principali riguarda il livello di aggregazione dei modelli di System Dynamics. Generalmente, la metodologia descrive il comportamento complessivo del sistema attraverso variabili aggregate e relazioni medie, piuttosto che attraverso la rappresentazione dettagliata di singole entità o eventi discreti (Tako & Robinson, 2012). Di conseguenza, può risultare meno adatta in situazioni in cui è necessario analizzare nel dettaglio processi operativi specifici, fenomeni di coda, allocazioni di risorse o interazioni che avvengono a livello micro. In questi casi, approcci come la Discrete Event Simulation possono offrire una rappresentazione più accurata delle dinamiche operative.

Un'altra criticità riguarda la dipendenza dei risultati dalle ipotesi formulate durante la fase di modellazione. La costruzione di un modello SD richiede infatti l'identificazione delle principali relazioni causali, dei parametri di funzionamento e delle regole decisionali che governano il sistema. La qualità delle simulazioni dipende quindi dalla correttezza di queste assunzioni e dalla disponibilità di informazioni affidabili per la calibrazione del modello (Rodriguez et al., 2021; Khakdaman et al., 2024). In contesti complessi, la raccolta di dati adeguati può rappresentare una sfida significativa e può influire sulla validità delle conclusioni ottenute.

Vi sono inoltre alcune difficoltà nella rappresentazione del comportamento individuale degli attori e delle interazioni che avvengono a livello micro. Sebbene la SD sia particolarmente efficace nell'analisi di fenomeni aggregati, tende a descrivere gli individui o le organizzazioni attraverso comportamenti medi e regole generali. Per questo motivo, è meno indicata quando l'obiettivo è studiare processi caratterizzati da elevata eterogeneità degli agenti o da comportamenti emergenti derivanti dalle loro interazioni dirette (Camur et al., 2023; Korder et al., 2024).

Un aspetto metodologico particolarmente rilevante riguarda infine il processo di raccolta e interpretazione dei dati necessari alla costruzione del modello. Secondo Forrester (1961), le informazioni utilizzate nella System Dynamics possono essere ricondotte a tre categorie principali: dati numerici, dati scritti e dati mentali. I primi comprendono serie storiche, database e indicatori quantitativi, i secondi includono documentazione aziendale, procedure operative e report e i terzi fanno riferimento alle conoscenze implicite degli attori coinvolti, come esperienze, percezioni e regole decisionali non formalizzate. La combinazione di queste diverse fonti consente di rappresentare aspetti del sistema che difficilmente emergerebbero da una semplice analisi quantitativa (Sternan, 2000).

Nel complesso, la System Dynamics è una metodologia particolarmente efficace per lo studio delle supply chain e dei sistemi complessi in generale. La sua capacità di rappresentare feedback, ritardi e processi di accumulazione la rende uno strumento

valido per comprendere le dinamiche di lungo periodo e supportare la formulazione di politiche gestionali più consapevoli.

2.3 Fondamenti di Artificial Intelligence e Machine Learning

2.3.1 Definizione e classificazioni dell'AI

L'intelligenza artificiale (AI) è diventata una delle tecnologie più influenti nei processi di trasformazione digitale delle aziende e delle supply chain. La letteratura identifica l'AI come l'insieme di sistemi informatici in grado di svolgere attività che normalmente richiederebbero capacità cognitive umane, quali apprendimento, ragionamento, riconoscimento di schemi, previsione e supporto alle decisioni (Walter et al., 2025; Spreitzenbarth et al., 2024; Boute & Udenio, 2021).

L'intelligenza artificiale può essere descritta come l'utilizzo combinato di algoritmi, dati e capacità computazionale per riconoscere pattern, acquisire conoscenza dall'esperienza e supportare la risoluzione di problemi complessi in contesti caratterizzati da elevata incertezza (Walter et al., 2025). Inoltre, l'AI viene associata alla capacità di una macchina di simulare alcune funzioni che tipicamente vengono attribuite all'intelligenza umana, tra cui l'apprendimento, il ragionamento, la pianificazione e l'adattamento a situazioni nuove. I sistemi intelligenti sono infatti progettati per raccogliere informazioni dall'ambiente, elaborarle e trasformarle in azioni o decisioni coerenti con gli obiettivi assegnati.

Le origini dell'AI come disciplina scientifica risalgono alla metà del Novecento. Nonostante le basi teoriche siano riconducibili ai lavori di Alan Turing, considerato uno dei fondatori dell'informatica moderna, il momento che segna la nascita ufficiale dell'AI è il “Dartmouth Summer Research Project” del 1956. In quell'occasione venne introdotto per la prima volta il termine “Artificial Intelligence” e si sviluppò l'idea che le capacità cognitive umane potessero essere replicate attraverso modelli computazionali.

Un contributo fondamentale fu fornito proprio da Turing, che nel 1950 pubblicò l'articolo "Computing Machinery and Intelligence". In questo lavoro veniva proposto il cosiddetto "Turing Test", secondo cui una macchina può essere considerata intelligente se il suo comportamento risulta indistinguibile da quello umano durante un'interazione osservata da un valutatore esterno. Anche se questo criterio è ancora oggi oggetto di dibattito, esso rappresenta uno dei primi tentativi di definire operativamente il concetto di intelligenza artificiale.

Nel corso della sua evoluzione, l'AI ha attraversato diverse fasi di sviluppo, caratterizzate dall'emergere di approcci teorici differenti. I primi studi si concentravano prevalentemente sulla logica simbolica e sulla rappresentazione esplicita della conoscenza, mentre successivamente si sono affermati sistemi esperti, reti neurali artificiali e tecniche basate sull'apprendimento automatico. Le capacità computazionali disponibili nei primi decenni erano limitate e questo ha rallentato il progresso della disciplina, contribuendo a periodi di ridotto interesse e investimenti, spesso definiti nella letteratura come "AI winters".

Da un punto di vista concettuale, la letteratura distingue tra Intelligenza Artificiale forte e Intelligenza Artificiale debole. La prima fa riferimento all'ipotesi teorica di sviluppare sistemi dotati di capacità cognitive equivalenti a quelle umane, inclusa la coscienza e la comprensione autonoma. La seconda, invece, riguarda sistemi progettati per svolgere compiti specifici senza possedere una reale consapevolezza. Quest'ultima forma di AI ha trovato un'applicazione concreta in ambito industriale e manageriale, diventando la base delle moderne soluzioni utilizzate nelle organizzazioni.

Si può affermare che l'evoluzione delle tecnologie digitali e l'aumento della disponibilità di dati hanno progressivamente ampliato il numero di applicazioni dell'AI. Oggi questa non viene più considerata una tecnologia unica e omogenea, ma un insieme articolato di strumenti e approcci differenti. In questa prospettiva, Walter et al. (2025) propongono una classificazione basata sulle funzioni svolte dai sistemi intelligenti.

La prima categoria è rappresentata dalla "descriptive AI", finalizzata alla raccolta, organizzazione e sintesi delle informazioni disponibili. A un livello più avanzato vi è

la “predictive AI”, che utilizza dati storici e algoritmi di apprendimento per individuare pattern e formulare previsioni di eventi futuri. In aggiunta, si ha la “prescriptive AI”, orientata a suggerire decisioni o azioni ottimali sulla base degli scenari analizzati. Infine, la “cognitive AI” che comprende sistemi caratterizzati da maggiore autonomia e capacità di apprendimento, in grado di elaborare anche dati non strutturati e adattarsi dinamicamente ai cambiamenti dell’ambiente operativo.

All’interno dell’ecosistema dell’intelligenza artificiale, il Machine Learning (ML) rappresenta oggi una delle tecnologie maggiormente utilizzate nelle applicazioni aziendali. Il Machine Learning può essere definito come l’insieme di tecniche che consentono ai sistemi informatici di apprendere dai dati e migliorare progressivamente le proprie prestazioni senza essere programmati per ogni singolo compito (Spreitzenbarth et al., 2024; Walter et al., 2025; Gidiagba et al., 2025). Il ML costituisce uno dei principali sottocampi dell’AI, focalizzato sull’apprendimento automatico attraverso l’analisi dei dati.

Si distinguono generalmente tre principali paradigmi di apprendimento automatico. Il primo è il “supervised learning”, nel quale gli algoritmi vengono addestrati utilizzando dati etichettati, ovvero osservazioni per cui è noto il risultato corretto. Questo approccio è particolarmente diffuso nei problemi di classificazione e previsione. Il secondo è “unsupervised learning”, che opera invece su dati privi di etichette e mira a individuare strutture nascoste, segmentazioni o anomalie all’interno dei dataset. Il terzo paradigma è il “reinforcement learning”, in cui un agente apprende attraverso l’interazione continua con l’ambiente, migliorando le proprie decisioni sulla base di un sistema di ricompense e penalità. A differenza degli altri approcci, il reinforcement learning si sviluppa in modo dinamico attraverso un processo iterativo di prova ed errore.

Un ulteriore sviluppo del Machine Learning è rappresentato dal Deep Learning (DL), alla base di molte delle applicazioni di AI più avanzate. Il Deep Learning utilizza reti neurali artificiali caratterizzate da molteplici livelli di elaborazione, capaci di apprendere automaticamente rappresentazioni sempre più complesse dei dati.

Questo approccio si è affermato grazie alla disponibilità di grandi quantità di dati e all'aumento della potenza computazionale, che hanno reso possibile l'addestramento di modelli sempre più sofisticati.

Tra le principali architetture di Deep Learning si hanno le “Convolutional Neural Networks” (CNN), particolarmente efficaci nell'elaborazione di immagini e dati visivi, le “Recurrent Neural Networks” (RNN), sviluppate per l'analisi di sequenze temporali e dati dinamici e le reti “Long Short-Term Memory” (LSTM), progettate per migliorare la capacità di apprendere dipendenze temporali di lungo periodo.

Comprendere le differenze tra Artificial Intelligence, Machine Learning e Deep Learning rappresenta un elemento fondamentale per analizzarne correttamente le applicazioni e le potenzialità. Come evidenziato da Spreitzenbarth et al. (2024), una distinzione chiara tra questi concetti consente di evitare ambiguità interpretative e di individuare le tecnologie effettivamente impiegate nei diversi contesti operativi.

Nel caso delle supply chain, questa distinzione assume particolare rilevanza, in quanto le diverse tecniche di AI possono supportare attività molto differenti, che spaziano dalla previsione della domanda all'ottimizzazione delle scorte, dalla pianificazione della produzione alla gestione dei rischi lungo la catena di fornitura.

2.3.2 Applicazioni dell'AI e del Machine Learning nella Supply Chain

Dall'analisi della letteratura emerge come l'Intelligenza Artificiale (AI) e il Machine Learning (ML) stiano assumendo un ruolo sempre più rilevante all'interno dei processi di supply chain, sia a livello strategico che a livello operativo. Tali tecnologie vengono adottate con l'obiettivo di migliorare la qualità delle decisioni, aumentare la capacità di risposta ai cambiamenti del contesto, ottimizzare l'impiego delle risorse e rafforzare aspetti come resilienza, sostenibilità e visibilità lungo l'intera catena di fornitura (Culot et al., 2024; Khedr & Rani, 2024; Polo-Triana et al., 2024).

Tra gli ambiti applicativi più analizzati in letteratura vi è la previsione della domanda e il demand planning. Numerosi studi evidenziano come gli algoritmi di ML siano in grado di elaborare grandi quantità di dati storici insieme a informazioni provenienti da fonti esterne, come condizioni meteorologiche, promozioni commerciali, eventi di calendario, dati di mercato e contenuti generati sui social media. Questa capacità consente di ottenere previsioni generalmente più accurate rispetto agli approcci tradizionali. Infatti, gli studiosi osservano che gran parte della ricerca sull'AI applicata al demand planning si concentra sullo sviluppo di strumenti predittivi basati su tecniche di Machine Learning e Deep Learning per la previsione della domanda di prodotti finiti, componenti e dei flussi di reso (Walter et al., 2025; Khedr & Rani, 2024; Boute & Udenio, 2021).

Un altro ambito rilevante riguarda la gestione delle scorte. Le tecniche di ML vengono utilizzate per determinare livelli di inventario più efficienti, ridurre il rischio di eccessi o carenze di stock, migliorare la rotazione dei magazzini e supportare politiche di riapprovvigionamento maggiormente dinamiche e adattive (Khedr & Rani, 2024; Polo-Triana et al., 2024).

Le applicazioni dell'AI e del ML si estendono inoltre alla gestione dei fornitori. Molti papers mostrano come queste tecnologie possano supportare i processi di valutazione, classificazione e selezione dei supplier attraverso l'analisi simultanea di molteplici criteri, tra cui costo, qualità, affidabilità, sostenibilità e livello di rischio (Gidiagba et al., 2025; Khedr & Rani, 2024; Polo-Triana et al., 2024). In molti casi, gli algoritmi di Machine Learning vengono integrati con metodologie multicriterio già consolidate, contribuendo a rendere le decisioni più oggettive e robuste.

Un'ulteriore area di sviluppo riguarda la logistica e il trasporto. In questo ambito, l'AI viene utilizzata nella previsione dei tempi di consegna, nell'ottimizzazione dei percorsi, nella gestione dinamica delle spedizioni e nel coordinamento delle attività operative in tempo reale, con effetti positivi sia sull'efficienza sia sulla riduzione dei costi logistici (Boute & Udenio, 2021; Khedr & Rani, 2024; Culot et al., 2024).

Boute e Udenio (2021), ad esempio, riportano diversi casi di utilizzo di algoritmi di supervised learning per stimare gli Estimated Time of Arrival (ETA), i tempi di attraversamento delle dogane e i tempi di fermo delle attrezzature, oltre che ad applicazioni di reinforcement learning per la gestione di sistemi di replenishment multi-source, il collaborative shipping e il controllo di inventari caratterizzati da elevata deperibilità.

Inoltre, vi è un interesse crescente per l'impiego del ML nei processi produttivi e nella manutenzione predittiva, gli algoritmi vengono utilizzati per monitorare le condizioni operative degli impianti, prevedere possibili guasti e ridurre i tempi di fermo, contribuendo anche al miglioramento della qualità dei processi e dei prodotti (Culot et al., 2024; Khedr & Rani, 2024).

L'utilizzo dell'AI risulta sempre più diffuso anche nell'ambito della gestione del rischio e della resilienza della supply chain. Gli algoritmi vengono utilizzati per individuare anomalie, anticipare possibili interruzioni operative, simulare scenari alternativi e supportare decisioni tempestive in contesti caratterizzati da elevata incertezza o volatilità (Culot et al., 2024; Walter et al., 2025; Polo-Triana et al., 2024).

Un ulteriore filone di ricerca riguarda il contributo dell'AI alla sostenibilità della supply chain. Le applicazioni descritte in letteratura comprendono la riduzione degli sprechi, l'ottimizzazione dei consumi energetici, il miglioramento della tracciabilità dei flussi, il supporto ai modelli di economia circolare e l'integrazione di criteri ESG nei processi di selezione di fornitori e partner logistici (Culot et al., 2024; Patalas-Maliszewska et al., 2024; Delgado et al., 2025). Nonostante le potenzialità riconosciute, diversi autori sottolineano come la diffusione di queste soluzioni sia ancora ostacolata da problematiche legate alla disponibilità e qualità dei dati, alla mancanza di standard condivisi, ai costi di implementazione e alla carenza di competenze specialistiche (Patalas-Maliszewska et al., 2024; Delgado et al., 2025).

Nel complesso, si può affermare che AI e Machine Learning non rappresentano solo strumenti destinati a specifiche attività operative, ma costituiscono delle tecnologie in grado di trasformare progressivamente l'intero funzionamento della supply chain.

L'effetto principale di questa evoluzione consiste nel passaggio verso sistemi sempre più predittivi, adattivi e interconnessi, capaci di supportare processi decisionali più efficaci e una maggiore capacità di risposta alle dinamiche del contesto competitivo (Boute & Udenio, 2021; Culot et al., 2024; Khedr & Rani, 2024).

2.3.3 Tecniche di Machine Learning maggiormente impiegate nella supply chain

Tra le tecniche maggiormente utilizzate in ambito supply chain management possiamo trovare le Artificial Neural Networks (ANN), considerate uno degli strumenti più versatili per affrontare problemi di previsione, classificazione e riconoscimento di pattern complessi. La loro efficacia deriva dalla capacità di modellare relazioni non lineari tra variabili di input e output, caratteristica particolarmente utile nei contesti operativi della supply chain, spesso caratterizzati da elevata complessità e da numerosi fattori interdipendenti (Khedr & Rani, 2024; Gidiagba et al., 2025). Allo stesso tempo, uno dei principali limiti delle reti neurali riguarda la ridotta interpretabilità dei risultati, poiché il processo attraverso cui il modello giunge a una determinata decisione risulta spesso difficilmente comprensibile.

Nell'ambito delle applicazioni basate sui dati temporali assumono particolare importanza le Recurrent Neural Networks (RNN) e le Long Short-Term Memory (LSTM). Queste architetture sono state progettate per elaborare informazioni sequenziali e per catturare le dipendenze temporali presenti nei dati, rendendole particolarmente adatte alla previsione della domanda e ad altri problemi caratterizzati da dinamiche evolutive nel tempo. Le LSTM rappresentano la soluzione più frequentemente adottata nelle attività di demand planning, soprattutto quando la domanda presenta andamenti irregolari. La loro capacità di conservare informazioni rilevanti anche su orizzonti temporali estesi consente di ottenere risultati superiori rispetto a molti modelli previsionali tradizionali (Walter et al., 2025; Khedr & Rani, 2024).

Inoltre, si osserva una crescente diffusione delle Convolutional Neural Networks (CNN), soprattutto nei contesti in cui la gestione della supply chain coinvolge dati visivi o segnali complessi. Questi modelli vengono applicati, ad esempio, nel controllo qualità automatizzato, nell'identificazione di difetti di produzione e in alcune attività logistiche avanzate (Khedr & Rani, 2024). Nonostante il loro impiego nella previsione della domanda sia meno diffuso rispetto alle LSTM, queste tecniche vengono considerate particolarmente promettenti per il monitoraggio dei processi produttivi e il miglioramento della qualità operativa.

Tra gli algoritmi tradizionali possiamo trovare le Support Vector Machines (SVM), utilizzate sia per problemi di classificazione sia di regressione, le SVM sono efficaci in contesti caratterizzati da elevata dimensionalità e da dataset relativamente limitati. Le loro applicazioni includono la selezione dei fornitori, la previsione della domanda e la valutazione del rischio lungo la supply chain (Gidiagba et al., 2025; Khedr & Rani, 2024).

Un'altra categoria rilevante comprende i Decision Trees (DT) e i metodi basati su alberi decisionali, tra cui Random Forest (RF) ed Extreme Gradient Boosting (XGBoost). I Decision Trees sono apprezzati per la loro semplicità interpretativa, che consente di comprendere facilmente il processo decisionale seguito dal modello. Questi algoritmi trovano applicazione in numerosi contesti, tra cui la classificazione dei fornitori, la gestione del rischio e la previsione della domanda.

Per quanto riguarda gli approcci di unsupervised learning, la tecnica maggiormente citata è il K-means clustering. Questo algoritmo consente di suddividere prodotti, clienti o fornitori in gruppi omogenei sulla base di caratteristiche comuni, supportando attività di segmentazione e analisi esplorativa dei dati (Boute & Udenio, 2021; Khedr & Rani, 2024).

Walter et al. (2025) evidenziano come le tecniche di clustering svolgano un ruolo importante in attività complementari, come la riduzione della dimensionalità e l'individuazione di pattern nascosti nei dati. Boute e Udenio (2021), invece, ne sottolineano l'utilità per applicazioni di customer segmentation, product segmentation e anomaly detection.

Oltre ai modelli predittivi tradizionali, la ricerca mostra un crescente interesse verso gli algoritmi evolutivi e le tecniche di ottimizzazione ispirate ai processi biologici. Tra queste, gli algoritmi genetici rappresentano una delle soluzioni più diffuse per affrontare problemi di ottimizzazione combinatoria complessi. Attraverso meccanismi che richiamano i processi di selezione naturale, ricombinazione e mutazione, questi algoritmi esplorano progressivamente le possibili soluzioni fino a individuare configurazioni ottimali o quasi ottimali. Nell'ambito della supply chain, trovano applicazione soprattutto nei problemi di scheduling, ottimizzazione dei percorsi, allocazione delle risorse e progettazione delle reti logistiche.

Infine, un'attenzione sempre crescente è rivolta al Reinforcement Learning (RL), considerato particolarmente adatto ai problemi decisionali dinamici e sequenziali. A differenza delle tecniche di apprendimento orientate esclusivamente alla previsione, il RL mira a identificare le azioni che massimizzano una ricompensa futura attraverso l'interazione continua con un ambiente dinamico (Boute & Udenio, 2021; Khedr & Rani, 2024). Le principali applicazioni riguardano il controllo delle scorte, il replenishment, l'ottimizzazione dei percorsi e la gestione adattiva dei processi decisionali in condizioni di incertezza. L'apprendimento avviene attraverso un processo iterativo di trial-and-error, nel quale un agente affina progressivamente la propria strategia sulla base dei risultati ottenuti. Tuttavia, diversi autori sottolineano come questi approcci richiedano elevate quantità di dati e notevoli risorse computazionali, fattori che possono limitarne l'adozione in contesti reali.

Nel complesso, la letteratura suggerisce che le tecniche di Machine Learning maggiormente utilizzate nella supply chain possano essere ricondotte a reti neurali artificiali, modelli ricorrenti e LSTM, support vector machines, alberi decisionali, tecniche di clustering e approcci basati sul reinforcement learning.

La scelta della soluzione più appropriata dipende dalle caratteristiche del problema da affrontare, dalla disponibilità e qualità dei dati, dai vincoli computazionali e dal livello di interpretabilità richiesto dal contesto decisionale (Culot et al., 2024; Walter et al., 2025; Khedr & Rani, 2024).

2.3.4 Vantaggi e limiti del Machine Learning nella supply chain

Uno dei principali vantaggi del Machine Learning riguarda il miglioramento delle capacità previsionali. I modelli di Machine Learning consentono infatti di intercettare relazioni complesse e non lineari tra variabili, difficilmente identificabili attraverso approcci statistici tradizionali, soprattutto quando si lavora con grandi volumi di dati e con informazioni provenienti da fonti eterogenee (Walter et al., 2025; Khedr & Rani, 2024). Questo si traduce in previsioni della domanda più accurate, in una pianificazione delle scorte più efficiente e in una maggiore capacità di anticipare criticità operative.

In numerosi studi questi modelli risultano particolarmente efficaci in contesti caratterizzati da elevata volatilità o da pattern di domanda irregolari, dove i metodi convenzionali tendono a mostrare prestazioni inferiori.

Accanto al miglioramento della previsione, la letteratura evidenzia anche un significativo incremento dell'efficienza operativa. L'utilizzo del Machine Learning consente di automatizzare attività ripetitive, velocizzare i processi decisionali e ottimizzare l'impiego delle risorse lungo l'intera catena logistica (Culot et al., 2024; Boute & Udenio, 2021). Ne derivano benefici concreti in termini di riduzione dei costi, miglioramento della qualità del servizio, diminuzione dei lead time e maggiore flessibilità operativa. Il ML contribuisce a ottimizzare simultaneamente diverse funzioni della supply chain, tra cui inventario, trasporti, produzione e manutenzione, con un impatto complessivo positivo sulla competitività aziendale (Khedr & Rani, 2024).

Un ulteriore vantaggio è rappresentato dal contributo alla resilienza e all'adattività dei sistemi di supply chain. Grazie alla capacità di elaborare dati in tempo reale e di integrare fonti informative eterogenee, il Machine Learning supporta le organizzazioni nell'identificazione tempestiva di anomalie, interruzioni e variazioni del contesto esterno, facilitando risposte più rapide e informate (Culot et al., 2024; Walter et al., 2025). In questo senso, il ML non si limita a migliorare la previsione degli eventi futuri, ma agisce anche come abilitatore di decisioni dinamiche in ambienti caratterizzati da incertezza.

Nonostante i benefici elencati, la letteratura evidenzia diversi limiti che ne rallentano l'adozione su larga scala. Il più ricorrente riguarda la dipendenza dalla qualità dei dati. Il principio del “garbage in, garbage out” sottolinea come dati incompleti, incoerenti o poco affidabili compromettano inevitabilmente la qualità dei risultati prodotti dai modelli, anche quando questi siano particolarmente sofisticati (Culot et al., 2024). Di conseguenza, la disponibilità, la pulizia e l'integrazione dei dati rappresentano una delle principali barriere all'implementazione del Machine Learning nelle supply chain reali (Walter et al., 2025; Khedr & Rani, 2024).

Inoltre, l'integrazione di soluzioni basate su Machine Learning nei sistemi aziendali esistenti richiede infrastrutture tecnologiche adeguate, capacità computazionali elevate e una buona integrazione tra piattaforme, oltre a significativi sforzi in termini di sviluppo, manutenzione e aggiornamento continuo dei modelli (Culot et al., 2024; Khedr & Rani, 2024). Tali aspetti comportano spesso costi rilevanti, che possono risultare particolarmente onerosi per le imprese di dimensioni medio-piccole (Walter et al., 2025).

Un limite aggiuntivo è legato alla scarsa interpretabilità di alcuni modelli, in particolare delle reti neurali profonde. Il cosiddetto black box effect rende infatti difficile comprendere in modo trasparente il processo attraverso cui il modello arriva a una determinata previsione o decisione (Culot et al., 2024; Khedr & Rani, 2024). Questo può ridurre la fiducia da parte dei decision maker e ostacolare l'adozione in contesti manageriali, soprattutto quando le decisioni supportate dagli algoritmi hanno un impatto rilevante sulle performance aziendali.

L'efficace utilizzo del Machine Learning richiede, inoltre, profili professionali in grado di combinare competenze analitiche, conoscenze tecniche e una solida comprensione dei processi di supply chain (Culot et al., 2024; Walter et al., 2025). La scarsità di tali figure e la necessità di aggiornamento continuo contribuiscono a rallentare la diffusione di queste tecnologie.

A queste criticità si aggiungono infine considerazioni di natura etica e organizzativa, tra cui il rischio di bias nei dati, questioni legate alla privacy e alla governance delle informazioni, oltre a possibili resistenze culturali all'adozione di sistemi automatizzati. In particolare, quando il Machine Learning viene applicato a decisioni sensibili, come la selezione dei fornitori o la gestione del rischio, eventuali distorsioni nei dati possono tradursi in risultati non equi o potenzialmente discriminatori (Gidiagba et al., 2025; Delgado et al., 2025; Culot et al., 2024).

Ulteriori limiti si hanno in relazione ai costi computazionali e alla complessità di addestramento, soprattutto nei modelli di Deep Learning e Reinforcement Learning. L'addestramento di reti neurali profonde richiede infatti risorse hardware significative, oltre a tempi di elaborazione elevati. Nel caso del Reinforcement Learning, una criticità rilevante è rappresentata dalla necessità di un numero molto elevato di interazioni con l'ambiente per apprendere politiche efficaci.

Questo comporta tempi di addestramento potenzialmente lunghi e costi computazionali elevati, che possono variare da ore fino a settimane nei casi più complessi.

Oltre agli aspetti computazionali, il Reinforcement Learning presenta anche difficoltà legate alla fase di modellazione del problema. Una formulazione non corretta della funzione di ricompensa può orientare l'agente verso comportamenti non desiderati o non coerenti con gli obiettivi aziendali, rendendo necessario un processo iterativo di sperimentazione e validazione prima di ottenere risultati affidabili.

Il Machine Learning può offrire benefici significativi in termini di accuratezza previsionale, efficienza operativa e capacità di adattamento della supply chain. Tali benefici, tuttavia, dipendono da condizioni precise, tra cui la qualità dei dati disponibili, la maturità tecnologica dell'organizzazione e la presenza di competenze adeguate (Culot et al., 2024; Walter et al., 2025; Khedr & Rani, 2024).

2.3.5 Conclusioni

Dall'analisi della letteratura emerge come la System Dynamics e l'Artificial Intelligence, offrono contributi differenti ma tra loro complementari allo studio e alla gestione delle supply chain. La System Dynamics consente di rappresentare la struttura causale dei sistemi complessi. Questa mette in evidenza i meccanismi di feedback e i ritardi che determinano il comportamento del sistema nel lungo periodo. L'AI e il ML, permettono invece di estrarre conoscenza da grandi quantità di dati, migliorare l'accuratezza delle previsioni e supportare i processi decisionali attraverso modelli capaci di riconoscere pattern, apprendere dall'esperienza e adattarsi a contesti dinamici.

Alla luce di questo, risulta utile studiare approcci integrati. Infatti, questi sono capaci di combinare la System Dynamics, che aiuta a comprendere la struttura e il comportamento della supply chain, con le tecniche di intelligenza artificiale, che permettono di analizzare i dati, migliorare le previsioni e supportare le decisioni. Questa integrazione offre quindi una base efficace per affrontare la crescente complessità delle moderne catene di fornitura.

3 Metodologia di ricerca

Nel presente lavoro si esegue una revisione strutturata della letteratura, finalizzata a comprendere in che modo la System Dynamics venga integrata con tecniche di Intelligenza artificiale o Machine Learning nei contesti di supply chain e logistica. L'obiettivo non è soltanto censire i contributi esistenti, ma individuare i principali pattern di integrazione e le finalità per cui tali integrazioni vengono impiegate.

In questo capitolo si illustrerà in modo approfondito la metodologia adottata per la revisione della letteratura pertinente agli obiettivi della ricerca. In particolare, verranno descritti il processo di individuazione e selezione degli articoli rilevanti, i database consultati e i criteri di inclusione ed esclusione applicati.

3.1 Descrizione dell'approccio metodologico

Per rendere il processo di selezione chiaro e verificabile, la revisione è stata organizzata secondo la logica del framework PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*), impiegato come linee guida per revisioni sistematiche. PRISMA è un riferimento metodologico che aiuta a descrivere in modo ordinato come si passa da un insieme iniziale di pubblicazioni individuate tramite ricerca ad un insieme finale di lavori effettivamente inclusi.

In coerenza con tale impostazione, la selezione è stata condotta in tre fasi successive.

La prima fase consiste nell'individuazione preliminare dei contributi.

È stato costruito un primo insieme di articoli potenzialmente pertinenti attraverso una ricerca basata su parole chiave riconducibili ai due pilastri metodologici (SD e AI/ML) e al dominio applicativo (supply chain/ logistica).

Nella seconda fase ho condotto una valutazione iniziale su titolo e abstract.

Gli articoli individuati sono stati sottoposti ad una prima verifica di pertinenza tramite la lettura di titolo, parole chiave e abstract. In questa fase mi sono concentrata in particolar modo sulla presenza di due elementi chiave: la presenza effettiva della SD come metodo di modellazione o simulazione e l'adozione esplicita di tecniche AI/ML. Questo passaggio mi ha consentito di ridurre il corpus eliminando i papers non allineati al tema o troppo generici rispetto all'integrazione SD-AI/ML.

La fase finale consiste nella lettura integrale e nella decisione di inclusione o esclusione degli articoli selezionati.

Ho letto integralmente gli studi ritenuti coerenti nella fase precedente per verificare la coerenza con agli obiettivi della tesi. La lettura integrale è stata necessaria per assicurarmi: quale ruolo svolga l'AI/ML, se la SD sia effettivamente utilizzata per rappresentare dinamiche e retroazioni nel sistema e se il contesto sia effettivamente riconducibile a supply chain o logistica. Solo al termine di questa verifica ho confermato oppure escluso gli articoli nel campione finale.

I papers inclusi sono stati organizzati in un database e codificati con una griglia uniforme. Tale codifica mi ha permesso di svolgere un'analisi comparativa, evidenziando sia le soluzioni metodologiche più ricorrenti sia le principali criticità riportate dagli autori.

Il flusso di selezione degli studi è sintetizzato nel seguente diagramma PRISMA:



Figura 1 – PRISMA Flow Diagram Process.

3.2 Criteri di selezione

La selezione degli articoli è stata effettuata utilizzando Scopus, banca dati bibliografica internazionale accessibile tramite le risorse elettroniche messe a disposizione dal Politecnico di Torino. Scopus consente ricerche avanzate su titolo, abstract e parole chiave, risultando adeguata per intercettare paper che combinano approcci di system dynamics e intelligenza artificiale o machine learning in ambito supply chain e logistica.

La fase di identificazione iniziale degli studi è stata condotta tramite una ricerca strutturata in Scopus basata sulla seguente query:

```
TITLE-ABS-KEY ( "System Dynamics model*" ) AND TITLE-ABS-KEY ( "Machine Learning" OR  
"Linear Regression" OR "Logistic Regression" OR "Ridge Regression" OR "Lasso Regression" OR  
"Elastic Net" OR "Decision Tree" OR "Random Forest" OR "Naive Bayes" OR "Gradient Boosting"  
OR "XGBoost" OR "LightGBM" OR "CatBoost" OR "AdaBoost" OR "K-Means" OR "Hierarchical  
Clustering" OR "Principal Component Analysis" OR "Artificial Neural Network" OR "Artificial  
Intelligence" OR "Deep Learning" OR "Reinforcement Learning" OR "Support Vector Machine"  
OR "K-Nearest Neighbour" ) AND ( "supply chain" OR logistics OR "operations management" OR  
manufacturing OR transportation OR "inventory management" OR "demand forecasting" OR  
procurement OR "suppliers selection" ) AND ( LIMIT-TO ( LANGUAGE,"English" ) )
```

La query è stata costruita per garantire congiuntamente: la presenza di un riferimento esplicito alla System Dynamics, l'inclusione di un ampio insieme di tecniche AI/ML (come metodi supervisionati, non supervisionati, deep learning e reinforcement learning) e la pertinenza al dominio supply chain/ logistica /operazioni, includendo anche ambiti affini quali manufacturing, transportation, inventory management, demand forecasting, procurement e supplier selection. È stato, inoltre, applicato un filtro linguistico limitando i risultati a pubblicazioni in lingua inglese, al fine di mantenere omogeneità terminologica e comparabilità tra studi.

L'esecuzione della query ha prodotto 130 risultati. Su questo insieme è stata quindi applicata la logica della metodologia PRISMA descritta in precedenza, per rendere trasparente e replicabile il processo di selezione.

In particolare, dopo una prima fase di screening basata su titolo, parole chiave e abstract, gli articoli potenzialmente rilevanti sono stati sottoposti a lettura integrale per verificare: l'effettivo utilizzo della SD come metodo di modellazione o simulazione, l'impiego operativo di tecniche AI o ML e la coerenza con il contesto supply chain/ logistico. Al termine di tali passaggi, il campione finale è risultato composto da 32 papers, inclusi nell'analisi e successivamente codificati nel database di lavoro.


4 Risultati

4.1 Analisi degli articoli selezionati

In questo paragrafo mirerò a fornire una panoramica descrittiva del campione di articoli scientifici selezionati per l'analisi, in particolare mi concentrerò sulla loro distribuzione temporale, origine geografica, settori di applicazione e modalità di integrazione tra System Dynamics e Intelligenza Artificiale o Machine Learning.


4.1.1 Distribuzione temporale

La distribuzione temporale degli articoli evidenzia una tendenza all'incremento della ricerca che combina SD e AI/ML negli ultimi anni. Nonostante i primi contributi risalgono al 2011, si osserva una crescita modesta fino al 2020. A partire dal 2021, la produzione scientifica subisce un'accelerazione significativa, con picco nel 2024. Questo andamento potrebbe suggerire una crescente attenzione da parte della comunità scientifica verso le sinergie tra le due metodologie, causata presumibilmente dall'aumento della disponibilità dei dati e la crescente complessità dei problemi che richiedono approcci di modellazione integrati.



4.1.2 Distribuzione geografica

L'origine geografica degli articoli evidenzia una predominanza dei contributi proveniente dall'Asia, con la Cina che si posiziona come il paese più prolifico (8 articoli), seguita dal Regno Unito (6 articoli) e dagli Stati Uniti (4 articoli). Un numero significativo di paesi contribuisce con un solo articolo, questo indica un interesse diffuso ma meno concentrato in specifiche aree geografiche. Inoltre, la presenza di collaborazioni internazionali, dove un articolo coinvolge autori da più paesi sottolinea la natura globale della ricerca. La diversità geografica suggerisce che l'integrazione di SD e AI/ML è un tema di rilevanza globale, affrontato in contesti socio-economici e ambientali eterogenei.




4.1.3 Settore di applicazione

I settori di applicazione in cui l'integrazione tra System Dynamics e AI/ML trova maggiore impiego sono numerosi e riflettono la natura trasversale di queste metodologie. Tra questi, la supply chain/logistica emerge come l'ambito più rilevante, confermando il ruolo centrale che tali approcci possono svolgere nella gestione della complessità delle moderne catene di approvvigionamento.

Accanto a questo settore, risultano presenti anche applicazioni in ambiti quali waste management, water resources management, urban management/planning, agriculture e circular economy/reverse logistics. La presenza di contributi relativi a energy/power systems, healthcare e business/management/policy suggerisce inoltre un'estensione progressiva dell'interesse verso nuovi contesti applicativi.

Nel complesso, questa eterogeneità conferma la versatilità dell'integrazione tra SD e AI/ML nel rispondere a problemi complessi, caratterizzati da interdipendenze, incertezza e necessità di valutare gli effetti delle decisioni nel tempo.



4.1.4 Analisi delle keywords e degli obiettivi


L'esame degli obiettivi principali e delle parole chiave utilizzate negli articoli selezionati fornisce una comprensione più approfondita delle finalità della ricerca e delle aree di intersezione tra system dynamics e intelligenza artificiale.

Le parole chiave fornite sono state categorizzate in tre principali sezioni:

Section	Keywords Used
SD term	System Dynamics, Simulation, Causal Mapping, FSD, Hybrid Model.
ML/AI methods	Artificial Intelligence, Machine Learning, Neural Networks (ANN, CNN, RNN), Random Forest, Support Vector Machine (SVM), Decision Trees, Deep Learning, Fuzzy Logic, K-means Clustering, Apriori Algorithm, Regression, Classification, Reinforcement Learning, AI Regression, AI-Based Sorting, K-Fold Cross Validation.
Supply Chain/Logistic Domains	Supply Chain, Disruption Recovery, Production Planning, Transportation, Logistics, Smart/Collaborative Logistics, Urban Supply Chain, Last Mile Logistics, Reverse Logistics, Circular Economy, Healthcare, Battery Recycling Logistics, Mineral Recovery Logistics, Ocean Freight, Crowdsourcing Logistics, Livestreaming Supply Chain, Performance Metrics, Decision Support, Parameter Estimation.

L'analisi di queste categorie mostra una propensione all'uso di terminologie specifiche di entrambe le discipline, sottolineando l'approccio integrato della ricerca. Parallelamente, la vasta gamma di domini legati alla supply chain e alla logistica conferma l'importanza di questo settore come terreno fertile per l'applicazione di tali approcci ibridi, con un'attenzione particolare a temi come la resilienza, l'efficienza e la sostenibilità.

L'analisi delle parole chiave permette di identificare le finalità predominanti che guidano gli studi che integrano SD e AI/ML.



I risultati evidenziano che gli obiettivi più frequentemente perseguiti sono la previsione e l'ottimizzazione. Questo dato è coerente con la natura predittiva dell'AI/ML e la capacità della SD di simulare scenari complessi e identificare punti di leva per l'intervento. La previsione si applica a diversi contesti, dalla gestione dei rifiuti alla domanda energetica, fino alle vendite, dimostrando la flessibilità di questi approcci combinati nel gestire l'incertezza e anticipare le tendenze future.

L'ottimizzazione, invece, si concentra sull'efficientamento di processi e sistemi, come la pianificazione della produzione o la gestione delle risorse.

Un altro obiettivo centrale è il supporto alle decisioni, che sottolinea il desiderio di fornire strumenti robusti per i decisori in contesti complessi, permettendo l'analisi di scenari alternativi e l'identificazione di strategie efficaci.

La gestione della domanda è strettamente legata alla previsione, mirata a bilanciare l'offerta e la richiesta in vari sistemi.

La sostenibilità emerge come un tema trasversale e di crescente importanza, che si manifesta in obiettivi specifici come la circular economy, la waste management e la reverse logistics. Questi studi cercano di utilizzare l'integrazione tra SD e AI o ML per analizzare e promuovere pratiche più sostenibili in vari settori, dalla gestione dei rifiuti al riciclo delle batterie.

Infine, obiettivi come il recupero delle interruzioni e la collaborazione nella supply chain riflettono la crescente necessità di aumentare la resilienza e l'efficienza delle catene di approvvigionamento di fronte a eventi imprevisti.

In sintesi, l'analisi degli obiettivi e delle parole chiave conferma che la combinazione di SD e AI/ML è orientata principalmente a:

- Migliorare le capacità predittive e di previsione in ambienti dinamici e complessi
- Ottimizzare processi e sistemi per raggiungere maggiore efficienza e resilienza
- Fornire strumenti avanzati di supporto alle decisioni che considerino interazioni complesse e feedback loop
- Promuovere la sostenibilità in diversi settori applicativi.

4.1.5 Workflow di integrazione SD-AI/ML e sinergia esplicita

L'analisi dei workflow di integrazione tra SD e AI/ML rivela che la maggior parte degli articoli presenta una sinergia esplicita tra le due metodologie. Questo dato suggerisce che i ricercatori non si limitano a utilizzare SD e AI/ML in parallelo, ma cercano di sfruttare i punti di forza di ciascun approccio per creare modelli ibridi più robusti e predittivi.

I workflow più comuni includono l'integrazione di SD con diverse tecniche di Machine Learning, come Random Forest, varie forme di Machine Learning generico (ANN, SVM, DT, Clustering, Decision Tree ecc) e Deep Learning (FNN, CNN, RNN). Si osservano anche combinazioni più specifiche come SD con Clustering Automa + Neural Networks, Fuzzy Logic, Reinforcement Learning.

La sinergia esplicita si manifesta spesso per:

- Migliorare la previsione e la stima dei parametri: come nel caso SD + Random Forest per la previsione delle vendite
- Analizzare dinamiche complesse e non lineari: L'integrazione con Random forest per l'analisi pattern-oriented dei modelli SD o con deep learning per la previsione della domanda nei sistemi energetici
- Ottimizzare processi e prendere decisioni: l'accompiamento di SD e Reinforcement Learning per ottimizzare le politiche di recupero nelle supply chain.

Questo orientamento verso l'integrazione ibrida evidenzia il fatto che i modelli SD possono beneficiare della capacità dell'AI/ML di gestire grandi volumi di dati, identificare pattern complessi e migliorare le capacità predittive, creando così strumenti di analisi e supporto decisionale più potenti e accurati. I casi in cui la sinergia non è esplicitamente indicata potrebbero riferirsi a studi in cui le due metodologie sono usate in fasi separate o con un'interazione meno diretta, ma che comunque contribuiscono al campo di ricerca.

Nr	Workflow di integrazione SD-AI/ML	Sinergia esplicita tra SD e AI/ML
1	SD + Cellular Automata + Neural Networks	X
2	SD + Random Forest	X
3	SD + ABM + Cellular Automata + GIS	
4	SD + Fuzzy Logic	X
5	SD + Machine Learning (ANN, SVM, DT, RF)	
6	SD + ABM + Deep Learning (FNN)	X
7	SD + Deep Learning (CNN)	X
8	SD + Machine Learning (Regression/Classification)	X
9	SD + Random Forest	X
10	SD + Machine Learning	
11	SD + Reinforcement Learning	X
12	SD + Machine Learning + Content Analysis	X
13	SD + Machine Learning (Clustering, Decision Trees, Apriori)	X
14	SD + K-means Clustering	
15	SD + Random Forest	X
16	SD + Machine Learning (SVM, ANN, RF)	X
17	SD + Text Mining	
18	SD + Design Science Research (AI Integration)	X
19	SD + AI (Topic Modeling, Bibliometric Analysis)	
20	SD + Machine Learning (RNN/LSTM)	X
21	Discrete Event Simulation + Genetic Algorithm	
22	SD + Machine Learning (Random Forest)	X

4.2 Caratteristiche metodologiche

In questo paragrafo andremo ad analizzare e ad approfondire le caratteristiche metodologiche dei principali workflow di integrazione tra system dynamics e intelligenza artificiale o machine learning, così come emergono in maniera esplicita nei papers analizzati.

4.2.2 Integrazione SD e Random Forest

Dall'analisi dei contributi emerge una chiara tendenza verso approcci ibridi che combinano System Dynamics (SD) e Random Forest (RF). Questa convergenza metodologica nasce dalla complementarità tra i due strumenti: da un lato, la SD consente di rappresentare sistemi complessi attraverso feedback loop, non linearità e ritardi temporali; dall'altro, la RF permette di apprendere relazioni input-output articolate, gestendo dataset complessi e relazioni non lineari.

La System Dynamics viene generalmente descritta come una metodologia orientata alla comprensione e gestione di problemi dinamici caratterizzati da elevata complessità strutturale, non linearità e presenza di ritardi (Edali, 2022). In questo contesto, essa supporta in modo particolare le fasi di policy design e policy evaluation, grazie alla possibilità di condurre esperimenti what-if e analisi di scenario o di sensitività. Tali strumenti consentono di valutare come variazioni nelle condizioni iniziali o nelle politiche influenzino il comportamento del sistema nel tempo.

Nonostante questi punti di forza, la letteratura evidenzia anche un limite metodologico rilevante. L'analisi basata su esplorazione manuale dei parametri e interpretazione visiva degli output tende infatti a risultare poco efficiente e, in alcuni casi, non del tutto affidabile. All'aumentare del numero di parametri, lo spazio delle combinazioni cresce rapidamente, rendendo impraticabile un'esplorazione esaustiva. Di conseguenza, l'analista finisce spesso per concentrarsi solo su una porzione limitata dello spazio parametrico.

A questo si aggiunge un ulteriore problema: la selezione degli scenari e l'interpretazione dei risultati possono introdurre bias, essendo influenzate dall'esperienza e dalle aspettative dell'analista stesso. Il rischio è quindi quello di trascurare configurazioni di input capaci di generare comportamenti critici o non intuitivi (Edali, 2022).

Questa criticità diventa particolarmente evidente nei contesti di supply chain, dove il numero di variabili operative (come capacità, lead time, livelli di servizio, domanda e fattori di rischio) è elevato e ulteriormente ampliato dalla presenza di shock esterni. In tali condizioni, un approccio esclusivamente manuale risulta difficilmente scalabile.

All'interno degli studi analizzati, la SD viene utilizzata per costruire modelli in grado di simulare l'evoluzione temporale di indicatori operativi e di rischio. Ad esempio, nel caso della supply chain agricola basata sul livestreaming, essa è impiegata per condurre un risk assessment, esplicitando le relazioni tra rischio, performance operativa e strategie di controllo (Zhang & Lian, 2025). In modo analogo, nel contesto del waste management dei materiali da costruzione, la SD consente di modellare l'intero ciclo operativo (dalla demolizione al riciclo) e di analizzarne gli impatti ambientali e logistici nel lungo periodo (Bamisaye et al., 2025).

In questi workflow integrati, Random Forest assume il ruolo di tecnica di apprendimento in grado di gestire relazioni non lineari e interazioni complesse tra variabili (Edali, 2022). Dal punto di vista metodologico, essa risulta particolarmente adatta come metamodello per diverse ragioni: è in grado di approssimare relazioni non lineari tra input e output, mantiene un buon livello di interpretabilità rispetto ad altri modelli ad alta accuratezza e consente di estrarre regole decisionali in forma if-then a partire dalla struttura ad albero.

Nei lavori analizzati, la RF viene utilizzata principalmente con due funzioni. La prima è di tipo predittivo: nel caso della supply chain agricola, ad esempio, viene impiegata per stimare un indicatore di rischio legato al rallentamento delle vendite, utilizzando variabili meteorologiche come input (Zhang & Lian, 2025).

La seconda funzione riguarda invece la validazione e il rafforzamento del framework SD. Nel caso del waste management, la RF viene addestrata sugli indicatori generati dal modello dinamico, mostrando un'elevata concordanza con gli output simulati (Bamisaye et al., 2025).

Dall'analisi della letteratura emergono tre principali logiche di integrazione tra SD e RF.

La prima riguarda l'uso della Random Forest come metamodello del modello SD. In questo schema, proposto da Edali (2022), la RF apprende la relazione input-output del modello dinamico, riducendo la necessità di eseguire ripetutamente simulazioni e permettendo un'esplorazione più ampia e meno distorta dello spazio parametrico.

La seconda logica prevede l'impiego della RF come modulo predittivo per variabili esogene o di rischio. Nel caso della supply chain agricola, ad esempio, la RF viene utilizzata per stimare rischi legati a fattori esterni, come condizioni meteorologiche, che influenzano crescita, qualità e distribuzione dei prodotti, con effetti diretti su logistica e inventario. In questo modo, il modello supporta decisioni operative anticipando possibili criticità.

La terza logica consiste nell'utilizzo della RF come strumento di validazione e analisi delle variabili più influenti. Nel caso del waste management, essa viene impiegata per replicare gli output del modello SD e valutarne la coerenza attraverso metriche quantitative, oltre che per identificare le variabili che incidono maggiormente sui risultati (Bamisaye et al., 2025). Questo approccio contribuisce a rafforzare la credibilità del modello dinamico e a supportare la prioritizzazione delle leve decisionali.

Nei contesti di supply chain e logistica, l'integrazione tra SD e RF risponde alla necessità di gestire sistemi caratterizzati da elevata complessità e variabilità, nei quali la performance dipende dall'interazione tra processi operativi, ritardi decisionali e fattori esterni.

Nel caso della supply chain agricola in livestreaming, emergono alcune caratteristiche distintive: la complessità delle relazioni tra attori, la rapidità con cui può crescere la domanda, la dispersione geografica dei produttori, gli elevati requisiti di freschezza e puntualità e la necessità di gestire grandi volumi di informazioni. Questi elementi rendono il sistema particolarmente sensibile a rischi operativi e informativi, richiedendo strumenti capaci sia di modellare le dinamiche sia di anticipare criticità.

Nel contesto del waste management, invece, l'analisi di scenario evidenzia come attività quali trasporto e demolizione contribuiscano in modo significativo ai consumi energetici e alle emissioni. Le simulazioni mostrano che politiche come l'espansione della capacità di riciclo, l'adozione di mezzi a basse emissioni o l'ottimizzazione dei carichi possono generare riduzioni rilevanti (Bamisaye et al., 2025).

In entrambe le applicazioni, la SD permette di rappresentare la struttura dinamica del sistema, mentre la RF contribuisce a gestire la complessità empirica e a migliorare la capacità predittiva. Il risultato è un sistema di supporto decisionale più completo rispetto all'utilizzo isolato delle due metodologie.

Un primo workflow ricorrente può essere descritto come "RF a supporto della SD". In questo schema, la RF fornisce stime predittive che alimentano la simulazione dinamica. Nel caso agricolo, ad esempio, essa viene utilizzata per costruire un modello predittivo del rischio di rallentamento delle vendite, basato su variabili meteorologiche. La scelta della RF è motivata dalla sua robustezza rispetto a outlier e rumore e dalla capacità di trattare dataset complessi. Il modello viene valutato attraverso metriche come MAE, SMAPE e RMSE, e i risultati sono utilizzati per supportare decisioni tempestive volte a ridurre backlog e perdite (Zhang & Lian, 2025).

Questa logica riflette un principio generale: la previsione di variabili esogene migliora la prontezza decisionale, mentre la SD consente di analizzare come tali variazioni si propagano nel sistema nel tempo.

Un secondo workflow vede invece la SD come struttura principale e la RF come strumento di validazione. Nel caso del waste management, la SD modella l'intero ciclo dei rifiuti da demolizione, mentre la RF viene addestrata sugli indicatori risultanti. L'elevata concordanza tra output simulati e predizioni RF suggerisce una buona coerenza del modello, mentre l'analisi delle variabili più influenti aiuta a individuare i principali driver del sistema (Bamisaye et al., 2025).

Infine, un terzo workflow, di natura più metodologica, è quello proposto da Edali (2022), che affronta direttamente il problema dell'esplorazione dello spazio parametrico. In questo approccio, si definiscono i range dei parametri e si generano combinazioni di input attraverso tecniche di campionamento, come il Latin hypercube sampling. Ogni combinazione viene simulata tramite il modello SD, producendo un dataset input-output su cui viene addestrata la Random Forest come metamodello.

A partire da questo metamodello, è possibile estrarre regole interpretabili in forma if-then, utili per identificare regioni dello spazio parametrico associate a specifici comportamenti del sistema.

Applicato alla supply chain, questo approccio consente di individuare configurazioni che stabilizzano o destabilizzano le dinamiche operative (ad esempio oscillazioni di inventario o instabilità dovute a ritardi), fornendo indicazioni concrete sui range di parametri associati a performance desiderabili.

4.2.2 Integrazione SD e Fuzzy Logic

Nel lavoro di Orji e Wei (2015), l'integrazione tra System Dynamics (SD) e logica fuzzy viene proposta come risposta a una duplice criticità che caratterizza il problema della selezione sostenibile dei fornitori: da un lato, la natura dinamica del fenomeno; dall'altro, l'elevata incertezza informativa. Gli autori mettono in discussione i tradizionali approcci di multi-criteria decision making, evidenziando come questi tendano a trattare criteri e alternative come elementi statici, collocando la decisione in un momento puntuale. Tale impostazione risulta limitante in contesti in cui le performance dei fornitori evolvono nel tempo, influenzate da investimenti, politiche aziendali, capacità organizzative e pressioni esterne.

In questa prospettiva, la sostenibilità non può essere considerata una condizione fissa, ma deve essere interpretata come un processo dinamico, soggetto a miglioramenti progressivi o, al contrario, a deterioramenti. È proprio in relazione a questa dimensione evolutiva che la System Dynamics assume un ruolo centrale: essa consente di rappresentare il sistema nella sua interezza, modellando relazioni causali, feedback, accumuli e ritardi temporali, e permettendo così di cogliere non solo il livello di performance raggiunto, ma anche la traiettoria lungo cui tale performance si sviluppa nel tempo (Orji & Wei, 2015).

Tuttavia, la sola modellazione dinamica non è sufficiente. La valutazione della sostenibilità dei fornitori si basa infatti spesso su informazioni incomplete, giudizi esperti e variabili difficilmente osservabili. In questo contesto, la logica fuzzy viene introdotta come strumento in grado di formalizzare l'ambiguità e la vaghezza tipiche dei processi decisionali reali, traducendo valutazioni linguistiche in rappresentazioni numeriche utilizzabili in analisi quantitative.

L'integrazione tra SD e fuzzy logic si fonda quindi su una complementarità funzionale: la fuzzy logic struttura e quantifica l'incertezza, mentre la SD consente di collocare tali informazioni all'interno di una dinamica temporale e sistemica, rendendo possibile analizzare l'evoluzione delle performance nel medio-lungo periodo.

L'approccio proposto dagli autori si articola in una vera e propria architettura metodologica. La logica fuzzy interviene nella fase iniziale, quando è necessario raccogliere e formalizzare le valutazioni sui fornitori rispetto ai criteri di sostenibilità.

Tali criteri comprendono dimensioni economiche, ambientali e sociali, includendo aspetti quali qualità, green design, competenze ambientali, sicurezza dei lavoratori, rispetto delle policy e trasparenza informativa. Le valutazioni vengono espresse tramite scale linguistiche e trasformate in numeri fuzzy triangolari.

Un passaggio cruciale è rappresentato dalla conversione di tali numeri fuzzy in valori quantitativi utilizzabili come input per il modello SD. Questa fase di traduzione consente di rendere operativamente trattabile la conoscenza esperta, mantenendone al contempo la complessità. Il risultato è una matrice di performance che non rappresenta una semplice fotografia statica, ma una base informativa pensata per alimentare un'analisi evolutiva.

Un ulteriore elemento distintivo è l'articolazione della valutazione su più orizzonti temporali (passato, presente e futuro) che consente di cogliere non solo lo stato attuale dei fornitori, ma anche la loro traiettoria evolutiva.

Una volta definiti gli input, la SD entra in gioco come strumento di simulazione. Gli autori costruiscono dapprima un causal loop diagram e successivamente un modello stock-and-flow, implementato in Vensim. In questa fase, la SD non viene utilizzata per produrre semplici previsioni lineari, ma per rappresentare il comportamento emergente del sistema, cioè il modo in cui le performance si trasformano nel tempo sotto l'effetto di feedback, accumuli e ritardi.

Ne deriva una concezione della sostenibilità come processo dinamico. Una variabile centrale è il tasso di investimento in fattori di sostenibilità, che influenza la performance complessiva e ne determina l'evoluzione. I risultati mostrano che un aumento degli investimenti genera una crescita non lineare della performance e che, dopo un certo periodo, gli effetti diventano cumulativi, superando il contributo diretto dell'investimento stesso. Questo suggerisce la presenza di meccanismi di apprendimento e consolidamento che i modelli statici non riescono a catturare.

L'integrazione tra fuzzy logic e SD permette quindi di superare una visione statica della sostenibilità, evidenziando come essa dipenda dalla capacità di attivare e mantenere nel tempo processi di miglioramento.

Non mancano tuttavia alcune criticità. Il modulo fuzzy dipende fortemente dalle valutazioni degli esperti, che possono essere influenzate da bias o asimmetrie informative. Inoltre, il modello dinamico si basa su alcune assunzioni semplificative (come la stabilità del budget nel periodo) che riducono la capacità di rappresentare variazioni improvvise o shock esterni. Infine, come in tutti i modelli SD, la qualità dei risultati dipende dalla correttezza della struttura causale ipotizzata.

Nel complesso, l'approccio proposto rappresenta non solo una soluzione tecnica, ma anche un cambiamento di prospettiva: la selezione dei fornitori non è più una decisione statica, ma un processo continuo, in cui la sostenibilità emerge dall'interazione tra qualità dell'informazione e dinamica del sistema.

4.2.3 Integrazione SD e Deep Learning (FNN, CNN)

L'integrazione tra System Dynamics (SD) e tecniche di Deep Learning, in particolare Feedforward Neural Networks (FNN) e Convolutional Neural Networks (CNN), rappresenta un ambito di crescente interesse nello studio dei sistemi complessi applicati alla supply chain e alla logistica. Questo filone si basa sull'idea che la SD e il deep learning possano svolgere ruoli complementari: la prima consente di rappresentare la struttura causale del sistema, mentre il secondo permette di apprendere relazioni non lineari dai dati e di produrre previsioni robuste anche in contesti caratterizzati da elevata variabilità (Ibrahim et al., 2023; Sakas et al., 2023).

Un primo elemento rilevante è che, in questi contesti, la previsione isolata non è sufficiente. È necessario comprendere come le variazioni previste si propaghino nel sistema, influenzando costi, capacità, livelli di servizio e performance complessiva. In questo senso, la SD fornisce il quadro interpretativo entro cui inserire i risultati del deep learning.

Nel contributo di Sakas et al. (2023), il deep learning viene integrato all'interno di un'architettura più ampia che combina Agent-Based Modeling (ABM), SD e FNN. In questo schema, la FNN non si limita a fornire output predittivi finali, ma opera come componente interna del modello, stimando variabili comportamentali degli agenti (come tempo di permanenza su un sito o livello di interazione) che influenzano direttamente le dinamiche logistiche.

Questo approccio introduce una logica micro-to-macro: le stime generate a livello micro (comportamento degli agenti) vengono propagate attraverso SD e ABM fino a influenzare indicatori macro, come indici di trasporto e costi logistici. Un elemento distintivo è la natura data-driven della parametrizzazione, in cui le relazioni del modello non derivano solo da ipotesi teoriche, ma anche da evidenze empiriche.

Accanto a questo approccio, emerge un secondo schema basato sull'utilizzo delle CNN come strumenti di feature extraction e forecasting (Ibrahim et al., 2023).

In questo caso, le CNN vengono impiegate per identificare pattern in serie temporali complesse e multivariate, mentre la SD mantiene il ruolo di modello strutturale per l'analisi delle dinamiche di sistema.

Dall'analisi della letteratura emergono quindi due principali modalità di integrazione:

- una modalità endogena, in cui il deep learning è parte integrante del modello simulativo
- una modalità modulare, in cui il deep learning opera come componente separata di previsione o estrazione delle feature.

In entrambi i casi, l'integrazione consente di migliorare sia la capacità predittiva sia quella esplicativa dei modelli. Tuttavia, non mancano criticità. I modelli di deep learning possono risultare meno efficaci nella previsione di eventi estremi, che in ambito logistico corrispondono spesso alle situazioni più critiche. Inoltre, l'aumento della complessità del modello comporta maggiori requisiti computazionali.

Nel complesso, l'integrazione SD-Deep Learning rappresenta un approccio promettente, ma richiede attenzione in termini di scalabilità, robustezza e validazione.

4.2.4 Integrazione SD e Machine Learning (ANN, SVM)

L'integrazione tra System Dynamics (SD) e Machine Learning (ML) rappresenta una delle evoluzioni più significative nell'analisi dei sistemi complessi applicati alla supply chain e alla logistica. L'interesse verso questo approccio deriva dalla crescente difficoltà di rappresentare sistemi caratterizzati da interdipendenze multiple, non linearità, ritardi informativi e vincoli operativi che si influenzano reciprocamente nel tempo.

In questo contesto, la System Dynamics offre una rappresentazione strutturale del sistema basata su stock, flow e feedback loop, consentendo di descrivere il comportamento dinamico e le sue retroazioni. Tuttavia, uno dei limiti più rilevanti degli approcci SD tradizionali risiede nella necessità di specificare in modo esplicito le relazioni funzionali tra variabili, spesso costruite su basi teoriche o euristiche. Questo può introdurre semplificazioni che non riflettono pienamente la complessità empirica del sistema.

Il Machine Learning interviene proprio in questo punto, offrendo strumenti capaci di apprendere tali relazioni direttamente dai dati osservati. In altre parole, il ML consente di sostituire o arricchire le funzioni di flusso e i parametri del modello SD con stime data-driven, riducendo la dipendenza da assunzioni semplificative e aumentando l'aderenza del modello alla realtà osservata (Gadewadikar & Marshall, 2024).

L'integrazione tra i due approcci può essere letta secondo due logiche principali. La prima prevede l'inserimento del Machine Learning all'interno del modello SD come strumento di stima delle relazioni funzionali. In questo caso, algoritmi come ANN o SVM vengono utilizzati per approssimare i flussi del sistema sulla base degli stati correnti delle variabili, sostituendo relazioni predefinite con funzioni apprese dai dati. La seconda logica, invece, utilizza la System Dynamics come ambiente di simulazione per valutare gli effetti sistemici delle decisioni supportate da modelli ML, verificando se miglioramenti locali si traducano effettivamente in benefici globali per il sistema.

Tra le tecniche più utilizzate in questo contesto vi sono le Artificial Neural Networks (ANN) e le Support Vector Machines (SVM). Le ANN risultano particolarmente adatte quando le relazioni tra variabili sono altamente non lineari e dipendono da molteplici fattori simultanei. In ambito supply chain, questo si traduce nella possibilità di modellare fenomeni complessi come il lead time effettivo, il throughput di magazzino o i tassi di reso, che dipendono da condizioni operative dinamiche e interconnesse. Tuttavia, l'utilizzo delle reti neurali comporta anche criticità legate alla necessità di grandi quantità di dati, al rischio di overfitting e alla limitata interpretabilità dei risultati.

Le SVM, Support Vector Regression, rappresentano invece una soluzione efficace nei casi in cui il dataset sia più limitato ma le relazioni restino non lineari. Grazie all'utilizzo di kernel non lineari, le SVM permettono di proiettare i dati in spazi dimensionali superiori, facilitando la separazione delle relazioni complesse tra variabili. In ambito logistico, queste tecniche possono essere utilizzate per stimare tempi di consegna, probabilità di ritardo o rischi di stockout in presenza di variabili esogene come condizioni meteo o congestione infrastrutturale. Rispetto alle ANN, le SVM tendono a garantire una maggiore stabilità in contesti con meno dati, pur richiedendo una selezione accurata dei parametri del modello.

Un elemento centrale dell'integrazione SD-ML riguarda la qualità dei dati e le fasi di pre-processing. Nei sistemi di supply chain, i dati sono spesso incompleti, rumorosi o distorti da fenomeni operativi come stockout, ritardi di registrazione o errori di misurazione. In particolare, la domanda osservata può non riflettere la domanda reale a causa di vincoli di capacità o indisponibilità di prodotto. Questo implica la necessità di tecniche di pulizia, normalizzazione e, in alcuni casi, correzione della censura del dato prima dell'addestramento dei modelli.

La validazione del modello integrato richiede inoltre un approccio su due livelli. Da un lato, è necessario verificare le performance del modello ML attraverso metriche statistiche e procedure di cross-validation. Dall'altro, occorre valutare il comportamento dinamico del sistema una volta reinserite le funzioni apprese all'interno della struttura SD.

Un modello può infatti risultare accurato a livello predittivo, ma generare dinamiche instabili o non realistiche quando inserito in un sistema di feedback.

Questo punto introduce un aspetto concettuale rilevante: la distinzione tra razionalità locale e razionalità globale. Un miglioramento delle performance predittive del modello ML non implica necessariamente un miglioramento delle prestazioni complessive del sistema. Al contrario, decisioni ottimizzate localmente possono generare effetti indesiderati a livello sistemico, come amplificazione della variabilità o instabilità delle scorte.

La SD diventa quindi essenziale per valutare la coerenza tra ottimizzazione locale e comportamento globale.

Nel complesso, l'integrazione tra SD e ML consente di superare i limiti di entrambi gli approcci: da un lato arricchisce la capacità empirica dei modelli dinamici, dall'altro inserisce le previsioni in una struttura causale esplicita. Tuttavia, richiede un elevato livello di rigore metodologico, soprattutto nella gestione dei dati, nella validazione e nell'interpretazione dei risultati.

4.2.5 Integrazione SD e Reinforcement Learning

L'integrazione tra System Dynamics e Reinforcement Learning si colloca all'interno della letteratura sulla resilienza delle supply chain, in particolare nello studio degli effetti delle disruption e della loro propagazione lungo la rete. Eventi globali recenti hanno evidenziato come le supply chain moderne, ottimizzate per l'efficienza e la riduzione dei costi, risultino particolarmente vulnerabili a shock improvvisi che possono generare effetti a cascata, noti come ripple effect (Bussieweke et al., 2025).

In questo scenario, la resilienza non viene più interpretata come semplice capacità di prevenire le disruption, ma come abilità del sistema di assorbirle, adattarsi e recuperare rapidamente. All'interno di questa prospettiva, le politiche di inventory management e ordering assumono un ruolo centrale, poiché influenzano direttamente la velocità e l'efficacia del processo di recupero.

La System Dynamics viene utilizzata per rappresentare la struttura della supply chain e per simulare la propagazione degli shock attraverso stock, flussi e feedback loop. Questa rappresentazione consente di catturare fenomeni come l'accumulo di backlog, le oscillazioni degli inventari e gli effetti ritardati delle decisioni operative. Tuttavia, la SD tradizionale si limita generalmente a confrontare scenari predefiniti, senza fornire un meccanismo automatico per l'ottimizzazione delle politiche decisionali.

È proprio in questo punto che si inserisce il Reinforcement Learning, che introduce una logica di apprendimento basata sull'interazione continua tra agente e ambiente. L'agente osserva lo stato del sistema, prende decisioni (ad esempio quantità d'ordine) e riceve una ricompensa che guida l'aggiornamento della propria policy. Attraverso questo processo iterativo, il sistema apprende strategie ottimali senza richiedere una conoscenza esplicita delle dinamiche sottostanti.

Nel framework proposto da Bussieweke et al. (2025), la System Dynamics viene utilizzata come ambiente simulativo all'interno del quale l'agente RL interagisce. Questo consente di generare un numero elevato di esperienze sintetiche necessarie per l'apprendimento, evitando i rischi e i costi associati alla sperimentazione sul sistema reale.

L'integrazione tra SD e RL assume quindi la forma di un approccio di simulation-optimisation, in cui la SD fornisce la struttura dinamica del sistema e il RL ne ottimizza il comportamento attraverso l'apprendimento di politiche adattive.

Un elemento centrale di questo approccio è la capacità del Reinforcement Learning di operare in condizioni di incertezza elevata, senza conoscere in anticipo la durata, la localizzazione o l'intensità delle disruption. I risultati mostrano che algoritmi come Proximal Policy Optimization (PPO) sono in grado di apprendere politiche più stabili ed efficaci rispetto ad approcci più semplici come A2C, riducendo la variabilità di inventari e backlog e migliorando la resilienza complessiva del sistema.

Un aspetto particolarmente rilevante è che le politiche apprese risultano adattive: non sono legate a scenari specifici, ma reagiscono allo stato corrente del sistema. Questo consente una maggiore generalizzazione rispetto ai metodi tradizionali basati su scenari predefiniti, che risultano meno flessibili in contesti reali caratterizzati da incertezza.

Dal punto di vista concettuale, l'integrazione SD-RL si collega anche all'idea di digital twin. La System Dynamics può essere interpretata come una rappresentazione dinamica della supply chain reale, mentre il Reinforcement Learning fornisce il motore decisionale in grado di suggerire politiche ottimali in tempo reale. In questo senso, l'approccio può essere visto come un possibile fondamento matematico per sistemi decisionali intelligenti applicati alla logistica.

Tuttavia, l'approccio presenta alcune limitazioni significative. La prima riguarda la dipendenza dalla qualità del modello SD: se la rappresentazione del sistema non è accurata, anche le politiche apprese rischiano di essere distorte. La seconda riguarda la scalabilità computazionale, poiché modelli più complessi richiedono risorse significative per l'addestramento. Inoltre, la progettazione della reward function rappresenta un elemento critico, poiché una formulazione non adeguata può portare a comportamenti subottimali o indesiderati.

Infine, resta il tema della validazione in contesti reali, ancora limitata nella letteratura.

Nonostante i risultati sperimentali siano promettenti, l'applicazione industriale dell'approccio richiede ulteriori verifiche, soprattutto in termini di robustezza e trasferibilità.

Nel complesso, l'integrazione tra System Dynamics e Reinforcement Learning rappresenta una direzione particolarmente promettente per la gestione delle supply chain in condizioni di incertezza e disruption. Essa consente di combinare la capacità descrittiva della SD con la capacità prescrittiva del RL, aprendo la strada a sistemi decisionali più adattivi e reattivi rispetto alle tradizionali politiche statiche.

5 Discussione e Conclusioni

Alla luce dei risultati emersi dall'analisi della letteratura, si osserva come l'integrazione tra System Dynamics (SD) e tecniche di Artificial Intelligence e Machine Learning (AI/ML) stia assumendo un ruolo sempre più rilevante nello studio e nella gestione dei sistemi complessi. Il corpus analizzato evidenzia chiaramente che questa convergenza non è un fenomeno marginale, ma un filone di ricerca in crescita, particolarmente significativo nei contesti caratterizzati da elevata complessità dinamica, forte interdipendenza tra variabili, incertezza decisionale e necessità di valutazioni di medio-lungo periodo.

In questo scenario, il settore della supply chain e della logistica emerge come uno degli ambiti applicativi più rappresentativi. Qui, la comprensione delle dinamiche sistemiche si conferma un elemento centrale per progettare soluzioni decisionali più efficaci, resilienti e capaci di adattarsi a contesti in continuo cambiamento.

I risultati presentati nel capitolo precedente hanno messo in evidenza non solo la varietà dei workflow di integrazione tra SD e AI/ML, ma anche la presenza di alcune configurazioni ricorrenti, impiegate soprattutto per attività di forecasting, ottimizzazione e supporto alle decisioni. Queste evidenze suggeriscono che il rapporto tra modellazione dinamica e intelligenza artificiale non debba essere interpretato come una semplice sovrapposizione di strumenti, ma piuttosto come una relazione di complementarità tra approcci che rispondono a esigenze diverse, ma profondamente connesse.

Da un lato, la System Dynamics permette di rappresentare la struttura causale del sistema, mettendo in luce feedback loop, ritardi e accumuli che ne determinano il comportamento nel tempo. Dall'altro, le tecniche di AI/ML offrono strumenti capaci di apprendere dai dati, migliorare la capacità predittiva, stimare relazioni complesse e supportare l'ottimizzazione delle decisioni.

Nel presente capitolo, i risultati dell'analisi vengono interpretati mettendo in evidenza i principali benefici delle combinazioni SD–AI/ML più diffuse, le tendenze emergenti nella letteratura e i limiti ancora presenti in questo ambito di ricerca.

A partire da queste considerazioni, vengono infine proposte alcune riflessioni sulle possibili evoluzioni future dell'integrazione tra modellazione dinamica e intelligenza artificiale, con particolare attenzione alle implicazioni per la gestione della supply chain.

5.1 Benefici delle combinazioni SD–AI/ML più diffuse

L'analisi del campione mostra che l'integrazione tra System Dynamics e tecniche di AI/ML non segue un'unica configurazione, ma si sviluppa attraverso combinazioni differenti, costruite in funzione del problema affrontato, della disponibilità dei dati e dell'obiettivo della ricerca. Questa varietà riflette la natura eterogenea dei problemi tipici della supply chain e della logistica, dove feedback, non linearità, ritardi e shock esterni rendono spesso insufficiente l'adozione di approcci esclusivamente simulativi o esclusivamente data-driven.

Nel complesso, i risultati indicano che il principale valore aggiunto delle combinazioni SD–AI/ML risiede nella loro complementarità. La System Dynamics consente di descrivere la struttura del sistema e simularne l'evoluzione nel tempo, mentre l'AI/ML contribuisce rafforzando la capacità del modello di apprendere dai dati, prevedere comportamenti, stimare parametri e supportare decisioni operative. L'integrazione, quindi, non si limita ad aumentare la capacità predittiva, ma migliora anche la robustezza complessiva e l'utilità pratica dei modelli.

Tra le combinazioni più ricorrenti emergono quelle tra System Dynamics e Random Forest, Fuzzy Logic, Deep Learning, Machine Learning supervisionato e Reinforcement Learning. Pur nelle loro differenze, tutte queste integrazioni condividono un obiettivo comune: rendere i modelli più adatti a rappresentare e gestire sistemi complessi in condizioni di incertezza.

Un primo gruppo di contributi riguarda l'integrazione tra System Dynamics e Random Forest, particolarmente utile nei casi in cui si debbano gestire relazioni non lineari e alta complessità parametrica. In questi lavori, la Random Forest viene impiegata come metamodello del sistema dinamico, come strumento predittivo per variabili esogene oppure come supporto all'analisi di sensibilità.

Il principale vantaggio di questa combinazione risiede nella possibilità di superare uno dei limiti tipici della System Dynamics, ovvero la difficoltà di esplorare in modo completo lo spazio dei parametri quando il numero delle variabili cresce. Nei sistemi di supply chain, infatti, le performance dipendono da molteplici fattori interconnessi (capacità, lead time, domanda, livelli di servizio e variabili esterne) rendendo poco praticabile un'analisi esclusivamente manuale degli scenari.

La Random Forest consente quindi di approssimare la relazione tra input e output del modello SD, riducendo il numero di simulazioni necessarie e ampliando la copertura dello spazio dei parametri. Questo permette di individuare configurazioni critiche o non intuitive che difficilmente emergerebbero con approcci tradizionali. Inoltre, la tecnica si rivela utile anche nella previsione di variabili esogene, come rischi climatici o variazioni della domanda, che possono poi essere integrate nel modello dinamico.

Un ulteriore punto di forza riguarda la relativa interpretabilità del metodo, che consente di identificare le variabili più rilevanti e, in alcuni casi, di estrarre indicazioni utili per la definizione delle politiche decisionali.

Un secondo filone rilevante è rappresentato dall'integrazione tra System Dynamics e Fuzzy Logic, particolarmente indicata nei contesti in cui le informazioni sono incomplete, qualitative o caratterizzate da ambiguità. In ambito supply chain, questa combinazione trova applicazione soprattutto nella selezione e valutazione dei fornitori, dove entrano in gioco non solo indicatori quantitativi, ma anche giudizi esperti legati a sostenibilità, affidabilità o trasparenza.

Il principale vantaggio di questo approccio è la capacità di formalizzare l'incertezza senza forzare eccessive semplificazioni.

La logica fuzzy consente infatti di trasformare valutazioni linguistiche in valori numerici utilizzabili nei modelli, mentre la System Dynamics inserisce queste informazioni all'interno di una struttura causale e temporale.

In questo modo, è possibile analizzare l'evoluzione delle performance nel tempo, superando una visione statica del problema e interpretando, ad esempio, la sostenibilità di un fornitore come un processo dinamico e non come una condizione istantanea.

Un terzo filone riguarda l'integrazione tra System Dynamics e Deep Learning, in particolare attraverso reti neurali feedforward e convolutional. Qui il valore aggiunto risiede nella combinazione tra la capacità della SD di rappresentare strutture causali e quella del deep learning di apprendere relazioni non lineari da grandi moli di dati.

In ambito supply chain e logistica, questa integrazione risulta particolarmente utile per forecasting, demand management e supporto decisionale in contesti caratterizzati da forte variabilità. Le reti neurali possono stimare variabili difficili da modellare in modo esplicito, mentre la System Dynamics consente di analizzarne l'impatto sul sistema complessivo.

Ne deriva un approccio in cui il deep learning migliora la qualità degli input del modello dinamico, mentre la SD ne interpreta gli effetti sistemici su inventari, costi e livelli di servizio. Un ulteriore vantaggio è la possibilità di costruire schemi micro-to-macro, nei quali il livello micro (comportamenti individuali o variabili latenti) viene tradotto in effetti aggregati.

Accanto a ciò, l'integrazione tra System Dynamics e Machine Learning supervisionato (ANN, SVM) si rivela utile nei casi in cui alcune relazioni del sistema non siano facilmente formalizzabili. In questi casi, il machine learning consente di stimare relazioni complesse tra variabili, mantenendo però la struttura causale della SD.

Un aspetto importante non riguarda solo la precisione predittiva, ma anche la possibilità di utilizzare la System Dynamics come ambiente di validazione sistemica. Un miglioramento locale delle previsioni, infatti, non corrisponde necessariamente a un miglioramento globale del sistema.

Ad esempio, previsioni più accurate possono generare politiche di riordino eccessivamente reattive, amplificando instabilità e bullwhip effect.

Infine, un approccio particolarmente avanzato è quello che integra System Dynamics e Reinforcement Learning. In questo caso, la SD funge da ambiente simulativo, mentre il RL apprende politiche decisionali attraverso l'interazione con il sistema.

Il vantaggio principale è la possibilità di sviluppare politiche adattive in presenza di disruption, senza conoscere a priori la natura dello shock. Questo è particolarmente rilevante in contesti caratterizzati da ripple effect e forte incertezza. Inoltre, l'apprendimento in ambiente simulato riduce costi e rischi rispetto alla sperimentazione reale, rendendo l'approccio coerente con le logiche dei digital twin.

Nel complesso, le diverse combinazioni convergono verso un obiettivo comune: migliorare la capacità dei modelli di rappresentare la complessità dei sistemi di supply chain, aumentando al tempo stesso capacità predittiva, robustezza e utilità decisionale.

5.2 Tendenze emergenti nell'integrazione SD-AI/ML

L'analisi della letteratura consente di individuare alcune tendenze chiare nell'evoluzione recente di questo filone.

Una prima evidenza riguarda la crescita dell'interesse scientifico, soprattutto negli ultimi anni, con un'accelerazione significativa dopo il 2020. Questo riflette sia la maggiore disponibilità di dati sia la crescente complessità dei sistemi decisionali.

Una seconda tendenza è il passaggio da un uso parallelo delle metodologie a forme di integrazione realmente sinergiche. SD e AI/ML non vengono più utilizzate in fasi separate, ma all'interno di workflow integrati.

Una terza tendenza riguarda il crescente orientamento verso forecasting, optimization e decision support, che diventano gli obiettivi principali. L'integrazione si sposta quindi da una funzione descrittiva a una funzione sempre più prescrittiva.

Un'ulteriore direzione riguarda l'attenzione crescente verso resilienza e sostenibilità, con applicazioni in disruption management, circular economy e gestione dei rischi. Questo riflette un cambiamento più ampio nelle priorità delle supply chain moderne.

Si osserva inoltre una forte evoluzione verso approcci data-driven, in cui l'AI non è solo uno strumento predittivo, ma anche un mezzo per estrarre pattern, stimare relazioni e integrare dati eterogenei nei modelli dinamici.

Infine, emerge l'interesse verso architetture digital twin e sistemi adattivi, nei quali simulazione e apprendimento continuo si combinano per supportare decisioni in tempo reale. Anche se ancora in fase iniziale, questa direzione appare particolarmente promettente.

5.3 Limiti e prospettive future

Nonostante i risultati positivi, l'integrazione tra SD e AI/ML presenta ancora diversi limiti.

Un primo riguarda la qualità dei dati, spesso incompleti o non strutturati, soprattutto nei contesti reali di supply chain. Questo può compromettere la fase di training dei modelli.

Un secondo limite riguarda la validazione, che richiede approcci multilivello ancora non standardizzati: non basta la performance statistica, ma serve anche coerenza dinamica.

Un ulteriore problema è l'interpretabilità, particolarmente critico nei modelli deep learning e reinforcement learning, che risultano spesso opachi per i decisori.

Anche la scalabilità computazionale rappresenta una sfida, soprattutto nei modelli complessi o multi-agente, dove i costi di simulazione e training possono essere elevati.

Un altro limite riguarda la dipendenza dalla qualità del modello SD stesso: errori nella struttura causale si propagano all'intero sistema integrato.

Infine, la trasferibilità dei risultati rimane limitata, poiché molti studi sono fortemente contestualizzati.

Le prospettive future includono lo sviluppo di framework metodologici più standardizzati, una maggiore attenzione alla spiegabilità dei modelli e l'estensione a supply chain più complesse e globali.

Ulteriori direzioni riguardano l'integrazione con dati in tempo reale, lo sviluppo di digital twin avanzati, approcci multi-agent e funzioni obiettivo multi-criterio, soprattutto nei modelli di reinforcement learning.

5.4 Conclusioni

L'analisi della letteratura evidenzia che l'integrazione tra System Dynamics e AI/ML rappresenta una delle direzioni più promettenti per lo studio dei sistemi complessi, in particolare nelle supply chain.

La System Dynamics consente di comprendere la struttura profonda dei sistemi, mettendo in evidenza feedback, ritardi e dinamiche emergenti. L'AI/ML, invece, potenzia questa base attraverso capacità predittive e adattive.

La risposta alla domanda di ricerca risulta quindi chiara: la System Dynamics può fungere da struttura fondamentale per comprendere e simulare le dinamiche della supply chain e, proprio grazie a questa base, facilitare l'uso di soluzioni di intelligenza artificiale più efficaci e coerenti.

In definitiva, non si tratta di una semplice somma di tecniche, ma di una vera complementarità metodologica. Nonostante i limiti ancora presenti, la letteratura suggerisce che questa integrazione abbia un potenziale significativo sia teorico che applicativo.

In un contesto caratterizzato da volatilità, interdipendenze globali e crescente attenzione alla sostenibilità, l'integrazione tra System Dynamics e AI/ML è destinata a diventare uno strumento sempre più rilevante per la progettazione di sistemi decisionali intelligenti, resilienti e adattivi.

Bibliografia

- Sakas, D.P.; Giannakopoulos, N.T.; Terzi, M.C.; Kanellos, N. Engineering Supply Chain Transportation Indexes through Big Data Analytics and Deep Learning. *Appl. Sci.* **2023**, *13*, 9983. <https://doi.org/10.3390/app13179983>
- Ibrahim, B.; Rabelo, L.; Sarmiento, A.T.; Gutierrez-Franco, E. A Holistic Approach to Power Systems Using Innovative Machine Learning and System Dynamics. *Energies* **2023**, *16*, 5225. <https://doi.org/10.3390/en16135225>
- Ifeyinwa Juliet Orji; Sun Wei. An innovative integration of fuzzy-logic and systems dynamics in sustainable supplier selection: A case on manufacturing industry. <http://dx.doi.org/10.1016/j.cie.2015.06.019>
- Sankaran, G.; Palomino, M.A.; Knahl, M.; Siestrup, G. Towards a System Dynamics Framework for Human–Machine Learning Decisions: A Case Study of New York Citi Bike. *Appl. Sci.* **2024**, *14*, 10647. <https://doi.org/10.3390/app142210647>
- Vahideh Bafandegan Emroozi; Mostafa Kazemi; Alireza Pooya; Mahdi Doostparast. Evaluating human error probability in maintenance task: An integrated system dynamics and machine learning approach. <https://doi.org/10.1002/hfm.21057>
- Jourabchi Amirkhizi, P.; Pedrammehr, S.; Pakzad, S.; Shahhoseini, A. Generative Artificial Intelligence in Adaptive Social Manufacturing: A Pathway to Achieving Industry 5.0 Sustainability Goals. *Processes* **2025**, *13*, 1174. <https://doi.org/10.3390/pr13041174>
- Jingjing Sun¹, Xin Guan, Zeyu Wang, Jiali Zhang, Yepei Tan & Peng Nie. A study on green innovation and entrepreneurship in the dual carbon era and its implications for the energy market. *Scientific Reports*, (2025) 15:18400, <https://doi.org/10.1038/s41598-025-02993-x>
- Guoyi Xiu, Zexu Zhao. Sustainable Development of Port Economy Based on Intelligent System Dynamics. 2021.
- Jyotirmay Gadewadikar, Jeremy Marshall. A methodology for parameter estimation in system dynamics models using artificial intelligence. *Systems Engineering*. 2024; 27:253–266.
- Mayowa Emmanuel Bamisaye, Babatunde Oluwaseun Ajayi, Issara Sereewatthanawut. Sustainable waste management of construction materials: Mathematical modelling and analysis. <https://doi.org/10.1016/j.rcradv.2025.200274>
- Hui Zhang, Zeke Lian. Exploring Agricultural Livestreaming and Agricultural Supply Chain Management Empowered by the Internet of Things and Artificial Intelligence. *Journal of Information Science and Engineering* 41, 791-815 (2025).

Natalia Magdalena Rafu Mamulak, Erma Suryani, Jerry Dwi Trijoyo Purnomo. Integrating System Dynamics and Random Forest Algorithm for Sales Forecasting.

Mert Edali. Pattern-oriented analysis of system dynamics models via random forests. *Syst. Dyn. Rev.* 38, 135–166 (2022)

Fabian Bussieweke, Josefa Mula & Francisco Campuzano-Bolarin (2025) Optimisation of recovery policies in the era of supply chain disruptions: a system dynamics and reinforcement learning approach, *International Journal of Production Research*, 63:5, 1649-1673, DOI: 10.1080/00207543.2024.2383293. <https://doi.org/10.1080/00207543.2024.2383293>

Cheng Qi, Ni-Bin Chang. System dynamics modeling for municipal water demand estimation in an urban region under uncertain economic impacts. *Journal of Environmental Management* 92 (2011) 1628e164. doi:10.1016/j.jenvman.2011.01.020

Junwoo Jeon, Çagatay Iris, Sungchul Hong, Andrew Lyons. Box rates unveiled: Predictive analytics for ocean freight rates with system dynamics and text mining under supply chain disruptions. *Int. J. Production Economics* 286 (2025) 109669. <https://doi.org/10.1016/j.ijpe.2025.109669>

Rubino, G.; Gattuso, D.; Gronalt, M. Modeling the Interactions Between Smart Urban Logistics and Urban Access Management: A System Dynamics Perspective. *Appl. Sci.* **2025**,15, 7882. <https://doi.org/10.3390/app15147882>

Anna-Maria Nitsche, Christian-Andreas Schumann, Bogdan Franczyk, Kevin Reuther. Artificial Intelligence Inspired Supply Chain Collaboration: A Design-Science Research and System Dynamics Approach. *International Conference on Engineering, Technology and Innovation (ICE/ITMC)*. DOI: 10.1109/ICE/ITMC52061.2021.9570266.

Anna-Maria Nitsche, Bogdan Franczyk, Christian-Andreas Schumann. System Dynamics Modeling for Smart and Collaborative Last Mile Networks. 2022 IEEE 28th International Conference on Engineering, Technology and Innovation (ICE/ITMC) & 31st International Association For Management of Technology (IAMOT) Joint Conference | 978-1-6654-8817-4/22

Shen, Xiang, Li, Chen. Supply chain production planning and scheduling coordination using discrete event simulation. *Int j simul model* 24 (2025) 1, 147-158. <https://doi.org/10.2507/IJSIMM24-1-CO3>

Antuela A. Tako, Stewart Robinson. The application of discrete event simulation and system dynamics in the logistics and supply chain context. *Decision Support Systems* 52 (2012) 802–815. doi:10.1016/j.dss.2011.11.015

Bernhard J. Angerhofer Marios C. Angelides. System Dynamics modelling in supply chain management: research review.

Mustafa Can Camur, Aristotelis E. Thanos, Walter Yund, Chin-Yuan Tseng, Chelsea C. White. An integrated system and discrete event supply chain simulation framework for supply chain resilience with non-stationary pandemic demand. 2023 Winter Simulation Conference (WSC), DOI: 10.1109/WSC60868.2023.10407779

Leni Herdiani, Maun Jamaludin, Iman Sudirman, Widjajani, Ismet Rohimat. A System Dynamics Model of Frozen Fish Supply Chain. (*IJACSA*) *International Journal of Advanced Computer Science and Applications*, Vol. 16, No. 1, 2025.

Núñez Rodríguez, J.; Andrade Sosa, H.H.; Villarreal Archila, S.M.; Ortiz, A. System Dynamics Modeling in Additive Manufacturing Supply Chain Management. *Processes* **2021**, 9, 982. <https://doi.org/10.3390/pr9060982>

Ish Chaudhary, Amol Kumar, Bidisha Borkakaty, Rajeev Ranjan N., Omprakash Ranakoti. Simulation-Driven Optimization for Supply Chain Agility. *III. International Conference on Electrical, Computer and Energy Technologies (ICECET 2023) 16-17 November 2023, Cape Town-South Africa*.

Korder, B.; Maheut, J.; Konle, M. Simulation Methods and Digital Strategies for Supply Chains Facing Disruptions: Insights from a Systematic Literature Review. *Sustainability* **2024**, 16, 5957. <https://doi.org/10.3390/su16145957>

Khakdaman, M.; Dullaert, W.; Inghels, D.; van Keeken, M.; Wissink, P. A System Dynamics Supply Chain Analysis for the Sustainability Transition of European Rolled Aluminum Products. *Sustainability* **2024**, 16, 8892. <https://doi.org/10.3390/su16208892>

Giovanna Culot, Matteo Podrecca, Guido Nassimbeni. Artificial intelligence in supply chain management: A systematic literature review of empirical studies and research directions. *Computers in Industry* 162 (2024) 104132. <https://doi.org/10.1016/j.compind.2024.104132>

Viet Linh Dang, Shuping Wan, Jiequn Guo.

Third- party logistic outsourcing: A review of two decades of advancing decision-making approaches with an up-to-date three-layer criteria framework integrating environmental, social, and governance metrics. *Int. J. Production Economics* 284 (2025) 109615. <https://doi.org/10.1016/j.ijpe.2025.109615>

Jan Martin Spreitzenbarth, Christoph Bode, Heiner Stuckenschmidt. Artificial intelligence and machine learning in purchasing and supply management: A mixed-methods review of the state-of-the-art in literature and practice. *Journal of Purchasing & Supply Management* 30 (2024) 100896. <https://doi.org/10.1016/j.pursup.2024.100896>

Ahmed M. Khedr, Sheeja Rani S. Enhancing supply chain management with deep learning and machine learning techniques: A review. *Journal of Open Innovation: Technology, Market, and Complexity* 10 (2024) 100379. <https://doi.org/10.1016/j.joitmc.2024.100379>

Joanna Oleśków-Szłapka, Hubert Wojciechowski, Roman Domański, Grzegorz Pawlowski. Logistics 4.0 Maturity Levels Assessed Based on GDM (Grey Decision Model) and Artificial Intelligence in Logistics 4.0 -Trends and Future Perspective. *Procedia Manufacturing* 39 (2019) 1734–1742.

Joachim O. Gidiagba, Lagouge K. Tartibu, Modestus O. Okwu. A systematic review of machine learning applications in sustainable supplier selection. *Decision Analytics Journal* 14 (2025) 100547. <https://doi.org/10.1016/j.dajour.2025.100547>

Polo-Triana, S., Gutierrez, J.C., & Leon-Becerra, J. (2024). Integration of machine learning in the supply chain for decision making: A systematic literature review. *Journal of Industrial Engineering and Management*, 17(2), 344-372. <https://doi.org/10.3926/jiem.6403>

Robert N. Boute, Maxi Udenio. AI in Logistics and Supply Chain Management.

Arne Walter, Kamrul Ahsan, Shams Rahman. Application of artificial intelligence in demand planning for supply chains: a systematic literature review. *The International Journal of Logistics Management* Vol. 36 No. 3, 2025.

Marco Antonio Diaz Martinez, Reina Veronica Roman Salinas, Santos Ruiz Hernandez, Gabriela Cervantes Zubirias, Mario Alberto Morales Rodriguez. Industry 4.0- Applications of machine learning in the field of industrial engineering: Systematic review of the literature. *Journal of Optimization in Industrial Engineering*, Vol.17, Issue 2, Summer & Autumn 2024, 243-258 DOI: 10.22094/QJIE.2024.1107423

Xinyue Hao & Emrah Demir (2025) Artificial intelligence in supply chain management: enablers and constraints in pre-development, deployment, and post-development stages, *Production Planning & Control*, 36:6, 748-770, DOI: 10.1080/09537287.2024.2302482. <https://doi.org/10.1080/09537287.2024.2302482>

Douaioui, K.; Oucheikh, R.; Benmoussa, O.; Mabrouki, C. Machine Learning and Deep Learning Models for Demand Forecasting in Supply Chain Management: A Critical Review. *Appl. Syst. Innov.* **2024**, 7, 93. <https://doi.org/10.3390/asi7050093>

Delgado, F.; Garrido, S.; Bezerra, B.S. Barriers to Visibility in Supply Chains: Challenges and Opportunities of Artificial Intelligence Driven by Industry 4.0 Technologies. *Sustainability* **2025**, 17, 2998. <https://doi.org/10.3390/su17072998>

Juan Carlos Leonardo Nizama Zevallos, Giuseppe Converso, Alberto Delgado Hernández, Doria-Andrade. Machine Learning and Automation Systems to Improve Port and Maritime Logistics Efficiency. *Journal of Ecohumanism* 2025 Volume: 4, No: 1, pp. 625 – 631 ISSN: 2752-6798 (Print) | ISSN 2752-6801 (Online) <https://ecohumanism.co.uk/joe/ecohumanism> DOI: <https://doi.org/10.62754/joe.v4i1.5844>

Ali, S.M.; Rahman, A.U.; Kabir, G.; Paul, S.K. Artificial Intelligence Approach to Predict Supply Chain Performance: Implications for Sustainability. *Sustainability* **2024**, *16*, 2373. <https://doi.org/10.3390/su16062373>

Patalas-Maliszewska, J.; Szmolda, M.; Łosyk, H. Integrating Artificial Intelligence into the Supply Chain in Order to Enhance Sustainable Production—A Systematic Literature Review. *Sustainability* **2024**, *16*, 7110. <https://doi.org/10.3390/su16167110>

Christopher, M. (2016). *Logistics & Supply Chain Management* (5th ed.). Pearson.

Chopra, S., & Meindl, P. (2019). *Supply Chain Management: Strategy, Planning, and Operation*. Pearson.

Lambert, D. M., Cooper, M. C., & Pagh, J. D. (1998). Supply Chain Management: Implementation Issues and Research Opportunities. *The International Journal of Logistics Management*, *9*(2), 1–20.

Mentzer, J. T., DeWitt, W., Keebler, J. S., Min, S., Nix, N. W., Smith, C. D., & Zacharia, Z. G. (2001). Defining Supply Chain Management. *Journal of Business Logistics*, *22*(2), 1–25.

Simchi-Levi, D., Kaminsky, P., & Simchi-Levi, E. (2008). *Designing and Managing the Supply Chain*. McGraw-Hill.

Ivanov, D. (2021). Supply Chain Viability and the COVID-19 Pandemic. *International Journal of Production Research*.

Ellram, L. M., & Cooper, M. C. (1993). Characteristics of Supply Chain Management and the Implications for Purchasing and Logistics Strategy. *The International Journal of Logistics Management*.

Aamodt, A., Nygård, M., 1995. Different roles and mutual dependencies of data, information, and knowledge—an AI perspective on their integration. *Data Knowl. Eng.* *16* (3), 191–222.

Adya, M., Collopy, F., 1998. How effective are neural networks at forecasting and prediction? A review and evaluation. *J. Forecast.* *17* (5-6), 481–495.

Forrester, J.W., 2007. System dynamics—the next fifty years. *Syst. Dyn. Rev.* *23* (2–3), 359–370.

Kunc, M., Mortenson, M.J., Vidgen, R., 2018. A computational literature review of the field of System Dynamics from 1974 to 2017. J. Simul. 12 (2),115–127.

Sitografia

IBM. 2024. “La storia dell’AI”. <https://www.ibm.com/it-it/think/topics/history-of-artificial-intelligence>

Intelligenza Artificiale Italia. 2022. “Gli inverni dell'intelligenza artificiale IA”. <https://www.intelligenzaartificialeitalia.net/post/gli-inverni-dell-intelligenza-artificiale-ia>

PRISMA Statement. <https://www.prisma-statement.org/>

IBM. 2026. “La guida 2026 al machine learning”. <https://www.ibm.com/it-it/think/machine-learning#605511093>