
**UNIVERSITA' DI UNIGE
SCUOLA DI SCIENZE SOCIALI
DIPARTIMENTO DI ECONOMIA**



Tesi di laurea magistrale
in
Management

**L'applicazione del
Machine Learning
nel retail**

Relatore: Nicoletta Buratti

Candidato: Jacopo Venere

**Anno accademico
2024/25**

Sommario

ABSTRACT	4
INTRODUZIONE	6
METODOLOGIA	9
CAPITOLO I: Il Machine Learning: principi, tecniche e strumenti	13
1.1 Definizione di Machine Learning	13
1.2 Evoluzione del Machine Learning	15
1.3 I tre principali problemi che il Machine Learning si pone di risolvere: regressione, classificazione e regressione	18
1.3.1 La regressione	18
1.3.2 La classificazione	19
1.3.3 La clusterizzazione	20
1.4 Gli algoritmi di Machine Learning	22
1.5 Approfondimento teorico su regressione, classificazione e clusterizzazione	25
1.5.1 La regressione: modelli e algoritmi principali	25
1.5.2 La classificazione: approcci e tecniche applicative	29
1.5.3 La clusterizzazione: metodi e strumenti di analisi dei dati	34
1.6 Costruzione dei modelli di Machine Learning	37
1.6.1 Dal problema al modello: il cosa	37
1.6.2 La realizzazione del modello: il come	39
1.6.3 Confronto tra metodologie e criteri di scelta	41
CAPITOLO II: L'uso del Machine Learning nel retail	44
2.1 Il Machine Learning nel retail	46
2.2 Il Machine Learning come strumento di supporto alle strategie di pricing dinamico nel retail	49
2.2.1 Il pricing come un problema di regressione	50
2.2.2 L'ottimizzazione dinamica dei prezzi nel retail online attraverso tecniche di Machine Learning	53
2.2.3 L'integrazione di IoT e Machine Learning per l'analisi in tempo reale dell'elasticità dei prezzi	55
2.2.4 Prospettive evolutive e sfide	57
2.3 Il Machine Learning per la segmentazione della clientela nel retail	59
2.3.1 La natura dinamica dei segmenti di clientela	61
2.3.2 Machine learning per la segmentazione dei clienti e l'elaborazione di strategie di marketing	63
2.3.3 Il ruolo del Machine Learning nell'analisi del comportamento dei clienti	66

2.4 Previsione della domanda nel retail: approcci di Machine Learning e implicazioni gestionali	69
2.4.1 Approcci di Machine Learning e pipeline dati per la previsione della domanda	70
2.4.2 Applicazione del Machine Learning alla previsione della domanda giornaliera nel retail	72
2.4.3 Previsioni di domanda per la gestione dello stock nel retail: approcci di Machine Learning.....	74
CAPITOLO III: Il caso studio Carrefour Italia	76
3.1: Evoluzione storica del Gruppo Carrefour.....	77
3.2: Visione tecnologica del Gruppo Carrefour	80
3.2.1 Struttura IT Italia	82
3.2.2 Il ruolo del Machine Learning in Carrefour Italia	84
3.3 La segmentazione della clientela in Carrefour Italia	85
3.3.1 Segmentazione comportamentale, KPI e leve di marketing	87
3.3.2 Il caso Carrefour Italia rispetto alla letteratura	88
3.4 La previsione della domanda in Carrefour Italia	90
3.4.1 Il caso Carrefour Italia rispetto alla letteratura	92
3.5 Implicazioni organizzative e sfide	95
CONCLUSIONI.....	97
BIBLIOGRAFIA.....	100
SITOGRAFIA	104

ABSTRACT

L'elaborato analizza l'applicazione ed il conseguente impatto del Machine Learning (ML) nel settore del retail. In particolare si propone di comprendere come questa tecnologia stia trasformando i processi gestionali e decisionali delle imprese attraverso un approccio sempre più data driven. La scelta dell'argomento nasce dall'interesse per l'applicazione delle AI nei processi di decisione aziendali.

La ricerca si è basata su una revisione della letteratura finalizzata ad individuare i principali ambiti applicativi del Machine Learning nel retail:

- pricing dinamico,
- segmentazione della clientela,
- previsione della domanda.

A integrazione del framework teorico, è stato condotto un caso studio su Carrefour Italia, sviluppato tramite interviste semi-strutturate condotte con la Chief Data Officer dell'azienda.

Le criticità emerse nell'applicazione del Machine Learning in un contesto aziendale sono legate alla qualità e quantità dei dati, all'interpretabilità dei modelli e al change management che ne consegue.

I risultati emersi evidenziano comunque come il Machine Learning costituisca, ormai, un'imprescindibile leva strategica per migliorare l'efficacia delle decisioni, a condizione che sussista un forte allineamento tra tecnologia e obiettivi di business, tassello di fondamentale importanza per la creazione di valore.

This paper analyzes the application and impact of machine learning (ML) in the retail sector. In particular, it aims to understand how this technology is transforming business management and decision-making processes through an increasingly data-driven approach. The choice of topic stems from an interest in the application of AI in business decision-making processes.

The research was based on a review of the literature aimed at identifying the main areas of application of Machine Learning in retail:

- dynamic pricing,
- customer segmentation,
- demand forecasting.

To complement the theoretical framework, a case study was conducted on Carrefour Italia, developed through semi-structured interviews with the company's Chief Data Officer.

The critical issues that emerged in the application of machine learning in a business context are related to the quality and quantity of data, the interpretability of models, and the resulting change management.

However, the results show that machine learning is now an essential strategic lever for improving the effectiveness of decisions, provided that there is a strong alignment between technology and business objectives, which is a key factor in creating value.

INTRODUZIONE

Il presente elaborato si propone di analizzare in modo sistematico e approfondito le applicazioni del Machine Learning nel settore retail, con l'obiettivo di comprendere come questa tecnologia stia trasformando i processi decisionali, gestionali e strategici delle imprese contemporanee in esso operanti. Il lavoro nasce dall'esigenza di indagare un tema di grande attualità, collocato all'intersezione tra innovazione tecnologica e gestione aziendale, due ambiti sempre più interconnessi nel contesto competitivo odierno.

Nel primo capitolo viene introdotto il concetto di Machine Learning all'interno della più ampia disciplina dell'Intelligenza Artificiale, mettendo in luce la sua natura analitica e predittiva. Dopo un'analisi teorica della materia, viene presentato un excursus storico che ne ripercorre l'evoluzione, dalle prime sperimentazioni degli anni Cinquanta, con i contributi pionieristici di studiosi quali Alan Turing, Arthur Samuel e Frank Rosenblatt, fino agli sviluppi contemporanei legati alle reti neurali profonde e ai modelli di apprendimento avanzato.

Il capitolo prosegue con l'analisi dei principali problemi affrontati dal Machine Learning:

- Regressione
- Classificazione
- Clusterizzazione

illustrandone le caratteristiche, le finalità e gli ambiti di applicazione.

Viene poi approfondito il tema degli algoritmi di apprendimento, descritti come l'insieme di procedure matematiche che permettono ai sistemi informatici di estrarre conoscenza dai dati. In particolare si analizzano le diverse forme di apprendimento supervisionato, non supervisionato, semi-supervisionato e per rinforzo, mettendo in evidenza le differenze metodologiche e gli scenari applicativi di ciascuna. Viene infine condotta un'analisi teorica più estesa sulle tecniche di regressione, classificazione e clusterizzazione, con esempi concreti che ne mostrano il funzionamento e le potenzialità in ambito decisionale.

Il secondo capitolo si focalizza sul ruolo del Machine Learning nel settore retail, contesto particolarmente interessante per la varietà di dati generati e per l'impatto diretto sulle strategie aziendali.

La prima parte introduce il concetto di Retail Analytics, illustrando come l'adozione di tecnologie di analisi dei dati, Big Data e Machine Learning stia modificando profondamente la gestione del punto vendita e delle piattaforme di e-commerce. Si evidenzia come l'utilizzo sistematico dei dati consenta di ottimizzare la pianificazione, la logistica, la gestione delle scorte e la relazione con la clientela, favorendo un approccio sempre più data-driven alle decisioni operative e strategiche.

L'analisi si concentra poi su tre principali ambiti applicativi del Machine Learning nel retail:

1. Il pricing dinamico, considerato una delle aree più innovative, viene interpretato come un problema di regressione volto a determinare il prezzo ottimale dei prodotti in funzione delle condizioni di mercato, delle strategie dei concorrenti e della domanda prevista. Vengono illustrati modelli predittivi, come il Random Forest Regressor, capaci di elaborare grandi volumi di dati e di supportare decisioni di prezzo precise e adattive.
2. La segmentazione della clientela, che utilizza tecniche di clusterizzazione per individuare gruppi omogenei di consumatori sulla base dei comportamenti d'acquisto e delle preferenze, consentendo strategie di marketing personalizzate e più efficaci.
3. La previsione della domanda, che impiega modelli di apprendimento supervisionato per stimare l'andamento futuro delle vendite e ottimizzare la gestione delle scorte, riducendo sprechi e inefficienze.

Ogni sezione approfondisce sia gli aspetti tecnici e metodologici sia le implicazioni gestionali derivanti dall'adozione del Machine Learning, evidenziando le sfide legate alla qualità dei dati, alla scelta dei modelli e alla loro integrazione nei processi aziendali. Il capitolo si conclude sottolineando come il Machine Learning rappresenti non solo uno strumento tecnologico, ma anche un cambiamento culturale nel modo di interpretare i dati e prendere decisioni consapevoli all'interno delle imprese.

All'interno del terzo capitolo viene presentato il caso studio di Carrefour Italia, collocandolo nel più ampio contesto organizzativo e tecnologico del Gruppo. Viene delineata la struttura dell'area IT, evidenziandone l'articolazione, le principali responsabilità funzionali e il modello di coordinamento tra livello centrale e di singola country, nonché il ruolo strategico della data platform come fondamento delle iniziative data-driven.

Successivamente il capitolo approfondisce due principali ambiti applicativi del Machine Learning: la segmentazione della clientela e la previsione della domanda. Per ciascun ambito vengono esaminate le motivazioni di business che hanno guidato l'adozione di tale tecnologia, le tipologie di dati utilizzati, le logiche operative sottostanti ai modelli e i benefici riscontrati, con particolare attenzione agli impatti sulle strategie di marketing, sui processi di riordino e sulla gestione dello stock.

Il capitolo si conclude con una riflessione sulle principali criticità emerse nel percorso di implementazione e sulle prospettive evolutive del Machine Learning in azienda. Vengono discusse le implicazioni legate all'interpretabilità dei modelli, alla governance del dato e al ruolo strategico delle tecnologie data-driven, sottolineando come il machine learning rappresenti uno strumento abilitante da applicare in modo mirato, all'interno di una più ampia strategia orientata al valore.

METODOLOGIA

Il presente elaborato adotta un approccio di revisione sistematica della letteratura, finalizzato a raccogliere, analizzare e sintetizzare in modo critico i principali contributi scientifici relativi all'applicazione del Machine Learning nel settore retail. La scelta di questo tema è maturata a seguito di un periodo di studio sulle nuove tecnologie applicate al mondo del retail, giungendo alla conclusione che il Machine Learning rappresenta una delle soluzioni più versatili e promettenti, con rilevanti implicazioni sia di natura gestionale che operativa.

Gli obiettivi principali della ricerca sono: individuare gli ambiti di applicazione del Machine Learning nel settore retail, analizzarne le tecniche più efficaci nei diversi contesti operativi e approfondire le opportunità, i rischi e le criticità derivanti dall'adozione di tale tecnologia. Le domande di ricerca che guidano l'analisi sono le seguenti:

- in quali ambiti del retail il Machine Learning è maggiormente applicato?
- quali tecniche risultano più efficaci nei diversi contesti operativi?
- quali sfide e opportunità emergono dall'adozione di tali tecnologie?

La revisione segue l'approccio sistematico articolato in quattro fasi sequenziali, Scoping, Keyword Searching, Citation Searching e Reporting basato su una metodologia consolidata per la conduzione di revisioni sistematiche.

1. Scoping

La fase di scoping definisce l'ambito e le finalità della revisione, chiarendo i concetti chiave e le domande di ricerca. Attraverso ricerche esplorative e analisi preliminari, sono stati individuati i termini rilevanti, i criteri di inclusione ed esclusione e i primi studi di riferimento. Tale fase ha garantito coerenza metodologica e una delimitazione appropriata del campo di indagine.

2. Keyword Searching

In questa fase sono state costruite stringhe di ricerca basate su concetti e sinonimi, combinate mediante operatori booleani (AND, OR) e specifici filtri. L'obiettivo è stato quello di bilanciare completezza e precisione nella selezione delle fonti. La

qualità della ricerca è stata verificata tramite controlli sulla capacità delle stringhe di individuare studi pertinenti e sull'adeguatezza della loro ampiezza. I database scelti hanno garantito un'adeguata copertura e funzionalità per il reperimento dei dati.

3. Citation Searching

La ricerca per citazioni ha permesso di ampliare il campione di studi, individuando ulteriori contributi tramite collegamenti bibliografici. Sono state condotte sia ricerche backward (fonti citate) sia forward (studi che citano le opere individuate), al fine di includere lavori fondativi e più recenti. Tale tecnica si è rivelata particolarmente utile per argomenti caratterizzati da terminologia ampia o ambigua, contribuendo ad aumentare la rappresentatività complessiva della revisione.

4. Reporting

La fase di reporting ha previsto la documentazione completa e trasparente dell'intero processo di ricerca. Sono stati descritti i database consultati, le strategie di ricerca adottate, i criteri di selezione e le fasi di screening, utilizzando schemi che ne garantissero la riproducibilità. Una rendicontazione accurata assicura la tracciabilità delle scelte metodologiche e rafforza la solidità complessiva della revisione.

La raccolta dei dati è iniziata nel settembre 2025 con un'analisi approfondita del concetto di Machine Learning e, successivamente, delle sue applicazioni nel contesto retail. I database consultati sono stati Scopus, Web of Science, Google Scholar, The Lens, uno per tutto, oltre a manuali e testi cartacei.

Le parole chiave utilizzate per la ricerca sono state: machine learning, retail, dynamic pricing, demand prediction, forecasting, customer segmentation e challenges, combinate tramite gli operatori booleani AND e OR. Sono stati inclusi articoli pubblicati tra il 2010 e il 2025, redatti in lingua inglese e italiana.

Sono stati selezionati esclusivamente studi pubblicati su riviste scientifiche peer-reviewed, pertinenti al tema dell'applicazione del Machine Learning nel retail. Sono stati invece esclusi articoli non scientifici e lavori non accessibili integralmente.

Dopo una prima analisi dei dati, delle definizioni e dei concetti, è stato condotto uno studio approfondito sul funzionamento del Machine Learning che ha portato all'individuazione di tre macroaree principali di applicazione nel contesto retail:

- dynamic pricing
- customer segmentation
- demand forecasting.

Questa classificazione ha consentito un'analisi più strutturata e comparativa delle fonti.

La metodologia adottata ha permesso di consultare un ampio numero di studi; tuttavia un limite della presente revisione è rappresentato dalla possibile esclusione di lavori rilevanti non indicizzati nei database utilizzati.

La scelta del caso studio di Carrefour Italia è stata dettata sia dal ruolo e dall'importanza che l'azienda ricopre nel panorama italiano del retail, più in particolare nell'ambito della grande distribuzione organizzata (GDO), che dall'elevata maturità e spiccato orientamento tecnologico e data-driven dell'azienda. La struttura dell'azienda e il campo in cui opera risultano essere un fit perfetto per l'applicazione del machine learning, grazie all'elevata quantità di dati a disposizione e al rapporto diretto con il cliente.

Il caso studio è stato elaborato sulla base di due interviste semi-strutturate condotte con la Chief Data Officer di Carrefour Italia, effettuate nel corso del mese di febbraio del 2026. Il ruolo dell'intervistata è inserito all'interno della funzione IT Italia, e riporta direttamente al Chief Information Officer, membro del Comitato Esecutivo (Comex). Le sue responsabilità comprendono l'intero ambito dei dati e delle attività di analytics, includendo anche lo sviluppo di use case e, in alcuni casi, applicazioni di Machine Learning e intelligenza artificiale.

Tutte le informazioni riportate nel capitolo fanno riferimento alla situazione di Carrefour Italia antecedente all'acquisizione avvenuta nel dicembre 2025 da parte di NewPrinces Group.

L'utilizzo di un unico caso studio necessita di alcune importanti premesse: le conclusioni non possono infatti essere generalizzate e riportate all'uso del Machine

Learning in ogni tipo di azienda a prescindere dal mercato in cui opera. I risultati ottenuti sono specifici dell'analisi nel retail e più specificatamente del contesto in cui opera Carrefour Italia.

CAPITOLO I: Il Machine Learning: principi, tecniche e strumenti

Il capitolo ha l'obiettivo di fornire il quadro teorico di riferimento per comprendere le applicazioni del Machine Learning analizzate poi nei capitoli successivi. Vengono introdotti i concetti chiave relativi ad esso, i principali problemi per il quale viene utilizzato, i relativi algoritmi di apprendimento e le diverse modalità con cui i modelli di Machine Learning vengono costruiti.

Il fine non è fornire una trattazione esaustiva sul Machine Learning, ma fornire le informazioni necessarie per poter comprendere ed affrontare correttamente tutti gli ambiti trattati nei capitoli successivi.

1.1 Definizione di Machine Learning

L'intelligenza artificiale può essere immaginata come una moneta a due facce. Da un lato, troviamo il Machine Learning, la componente più analitica e razionale, che si fonda sull'elaborazione e sull'interpretazione di grandi quantità di dati al fine di trarne conoscenza e previsioni utili. Dall'altro lato, l'intelligenza artificiale generativa rappresenta l'aspetto più creativo e intuitivo, capace di produrre nuovi contenuti (testi, immagini, musica o soluzioni progettuali) ampliando così i confini dell'innovazione tecnologica. Queste due dimensioni dell'IA possono essere paragonate ai due emisferi del cervello umano: quello sinistro, logico e strutturato, associato al Machine Learning, e quello destro, creativo e immaginativo, riconducibile all'IA generativa.

Sebbene il Machine Learning sia spesso percepito come un elemento tecnico e meno visibile dell'intelligenza artificiale, esso costituisce la base operativa che consente a molte tecnologie di supportare le decisioni quotidiane. Esempi concreti sono i sistemi di raccomandazione di piattaforme come Netflix o gli algoritmi di navigazione di Google Maps, che selezionano il percorso più efficiente sulla base dei dati raccolti in tempo reale. In questi casi, l'algoritmo "impara" dai comportamenti passati per ottimizzare le scelte future, in modo analogo a come l'essere umano perfeziona le proprie decisioni attraverso l'esperienza.

Il concetto di apprendimento, nel senso più ampio, si riferisce al processo mediante il quale individui o sistemi acquisiscono nuove conoscenze, competenze o comportamenti, modificando le proprie risposte in base all'esperienza. Nell'uomo, tale

processo è stato interpretato da diverse teorie psicologiche, tra cui il comportamentismo, il cognitivismo, il costruttivismo, l'apprendimento esperienziale e quello sociale. Le macchine, al contrario, non apprendono dall'esperienza diretta, ma dall'elaborazione sistematica dei dati.

Il Machine Learning rappresenta dunque quella branca dell'intelligenza artificiale che consente ai sistemi informatici di migliorare progressivamente le proprie prestazioni senza essere esplicitamente programmati per farlo. In altre parole, i computer possono adattare i propri comportamenti e decisioni sulla base dei risultati ottenuti, incrementando la propria accuratezza nel tempo.

Storicamente, il termine Machine Learning è stato introdotto nel 1959 da Arthur Samuel, che lo definì come il campo di studio volto a fornire ai computer la capacità di apprendere automaticamente dall'esperienza. Successivamente, Tom Mitchell (1997) ne ha fornito una definizione più rigorosa, tuttora ampiamente citata in ambito accademico: un programma per computer può essere considerato capace di apprendere da un'esperienza E , rispetto a un compito T e a una misura di prestazione P , se la sua capacità di svolgere T , valutata tramite P , migliora con l'esperienza E .

In sintesi, il Machine Learning consente ai sistemi di elaborazione di adattarsi autonomamente a contesti complessi e mutevoli, rendendoli strumenti fondamentali non solo per l'evoluzione dell'intelligenza artificiale, ma anche per l'analisi economica e la gestione dei processi decisionali basati sui dati.

1.2 Evoluzione del Machine Learning

I concetti di Intelligenza Artificiale e Machine Learning non sono recenti, ma affondano le proprie radici in oltre sei decenni di ricerca e sviluppo condotti da informatici, ingegneri, ricercatori, studenti e professionisti del settore. Le basi matematiche del machine learning si fondano principalmente sull'algebra, sulla statistica e sulla teoria della probabilità.

Lo sviluppo significativo di queste discipline ebbe inizio tra gli anni Cinquanta e Sessanta, grazie ai contributi pionieristici di studiosi quali Alan Turing, John McCarthy, Arthur Samuel, Allen Newell e Frank Rosenblatt. Arthur Samuel realizzò uno dei primi modelli funzionanti di Machine Learning attraverso un programma in grado di apprendere strategie per il gioco della dama, mentre Frank Rosenblatt sviluppò il Perceptron, un algoritmo ispirato al funzionamento dei neuroni biologici che costituì la base per il successivo sviluppo delle reti neurali artificiali.

Le prime fondamenta teoriche del campo risalgono agli anni Cinquanta, quando Alan Turing propose il celebre Turing Test come criterio per valutare l'intelligenza di una macchina, stabilendo che un computer avrebbe potuto essere considerato intelligente qualora fosse riuscito a convincere un osservatore umano di trovarsi di fronte a un altro essere umano. Nel 1952 Arthur Samuel sviluppò un algoritmo di apprendimento capace di giocare autonomamente a dama e di migliorare le proprie prestazioni attraverso l'auto-addestramento. Nel 1956 Martin Minsky, John McCarthy, Claude Shannon e Nathan Rochester organizzarono la conferenza di Dartmouth, comunemente riconosciuta come l'atto di nascita ufficiale dell'Intelligenza Artificiale.

Nel 1958 Rosenblatt progettò il Perceptron, ponendo le basi per le reti neurali artificiali, mentre nel 1967 venne introdotto l'algoritmo del Nearest Neighbor, utilizzato per il riconoscimento dei pattern. Alla fine degli anni Settanta, studenti dell'Università di Stanford svilupparono lo "Stanford Cart", un robot in grado di muoversi autonomamente evitando ostacoli. Nel 1981 Gerald Dejong introdusse l'Explanation Based Learning (EBL), un metodo che consentiva ai computer di analizzare i dati di addestramento e formulare regole per eliminare informazioni irrilevanti.

Negli anni successivi Terry Sejnowski sviluppò NetTalk, un sistema capace di apprendere la pronuncia delle parole in lingua inglese, grazie a un processo di

apprendimento assimilabile a quello dei bambini. Durante gli anni Novanta l'attenzione del machine learning si spostò progressivamente da un approccio basato sulla conoscenza a uno data-driven, consentendo l'analisi di sempre più grandi volumi informativi. Nel 1997 il computer Deep Blue di IBM sconfisse il campione mondiale di scacchi Gary Kasparov, dimostrando concretamente il potenziale competitivo dei sistemi intelligenti; questo risultato fu stato possibile grazie ad innovazioni teoriche e tecniche che alimentarono l'interesse verso l'intelligenza Artificiale, sia dal punto di vista economico che accademico.

Una delle sfide più grandi del tempo era quella di trasferire di traslare le capacità tecniche e i successi ottenuti in campo sperimentale con l'IA, in applicazioni pratiche ed economicamente vantaggiose. Queste problematiche scaturivano soprattutto dalla presenza di hardware troppo limitati e difficoltà nel comprendere, e quindi imitare, il pensiero umano. Questo ha permesso di capire meglio quelli che erano sia i limiti che le potenzialità dell'intelligenza artificiale, portando il focus dell'innovazione verso il Machine Learning, l'elaborazione del linguaggio naturale e le reti neurali.

Il termine Deep Learning venne coniato nel 2006 da Geoffrey Hinton per descrivere una sottocategoria del Machine learning che, attraverso reti neurali profonde composte da più strati, è in grado di imitare il comportamento del cervello umano, apprendere ed elaborare rappresentazioni complesse dei dati e creare modelli di previsione.

Numerose aziende tecnologiche continuarono a investire nello sviluppo di piattaforme avanzate di machine learning. Nel 2015 Amazon lanciò la propria piattaforma di Machine Learning, Microsoft sviluppò il Distributed Machine Learning Toolkit per distribuire i calcoli su più computer, ed Elon Musk e Sam Altman fondarono OpenAI, organizzazione inizialmente no-profit, volta a promuovere la ricerca sull'Intelligenza Artificiale. Nel 2016 Google presentò DeepMind, il cui programma AlphaGo divenne il primo sistema in grado di sconfiggere un giocatore professionista di Go, combinando tecniche di machine learning e ricerca ad albero. L'anno successivo Google introdusse applicazioni quali Google Lens, Google Clips, Google Home Mini e i telefoni Nexus, tutte basate su machine learning e deep learning; parallelamente Nvidia introdusse le GPU come motore del deep learning, mentre Apple sviluppò HomePod, un dispositivo interattivo fondato su tecnologie di apprendimento automatico.

Quello che ha reso possibile questa rivoluzione tecnologica è la “datification”, ovvero dei processi che permettono di trasformare in dati digitali aspetti del mondo reale. La possibilità di accedere a grandi volumi di dati, assieme ad una sempre più potente potenza di calcolo ha permesso la creazione di modelli di AI sempre più avanzati. I campi di applicazione dell’AI sono aumentati in modo esponenziale, grazie alle reti neurali profonde si è riusciti ad avviare analisi molto avanzate sia di immagini, di linguaggio e pattern complessi, permettendo all’Intelligenza Artificiale di fare il suo ingresso anche in campi come gli assistenti virtuali, la guida autonoma, la medicina personalizzata, così come la previsione dei trend di mercato e la personalizzazione dei servizi online.

1.3 I tre principali problemi che il Machine Learning si pone di risolvere: regressione, classificazione e regressione

Il Machine Learning si articola in diverse categorie di problemi, che si distinguono in base alla natura dei dati in ingresso e agli obiettivi del modello. In particolare, i tre principali problemi che questa disciplina si propone di risolvere sono la regressione, la classificazione e il clustering.

La regressione riguarda la previsione di valori numerici continui, come prezzi, quantità o tempi. La classificazione, invece, si concentra sull'assegnazione di elementi a determinate categorie o classi predefinite (ad esempio, distinguere tra clienti soddisfatti e insoddisfatti). Infine, il clustering è una tecnica di apprendimento non supervisionato che mira a raggruppare elementi simili tra loro senza conoscere in anticipo le categorie di appartenenza.

Queste tre tipologie rappresentano le fondamenta operative del machine learning e trovano applicazione in numerosi contesti economici e aziendali, dalla previsione della domanda alla segmentazione dei mercati, fino all'analisi dei comportamenti dei consumatori.

1.3.1 La regressione

Il machine learning, grazie alla capacità di elaborare grandi quantità di dati (spesso superiori alla capacità di analisi umana) è in grado di formulare previsioni molto accurate. Questo tipo di problema viene affrontato attraverso la *regressione*, una tecnica che si basa sull'analisi di variabili numeriche e continue per stimare quantità o valori, rispondendo a domande di tipo quantitativo come “quanto” o “quanti”.

La regressione è quindi una tipologia di problema di Machine Learning che si prefigge di prevedere il valore di una variabile continua (ovvero una variabile che può assumere un numero infinito di valori all'interno di un intervallo definito) basandosi su dati storici. La variabile target, o variabile dipendente, rappresenta ciò che il modello cerca di prevedere, mentre le variabili indipendenti sono i fattori che influenzano tale risultato.

Un esempio concreto è rappresentato da Airbnb, dove il modello di Machine Learning utilizza diverse variabili indipendenti, come la posizione dell'immobile, la

stagionalità, la domanda locale, le caratteristiche dell'alloggio, le recensioni e la presenza di eventi locali, per stimare il prezzo di affitto giornaliero, che costituisce la variabile target.

Allo stesso modo, Google Maps utilizza dati storici sul traffico e variabili indipendenti come l'orario della giornata, il giorno della settimana, le festività e gli eventi speciali per stimare il tempo di percorrenza, che rappresenta la variabile target.

La regressione, pertanto, costituisce uno degli strumenti fondamentali del machine learning, poiché consente di trasformare i dati in previsioni quantitative, fornendo un supporto concreto ai processi decisionali e di analisi economica.

1.3.2 La classificazione

Piattaforme come Netflix e Gmail riescono a conoscere con notevole precisione le preferenze e le necessità degli utenti grazie all'applicazione del Machine Learning, in particolare attraverso la risoluzione di problemi di Classificazione.

In modo analogo alla regressione, la classificazione rappresenta una tipologia di problema in cui il Machine Learning si prefigge di prevedere il valore di una variabile discreta, ovvero una variabile che può assumere valori distinti e non continui, basandosi su dati storici. In questo tipo di problemi, l'output può appartenere a un numero finito di classi predefinite, come Sì/No o Vero/Falso. In base al numero di categorie considerate, si distinguono problemi di classificazione binaria e multi-classe.

Applicazioni come Netflix e Gmail utilizzano questo approccio per migliorare l'esperienza degli utenti. Nel caso di Netflix, le variabili indipendenti comprendono le scelte di visualizzazione precedenti, le valutazioni assegnate ai contenuti e persino i programmi che l'utente ha deciso di interrompere. Sulla base di questi dati, il modello di classificazione elabora una variabile target, costituita da una lista di raccomandazioni personalizzate.

Allo stesso modo, Gmail impiega la classificazione per filtrare e identificare i messaggi di spam. Analizzando miliardi di e-mail, il sistema riesce a riconoscere le caratteristiche ricorrenti dei messaggi indesiderati, come la presenza di determinate parole chiave, schemi testuali o comportamenti dell'utente in relazione a e-mail simili ricevute in passato. In questo caso, la variabile target è composta da due stati possibili:

spam o non spam. Il modello si propone quindi di prevedere correttamente in quale delle due categorie rientri ciascun messaggio.

In entrambi gli esempi, la classificazione agisce come un filtro che consente di distinguere ciò che è rilevante per l'utente da ciò che non lo è. Essa rappresenta dunque un chiaro esempio di come il Machine Learning possa contribuire a migliorare l'esperienza online, personalizzando i servizi e rispondendo in modo sempre più preciso alle esigenze individuali degli utenti.

1.3.3 La clusterizzazione

La clusterizzazione, a differenza della regressione e della classificazione, non mira a prevedere il valore di una variabile attraverso l'analisi di dati storici, ma si concentra sul raggruppamento dei dati in cluster, in modo tale che ciascun gruppo contenga elementi con caratteristiche simili. L'obiettivo è identificare strutture intrinseche nei dati, creando cluster basati sulla similarità tra le osservazioni. Una volta addestrato, l'algoritmo è in grado di assegnare nuovi dati a uno dei cluster esistenti.

Un esempio applicativo è rappresentato da Amazon, dove ogni clic, ricerca o acquisto contribuisce a creare un profilo dinamico delle preferenze degli utenti, utilizzato dalla piattaforma per suggerire prodotti. Le raccomandazioni non si limitano agli articoli già selezionati dall'utente, ma includono anche prodotti correlati che potrebbero suscitare interesse. Questo avviene attraverso l'analisi dei modelli di acquisto di utenti con gusti simili. I prodotti vengono così raggruppati in cluster con caratteristiche comuni, e quando un utente seleziona un articolo appartenente a un cluster, la piattaforma propone anche gli altri articoli del gruppo, migliorando l'esperienza di acquisto e aumentando la probabilità di trovare prodotti rilevanti.

Analogamente, Spotify adotta un approccio simile nel contesto musicale. Analizzando le tracce ascoltate dall'utente, il genere, l'artista e le abitudini di ascolto di utenti con gusti simili, la piattaforma genera playlist personalizzate. Queste playlist rappresentano cluster di brani che non si limitano a riproporre contenuti già noti, ma introducono anche nuovi artisti e generi, ampliando i gusti musicali dell'utente.

Dietro queste esperienze di personalizzazione vi è un costante lavoro di analisi e apprendimento da parte degli algoritmi, che elaborano quantità di dati impossibili da

gestire manualmente. Grazie a questo processo, piattaforme come Amazon e Spotify sono in grado di offrire selezioni altamente personalizzate, perfettamente allineate ai gusti e alle preferenze degli utenti.

1.4 Gli algoritmi di Machine Learning

Un algoritmo di Machine Learning può essere definito come un insieme di regole e procedure matematiche utilizzate per elaborare dati e trarre conoscenza da essi. Tali algoritmi possono differire notevolmente per complessità e vengono selezionati in funzione del tipo di problema da affrontare e delle caratteristiche dei dati disponibili. In generale, un algoritmo rappresenta una sequenza strutturata di istruzioni in grado di apprendere dai dati storici.

A differenza degli algoritmi tradizionali, che seguono istruzioni esplicite per eseguire un compito specifico, come la gestione dell'inventario di un magazzino o l'esecuzione di un ciclo di lavaggio impostato su un determinato programma, gli algoritmi di machine learning sono progettati per migliorare progressivamente le proprie prestazioni attraverso l'analisi di grandi quantità di dati. Ciò avviene senza la necessità di una programmazione esplicita per ciascun compito.

In questo contesto, è possibile distinguere due principali modalità di apprendimento: l'apprendimento supervisionato e quello non supervisionato.

1.4.1 Apprendimento supervisionato

L'apprendimento supervisionato rappresenta la forma di apprendimento maggiormente in linea con la concezione tradizionale di "imparare per esempi". In questo approccio, un algoritmo di Machine Learning viene addestrato utilizzando un dataset già corredato di etichette, che specificano la categoria o il valore corretto associato a ciascun dato di input.

Ad esempio, al modello vengono mostrate numerose immagini di mele, differenti per forma e colore, ciascuna accompagnata dalla propria etichetta "mela". Lo stesso processo viene ripetuto con altre categorie, come le banane. Dopo la fase di addestramento, il modello sarà in grado di riconoscere una nuova immagine di una mela, basandosi sulle caratteristiche visive apprese, quali forma e tonalità cromatica.

Questo processo richiama da vicino il modo in cui i bambini apprendono a riconoscere gli oggetti: attraverso esposizioni ripetute e l'associazione di nomi, come quando un genitore indica un animale dicendo "questo è un gatto", senza dover spiegare le differenze strutturali con altri animali.

L'apprendimento supervisionato costituisce la base di molte tecnologie intelligenti oggi di uso comune. Servizi come Gmail, ad esempio, impiegano questo approccio per distinguere automaticamente i messaggi di posta indesiderata da quelli legittimi, analizzando milioni di esempi già etichettati. Allo stesso modo, piattaforme come Airbnb sfruttano modelli supervisionati per offrire raccomandazioni personalizzate, basandosi su dati storici relativi alle prenotazioni, alle preferenze e alle esperienze degli utenti.

Questo tipo di apprendimento è alla base di due principali categorie di problemi: la regressione e la classificazione.

1.4.2 Apprendimento non supervisionato

L'apprendimento non supervisionato costituisce una branca del Machine Learning che opera su dati privi di etichette. La principale sfida di questo approccio consiste nel consentire al modello di individuare autonomamente strutture e relazioni latenti all'interno dei dati. A differenza dell'apprendimento supervisionato, in questo caso non esistono etichette predefinite, come "questa è una mela", che guidino il processo di apprendimento verso una risposta specifica. È il modello stesso che, analizzando i dati, riconosce schemi ricorrenti e li organizza in gruppi o cluster significativi.

Ad esempio, un algoritmo può esaminare immagini di diversi tipi di frutta e, senza sapere in anticipo se si tratti di mele, banane o pere, individuare somiglianze basate su caratteristiche come forma, colore o dimensione, raggruppando così gli oggetti in modo coerente.

Questo meccanismo può essere paragonato al modo in cui un bambino apprende a distinguere e classificare gli oggetti che lo circondano. Anche senza ricevere spiegazioni esplicite, il bambino tende a raggruppare oggetti simili in base a proprietà comuni. Ad esempio, può notare che automobili, motociclette e biciclette condividono alcune caratteristiche, come il numero di ruote o la funzione di trasporto, e creare spontaneamente categorie sulla base di tali osservazioni.

Allo stesso modo, l'apprendimento non supervisionato permette ai modelli di identificare strutture nascoste nei dati senza alcuna guida esterna. Questo approccio è alla base di molti sistemi di raccomandazione moderni, come quelli utilizzati da Spotify per suggerire brani musicali o da Amazon per proporre prodotti, nei quali gli oggetti vengono

raggruppati in base alla somiglianza tra preferenze degli utenti o caratteristiche degli articoli.

L'apprendimento non supervisionato riveste quindi un ruolo fondamentale per la sua capacità di individuare schemi e relazioni all'interno di insiemi di dati complessi e disordinati, costituendo il fondamento dei processi di clusterizzazione.

1.4.3 Altri tipi di apprendimento

Oltre agli approcci supervisionato e non supervisionato, esistono altre forme di apprendimento che combinano o estendono tali metodologie, adattandosi a contesti applicativi più complessi.

L'apprendimento semi-supervisionato rappresenta un compromesso tra i due approcci precedenti, integrando elementi dell'apprendimento supervisionato e di quello non supervisionato. In molti casi reali, infatti, ottenere etichette per ogni dato può risultare oneroso o talvolta impossibile. Questo metodo utilizza quindi un ampio insieme di dati non etichettati, affiancato da una porzione più ridotta di dati etichettati, al fine di migliorare l'efficienza e la qualità dell'apprendimento complessivo.

Un'altra metodologia è l'apprendimento per rinforzo, che si distingue per la sua natura basata su decisioni sequenziali e meccanismi di ricompensa. In questo contesto, l'algoritmo apprende attraverso un processo iterativo di tentativi ed errori, ricevendo feedback positivi o negativi in base alle azioni intraprese. L'obiettivo è sviluppare una strategia capace di massimizzare le ricompense cumulative. Tale approccio trova particolare applicazione in ambiti come i giochi, la guida autonoma e i sistemi di trading automatizzati.

Queste diverse metodologie, insieme agli approcci supervisionato e non supervisionato, offrono agli sviluppatori di machine learning un insieme flessibile di strumenti per affrontare una vasta gamma di problemi, favorendo l'adattabilità dei sistemi e la loro capacità di apprendere da dati di natura eterogenea.

In sintesi, è possibile osservare che applicazioni come Google Maps e Airbnb affrontano problemi di regressione tramite l'apprendimento supervisionato; Gmail e Netflix gestiscono compiti di classificazione con lo stesso approccio; mentre Amazon e Spotify applicano metodologie non supervisionate per la clusterizzazione dei dati.

1.5 Approfondimento teorico su regressione, classificazione e clusterizzazione

È opportuno analizzare in modo sistematico le tre principali tipologie di problemi nell'ambito del Machine Learning: regressione, classificazione e clusterizzazione. Per ciascuna di esse è necessario chiarire la natura del problema, la struttura del modello, gli algoritmi utilizzati per risolverlo e le modalità con cui tali modelli vengono costruiti.

1.5.1 La regressione: modelli e algoritmi principali

La regressione è una classe di problemi in cui l'obiettivo consiste nel prevedere valori continui sulla base di esperienze passate. Gli algoritmi impiegati per affrontare problemi di regressione vengono addestrati e successivamente testati su dati storici organizzati in un dataset, cioè una raccolta strutturata di osservazioni. Tale dataset contiene una o più variabili indipendenti (input) e una variabile dipendente o variabile target (output), che rappresenta la grandezza che il modello deve stimare. Questi algoritmi si fondano sull'apprendimento supervisionato, poiché, durante l'addestramento, dispongono sia degli input sia dei corrispondenti output attesi. In termini pratici, un modello di regressione mira a individuare la relazione tra la variabile target e le variabili indipendenti associate.

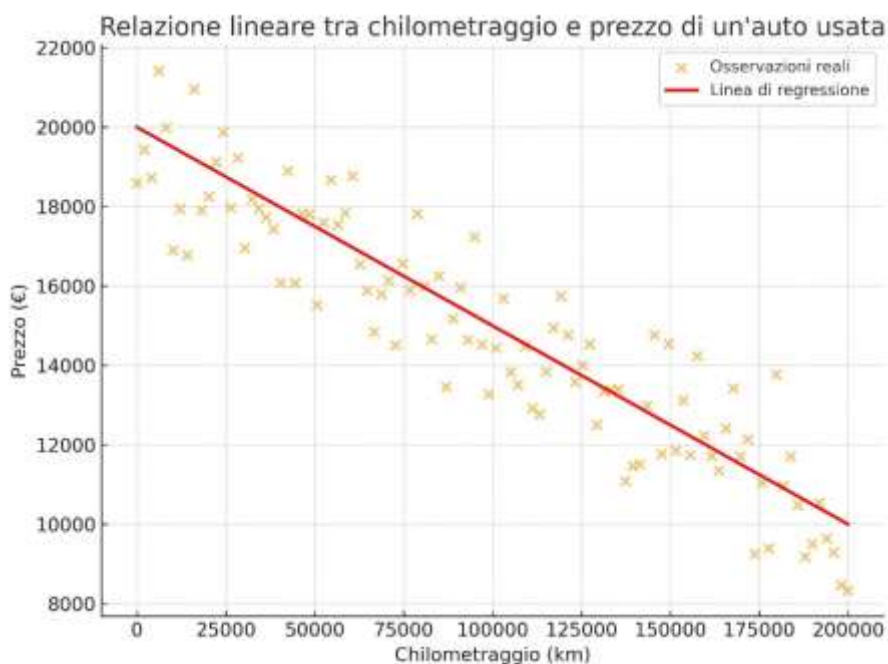
Un esempio applicativo è il seguente: un'impresa può utilizzare un modello di regressione per determinare in che modo il volume di vendita (variabile target) dipenda dall'investimento pubblicitario (variabile indipendente). In questo caso si parla di regressione semplice, poiché vi è una sola variabile esplicativa. Se invece si introducono ulteriori variabili indipendenti, come il numero di punti vendita, il numero di rappresentanti commerciali, il prezzo medio del prodotto, e così via, il problema diventa di regressione multipla.

Nel contesto della regressione multipla, l'analisi consente di valutare come il volume di vendita vari al modificarsi di una singola variabile di interesse (ad esempio, il numero di punti vendita), mantenendo costanti tutte le altre. Ciò evidenzia l'utilità dei modelli di machine learning nell'esecuzione di analisi di sensibilità. L'analisi di sensibilità è una procedura che consente di misurare quanto il risultato prodotto dal modello cambi al variare di una o più variabili in ingresso, mantenendo ferme le altre. In questo modo è possibile individuare le variabili più rilevanti e stimare l'impatto delle loro variazioni sul risultato finale.


Sia nei modelli di regressione semplice, sia in quelli di regressione multipla, la relazione tra variabili indipendenti e variabile target può essere di tipo lineare oppure non lineare, a seconda delle caratteristiche intrinseche dei dati osservati. La scelta dell'algorithmo dipende dunque dalla natura di questa relazione, poiché l'obiettivo è sempre quello di adattare il modello in modo da descrivere adeguatamente l'andamento reale dei dati.

Di seguito si presentano i principali algoritmi utilizzabili nei problemi di regressione:

- **Regressione lineare:** La regressione lineare è l'algorithmo più diffuso per la previsione di variabili continue quando si ipotizza una relazione diretta e proporzionale tra variabile indipendente e variabile dipendente. Ad esempio, si può stimare il prezzo di vendita di un'automobile usata a partire dal chilometraggio, assumendo che il prezzo diminuisca linearmente all'aumentare dei chilometri percorsi. In termini intuitivi, si ipotizza che per ogni ulteriore migliaio di chilometri percorsi, il valore dell'auto si riduca di una quantità fissa. Questo implica una relazione regolare e prevedibile: più elevato è il chilometraggio, minore è il prezzo dell'auto, con un decremento che procede in maniera uniforme.



- **Regressione non lineare:** Quando la relazione tra le variabili non segue un andamento proporzionale e non può essere rappresentata in modo adeguato da una retta, si ricorre a modelli di regressione non lineare. Questo accade, ad esempio, se il deprezzamento di un'automobile non procede a un ritmo costante rispetto al chilometraggio, ma accelera o rallenta in determinati intervalli. In tali casi è opportuno adottare funzioni più complesse (ad esempio di tipo polinomiale o esponenziale) per descrivere correttamente il comportamento osservato nei dati.



- **Alberi decisionali per la regressione (decision tree):** Gli alberi decisionali applicati alla regressione operano suddividendo progressivamente il dataset sulla base delle caratteristiche delle variabili indipendenti, cioè le variabili utilizzate per effettuare la previsione. Questo processo di suddivisione genera sottogruppi via via più piccoli e omogenei. Ogni partizione è costruita in modo da rendere le osservazioni all'interno del sottogruppo quanto più simili possibile in termini della variabile dipendente, vale a dire la grandezza che si desidera prevedere.

Per chiarire, si consideri il problema della previsione del prezzo di vendita di immobili partendo da attributi quali la metratura, il numero di stanze, l'anno di costruzione e la localizzazione geografica. Un albero decisionale potrebbe iniziare separando le abitazioni in base alla zona, poi ulteriormente in base all'anno di costruzione, e così via. Ogni suddivisione viene scelta per ottenere gruppi finali di abitazioni che presentino valori di prezzo simili. Quando il dataset è stato completamente partizionato in questi gruppi finali (le cosiddette "foglie" dell'albero), la previsione per un nuovo immobile si ottiene individuando a quale foglia esso appartiene e utilizzando, come stima del prezzo, la media o la mediana dei prezzi degli immobili contenuti in quella stessa foglia.

In sostanza, l'albero costruisce un percorso decisionale basato sulle caratteristiche dell'immobile e associa a quel percorso una stima del prezzo. Questo tipo di algoritmo è particolarmente efficace perché è in grado di adattarsi a relazioni anche molto complesse e non lineari tra variabili e, allo stesso tempo, produce un modello interpretabile: è possibile visualizzare con chiarezza le decisioni prese e comprendere su quali caratteristiche esse si basano.

- **Gradient boosting:** Il gradient boosting è un approccio più avanzato che costruisce il modello predittivo come combinazione di numerosi modelli di base, in genere alberi decisionali semplici e con capacità predittiva limitata. Il metodo procede per iterazioni successive: ad ogni passo viene aggiunto un nuovo modello che ha il compito specifico di correggere gli errori commessi dai modelli precedenti. In questo modo la previsione viene progressivamente affinata. Questo processo iterativo risulta particolarmente adatto a problemi di regressione caratterizzati da relazioni complesse tra le variabili, in cui non è presente un andamento lineare semplice ma, al contrario, dinamiche articolate e mutevoli. Grazie al miglioramento continuo basato sugli errori residui delle iterazioni precedenti, il gradient boosting è in grado di formulare previsioni accurate anche in contesti con elevata complessità.

- **Reti neurali artificiali (RNA):** Le reti neurali artificiali costituiscono una famiglia di algoritmi estremamente potente e flessibile nell'ambito del machine learning, soprattutto quando si affrontano problemi di regressione in cui la relazione tra le variabili è non lineare e complessa. Queste reti sono composte da unità di elaborazione elementari, denominate neuroni, organizzate in strati. Ogni neurone in uno strato riceve in ingresso segnali provenienti dallo strato precedente, applica una trasformazione matematica e trasmette il risultato allo strato successivo.

Questa architettura stratificata consente alle reti neurali di apprendere e rappresentare diversi livelli di complessità nei dati. Per esempio, in un'analisi del comportamento di acquisto dei consumatori, uno strato iniziale potrebbe cogliere informazioni di base sul cliente (quali età e area geografica), mentre strati più profondi potrebbero modellare in che modo tali caratteristiche si riflettano sulla frequenza o sulla preferenza di acquisto. Le cosiddette reti profonde, cioè reti neurali con molti strati nascosti, risultano particolarmente efficaci nell'apprendere relazioni articolate di questo tipo.

Ogni strato nascosto può essere interpretato come un livello di astrazione che trasforma progressivamente i dati in ingresso, rendendo possibile l'individuazione di schemi che sarebbero difficili da catturare con metodologie più tradizionali. Per queste ragioni, le reti neurali artificiali si rivelano strumenti adattabili a problemi di regressione di diversa complessità, dai casi più semplici ai casi più sfidanti, con applicazioni che spaziano, ad esempio, dalla stima dei prezzi di mercato alla valutazione in ambito sanitario.

1.5.2 La classificazione: approcci e tecniche applicative

La classificazione è una tipologia di problema che mira a prevedere variabili discrete a partire da esperienze precedenti. Analogamente alla regressione, anche la classificazione utilizza un dataset composto da una o più variabili indipendenti e da una variabile target, cioè la variabile che il modello deve stimare. Di conseguenza, la classificazione rientra nell'ambito dell'apprendimento supervisionato. Esempi tipici sono: la previsione dell'interruzione o della continuità di un servizio da parte di un utente;

la presenza o l'assenza di una determinata malattia in un paziente; l'assegnazione di un messaggio di posta elettronica alla categoria "spam" o "non spam"; la previsione dell'eventuale stato di insolvenza di un cliente bancario.

È possibile distinguere diverse tipologie di problemi di classificazione in funzione del numero e della natura delle categorie che la variabile target può assumere:

- **Classificazione binaria:** nella classificazione binaria, la variabile target può assumere esclusivamente due stati possibili. Un esempio illustrativo è il processo di approvazione del credito. In tale contesto, un modello di Machine Learning viene addestrato utilizzando variabili indipendenti che rappresentano fattori di input quali dati finanziari e personali dell'individuo: storico creditizio, reddito, età e durata dell'impiego. Sulla base di tali informazioni, il modello produce l'esito della variabile target, che in questo caso corrisponde alla decisione di approvare o non approvare la richiesta di credito. L'uscita del modello è quindi binaria: approvato / non approvato.

- **Classificazione multiclasse:** nella classificazione multiclasse, la variabile di output può appartenere a più di due categorie. In ambito marketing, ad esempio, è possibile addestrare un modello di machine learning per assegnare ciascun cliente a un segmento di mercato specifico. Il modello utilizza variabili indipendenti come dati demografici, comportamenti e dati di acquisto al fine di identificare il segmento di appartenenza. Le possibili categorie della variabile target possono includere, a titolo esemplificativo: "giovani professionisti", "famiglia con bambini", "pensionati", "imprenditori". Ogni cliente viene così assegnato a una di queste classi, mostrando come la classificazione multiclasse permetta di sviluppare soluzioni mirate a esigenze di business complesse.

- **Classificazione multi-etichetta:** nella classificazione multi-etichetta, un'unica osservazione può essere associata simultaneamente a più categorie. Un esempio è quello dell'editoria digitale. Un articolo di cronaca relativo a un grande evento sportivo internazionale, come le Olimpiadi svoltesi a Tokyo, può essere etichettato allo stesso tempo come "sport", "intrattenimento" e "località". Un modello di Machine Learning addestrato alla classificazione multi-etichetta in un sistema di gestione dei contenuti può

individuare e assegnare automaticamente tali etichette, basandosi sull'analisi del testo e su criteri predefiniti. Questo processo migliora l'organizzazione e la reperibilità dei contenuti.

Dopo avere delineato le principali forme di classificazione, si possono descrivere gli algoritmi maggiormente utilizzati per affrontare questo tipo di problemi:

- **Alberi decisionali per la classificazione:** gli alberi decisionali per la classificazione operano in modo analogo agli alberi utilizzati per la regressione: sfruttano le caratteristiche delle variabili indipendenti per suddividere progressivamente il dataset in gruppi omogenei rispetto a una variabile dipendente di tipo categorico. Si consideri, a titolo di esempio, la decisione di uscire o meno in barca a vela in funzione delle condizioni meteorologiche. L'albero può iniziare valutando se il vento è adeguato. Se il vento non è ritenuto idoneo, la decisione finale è immediatamente "non uscire". Se invece il vento è giudicato ideale, il passo successivo consiste nel valutare la situazione meteo generale. Se le condizioni sono favorevoli, la decisione risultante è "uscire". Se non lo sono, viene introdotto un ulteriore criterio, ad esempio la disponibilità di tempo ("hai tempo disponibile?"). Se la risposta è positiva, la decisione resta "uscire", altrimenti "non uscire". Questo esempio illustra il funzionamento degli alberi decisionali: ogni nodo rappresenta una scelta basata su una specifica caratteristica, e ogni percorso che conduce a una foglia corrisponde a una combinazione di condizioni che porta a una decisione finale. Tale modello risulta utile perché rende esplicito il processo decisionale, soprattutto in situazioni in cui la scelta dipende da più fattori.

- **Foreste casuali (Random Forest):** le foreste casuali costituiscono una classe di algoritmi di machine learning più avanzata rispetto al singolo albero decisionale. Invece di costruire un unico albero, la foresta crea un insieme di alberi decisionali, ciascuno dei quali viene addestrato su un campione differente dei dati originali. Questa strategia riduce il rischio che il modello si adatti in modo eccessivamente specifico agli esempi presenti nel dataset di addestramento, fenomeno noto come addestramento

eccessivo, che può condurre a errori di previsione. Durante la costruzione di ciascun albero non è casuale soltanto la selezione del campione di dati, ma anche la scelta delle caratteristiche utilizzate per effettuare le suddivisioni. Ciò aumenta la diversità dei singoli alberi. Per giungere a una decisione finale, la foresta aggrega le “opinioni” di tutti gli alberi e seleziona la soluzione più frequentemente proposta. Questo meccanismo di aggregazione consente di compensare le debolezze dei singoli alberi e di ottenere una previsione complessivamente più stabile e accurata. Tale tecnica è descritta come particolarmente rilevante in ambiti quali la finanza, la sanità e la ricerca ambientale, contesti nei quali le decisioni assunte risultano cruciali.

- **Support Vector Machines (SVM):** gli algoritmi SVM costituiscono uno strumento impiegato per l’assegnazione di un’osservazione a una categoria. Sono particolarmente efficaci nei problemi in cui le classi da distinguere sono due, come nel rilevamento delle e-mail di tipo spam, ma possono essere estesi anche a situazioni con più categorie, ad esempio distinguere più tipi di frutta in base a caratteristiche come colore, dimensione e forma.

Il funzionamento può essere descritto in termini geometrici. Si immagina un piano sul quale siano rappresentati punti di due colori diversi, ciascuno appartenente a una delle due categorie. L’obiettivo dell’algoritmo è individuare una linea che separi i punti di un colore dai punti dell’altro colore. In spazi con più dimensioni, questa linea diventa una superficie di separazione. Questa frontiera di separazione è detta margine decisionale.

La peculiarità del metodo risiede nel criterio con cui tale margine viene scelto: l’algoritmo ricerca la separazione che massimizza la distanza tra la frontiera e i punti più vicini appartenenti alle due categorie. Questi punti vicini al margine sono detti vettori di supporto e sono determinanti nella definizione della separazione ottimale. Massimizzando questa distanza, il modello diventa più robusto rispetto a piccole variazioni dei dati. Ciò implica che l’algoritmo non solo produce buone prestazioni sui dati

utilizzati per l'addestramento, ma mantiene prestazioni elevate anche quando analizza nuovi dati non osservati in precedenza.

- **Regressione logistica:** La regressione logistica è un algoritmo di classificazione utilizzato nei problemi binari, ossia nei casi in cui la variabile target può assumere soltanto due stati (ad esempio: sì / no; corretto / errato; spam / non spam; frode / non frode). L'algoritmo elabora le variabili indipendenti e stima la probabilità, espressa in termini percentuali da 0 a 100%, che la variabile target appartenga a uno dei due stati. Generalmente, la soglia di distinzione tra le due classi è fissata al 50%.

Tale approccio viene adottato, ad esempio, in ambito medico per verificare se una diagnosi risulti positiva o negativa; nel marketing per individuare se un cliente interromperà un servizio oppure continuerà a utilizzarlo; in ambito finanziario per distinguere tra clienti a rischio di insolvenza e clienti non a rischio. La possibilità di associare a ciascun caso una probabilità quantitativa rende la regressione logistica uno strumento utile sia per la valutazione del rischio sia per decisioni fondate su soglie probabilistiche.

- **K-Nearest Neighbors (KNN):** l'algoritmo K-Nearest Neighbors è un metodo di classificazione che assegna una nuova osservazione a una categoria sulla base della somiglianza con casi già noti. Il procedimento può essere descritto in tre passaggi: in primo luogo, si calcola la distanza tra l'osservazione da classificare e ciascuna osservazione presente nel dataset di addestramento; in secondo luogo, si ordina l'insieme di queste distanze dalla più piccola alla più grande; infine, si selezionano i primi "K" casi più vicini. La categoria assegnata alla nuova osservazione è determinata dalla classe maggiormente rappresentata tra questi vicini. Questa modalità operativa rende il KNN un algoritmo intuitivo ed efficace. Risulta particolarmente utile in applicazioni quali il riconoscimento di schemi ricorrenti, i sistemi di raccomandazione di prodotti e, più in generale, in compiti di classificazione nei quali la similarità tra gli elementi del dataset costituisce un indicatore affidabile per determinare l'appartenenza a una classe. La scelta del parametro "K" è cruciale: un valore troppo basso può

rendere il modello eccessivamente sensibile alla presenza di osservazioni anomale, mentre un valore troppo alto può produrre una classificazione eccessivamente generalizzata.

- **Gradient boosting:** rappresenta una classe di algoritmi particolarmente efficace nella costruzione di modelli predittivi complessi. Esso procede in modo incrementale, generando il modello finale attraverso una sequenza di stadi successivi. L'idea di base consiste nel combinare molteplici modelli deboli, ossia modelli semplici e meno accurati considerati singolarmente, per ottenere un modello complessivo più preciso e stabile. Questo approccio risulta adatto anche a problemi di classificazione articolati, poiché ogni fase dell'algoritmo è orientata a correggere gli errori delle fasi precedenti, migliorando progressivamente la capacità predittiva del sistema.

1.5.3 La clusterizzazione: metodi e strumenti di analisi dei dati

La clusterizzazione costituisce una tipologia di problema che ha l'obiettivo di individuare gruppi o schemi interni ai dati senza disporre, in partenza, di etichette predefinite. A differenza della regressione e della classificazione, nelle quali il modello apprende a partire da esempi etichettati, nella clusterizzazione l'algoritmo opera in regime di apprendimento non supervisionato. Questo significa che il sistema analizza i dati così come sono, ricercando autonomamente configurazioni ricorrenti e strutture latenti. Tale approccio è particolarmente utile quando si lavora con insiemi di dati di grandi dimensioni, poiché consente di mettere in evidenza relazioni e raggruppamenti che non sarebbero facilmente individuabili tramite un'analisi manuale.

L'impiego della clusterizzazione è diffuso in molteplici contesti applicativi. Nel settore delle telecomunicazioni, ad esempio, gli operatori utilizzano tecniche di clusterizzazione per segmentare la clientela sulla base di modelli di consumo simili. Ciò consente di sviluppare strategie commerciali mirate e di ridurre la probabilità che i clienti interrompano il servizio. Allo stesso modo, nel marketing digitale tali algoritmi vengono applicati per suddividere i visitatori di un sito web in gruppi omogenei, analizzando indicatori quali il tempo di permanenza sulle pagine, le pagine visitate e la frequenza di

acquisto. L'analisi di queste informazioni rende possibile la personalizzazione dell'esperienza utente e l'ottimizzazione delle campagne pubblicitarie.

Di seguito si descrivono i principali algoritmi utilizzati per affrontare problemi di clusterizzazione.

- **K-means:** è uno degli algoritmi più utilizzati per suddividere un insieme di dati in gruppi omogenei (cluster). Il procedimento inizia selezionando in modo casuale “K” punti del dataset, che fungono da centroidi iniziali dei gruppi. Successivamente, ogni elemento del dataset viene assegnato al gruppo il cui centro risulta più vicino, sulla base della distanza euclidea (ovvero la distanza in linea retta). Una volta effettuata questa prima assegnazione, la posizione di ciascun centro viene aggiornata affinché rappresenti in modo più accurato la posizione media degli elementi appartenenti al gruppo. Queste due operazioni, assegnazione dei punti al centro più vicino e ricalcolo dei centroidi, vengono ripetute iterativamente. A ogni iterazione alcuni punti possono cambiare gruppo se risultano più vicini a un nuovo centro. Il processo termina quando i centroidi non subiscono più variazioni significative, indicando che è stata raggiunta una suddivisione stabile dei dati. K-means è apprezzato per semplicità ed efficienza; tuttavia, l'efficacia dell'algoritmo dipende sia dalla scelta del numero di gruppi “K”, sia dalla selezione iniziale dei centroidi, che possono influenzare in modo rilevante il risultato finale.

- **DBSCAN (Density-Based Clustering of Applications with Noise):** è un algoritmo che individua i cluster sulla base della densità dei punti nello spazio dei dati. A differenza di K-means, non richiede di specificare in anticipo il numero di cluster da identificare. Inoltre, è in grado di riconoscere gruppi con forme irregolari e di gestire efficacemente la presenza di punti anomali (rumore). Questo lo rende particolarmente adatto in situazioni in cui i dati contengono outlier e non è nota a priori la struttura del raggruppamento.

- **Clustering gerarchico:** il clustering gerarchico organizza i dati in una struttura ad albero, mostrando le relazioni di prossimità tra gli elementi e tra i gruppi formati. Tale struttura può essere costruita secondo due approcci: uno di tipo agglomerativo, in cui si parte da singoli elementi che vengono

progressivamente uniti in gruppi più ampi, e uno di tipo divisivo, in cui si parte da un insieme unico che viene suddiviso in gruppi sempre più piccoli. Un vantaggio rilevante di questo metodo è la possibilità di rappresentare graficamente le connessioni tra gli oggetti, consentendo una lettura immediata delle somiglianze e delle distanze tra i vari insiemi individuati.

- **Fuzzy K-means:** costituisce una variante dell'algoritmo K-means. A differenza della versione standard, nella quale ogni punto appartiene a un solo cluster, il fuzzy K-means consente a ciascun elemento di avere diversi gradi di appartenenza a più cluster. Questo risulta utile nei casi in cui i confini tra gruppi non siano netti e i dati presentino caratteristiche che li rendono compatibili con più di una categoria. In tali situazioni, la rappresentazione sfumata dell'appartenenza ai cluster riflette più fedelmente la natura dei dati osservati

1.6 Costruzione dei modelli di Machine Learning

Nel contesto del Machine Learning, la conversione di un'idea in un modello operativo non può basarsi esclusivamente sull'intuizione, ma richiede un approccio sistematico e accuratamente pianificato. Risulta quindi necessario definire in modo esplicito le fasi che consentono di passare dalla formulazione del problema alla realizzazione del modello, distinguendo chiaramente gli obiettivi da perseguire e le modalità con cui raggiungerli mediante strumenti adeguati.

Una strutturazione metodologica di questo tipo permette di ottenere un modello affidabile e coerente, oltre a garantirne l'allineamento con gli obiettivi stabiliti. A prescindere dalla natura del problema affrontato, ogni fase del processo di sviluppo deve essere eseguita con rigore, al fine di ottimizzare le prestazioni e l'effettiva applicabilità del modello.

1.6.1 Dal problema al modello: il cosa

La realizzazione di modelli di Machine Learning finalizzati alla risoluzione dei problemi analizzati si articola in una serie di fasi definite, la cui struttura varia in funzione della tipologia di problema affrontato. In particolare, i problemi di regressione e di classificazione si basano su un approccio di apprendimento supervisionato, mentre quelli di clusterizzazione adottano un apprendimento non supervisionato.

Per quanto riguarda la costruzione dei modelli di regressione e classificazione, il processo può essere descritto attraverso i seguenti passaggi:

1. **Definizione del problema:** individuazione chiara dell'obiettivo, ad esempio la previsione del valore di una variabile target a partire da una o più variabili indipendenti.
2. **Raccolta dei dati:** costituzione di dataset adeguati che comprendano sia le variabili indipendenti sia la variabile dipendente.
3. **Preparazione dei dati:** pulizia del dataset da errori o valori mancanti e organizzazione dei dati in una forma idonea all'addestramento; in questa fase si procede anche alla normalizzazione o standardizzazione dei dati, al fine di evitare distorsioni nei risultati del modello.

4. **Selezione dell'algoritmo:** scelta dell'algoritmo più idoneo in relazione alla natura del problema e alle caratteristiche dei dati disponibili.

5. **Addestramento dell'algoritmo:** applicazione dell'algoritmo a una porzione del dataset, denominata insieme di training.

6. **Valutazione del modello:** verifica delle prestazioni del modello su un insieme di dati distinto da quello di addestramento, utilizzando metriche di valutazione appropriate per misurare l'accuratezza delle previsioni o delle classificazioni.

7. **Ottimizzazione del modello:** miglioramento delle prestazioni mediante la regolazione dei parametri, l'impiego di tecniche di selezione delle caratteristiche o la sperimentazione di algoritmi alternativi, se necessario.

8. **Implementazione:** utilizzo del modello addestrato per effettuare previsioni o classificazioni su nuovi dati, applicandolo a contesti decisionali di tipo operativo o strategico.

Lo sviluppo di modelli di clusterizzazione segue una sequenza di passaggi strutturati, finalizzati all'individuazione di raggruppamenti significativi all'interno dei dati. Tali fasi possono essere descritte come segue:

1. **Definizione del problema:** determinazione dell'obiettivo dell'analisi, ad esempio l'identificazione di gruppi naturali nei dati oppure la scoperta di schemi e relazioni non immediatamente evidenti.

2. **Raccolta dei dati:** acquisizione di un dataset contenente le variabili necessarie per l'analisi dei cluster, assicurandosi che esso sia rappresentativo della popolazione di riferimento.

3. **Preparazione dei dati:** pulizia del dataset mediante la rimozione o la correzione di valori mancanti e outlier, ossia osservazioni che si discostano in modo significativo dal resto dei dati; in questa fase si procede inoltre alla normalizzazione e standardizzazione delle variabili, così da garantire un calcolo equo delle distanze, soprattutto in presenza di scale differenti.

4. **Selezione dell'algoritmo di clusterizzazione:** scelta dell'algoritmo più adeguato in funzione della natura dei dati e degli obiettivi prefissati, tenendo conto della capacità di gestire la tipologia e la dimensione del dataset, nonché della forma e della distribuzione dei cluster attesi.

5. **Configurazione dei parametri:** impostazione dei parametri dell'algoritmo selezionato, fase che può richiedere un processo iterativo di sperimentazione e ottimizzazione.

6. **Esecuzione dell'algoritmo di clusterizzazione:** applicazione dell'algoritmo al dataset opportunamente preparato per ottenere i cluster.

7. **Valutazione dei cluster:** analisi dei risultati ottenuti attraverso metriche di valutazione e, ove disponibili, il confronto con benchmark noti, verificando la coerenza dei cluster rispetto agli obiettivi del progetto.

8. **Implementazione:** impiego del modello per la clusterizzazione di nuovi dati e utilizzo dei risultati a supporto di decisioni strategiche e operative.

Le tre principali tipologie di problemi considerate si distinguono in base alla modalità di apprendimento. Nei problemi di regressione e classificazione l'apprendimento è supervisionato, poiché il modello viene addestrato su dati etichettati; nei problemi di clusterizzazione, invece, l'apprendimento è non supervisionato, in quanto il modello individua autonomamente strutture e schemi utili al raggruppamento dei dati in cluster omogenei.

1.6.2 La realizzazione del modello: il come

Per l'implementazione delle fasi precedentemente descritte è possibile adottare due principali metodologie.

- La prima è rappresentata dagli approcci basati sulla scrittura di codice, che prevedono l'utilizzo di linguaggi di programmazione quali Python o R e l'impiego di librerie dedicate. Python e R costituiscono due dei linguaggi maggiormente utilizzati nell'ambito della data science e del machine learning. Python si distingue per una sintassi chiara e leggibile e per la disponibilità di numerose librerie per l'analisi dei dati, caratteristiche che lo rendono

particolarmente indicato per la manipolazione dei dataset e per l'apprendimento automatico. R, invece, è ampiamente apprezzato per le sue avanzate funzionalità statistiche e di visualizzazione dei dati ed è frequentemente impiegato nell'analisi statistica approfondita e nella modellazione predittiva. La scelta tra i due linguaggi dipende generalmente dalle esigenze specifiche del progetto, dalle preferenze individuali e dal contesto industriale di riferimento. L'approccio basato sulla programmazione consente un elevato grado di flessibilità nella personalizzazione dei modelli e nella gestione delle complessità tecniche, permettendo una regolazione dettagliata in funzione delle necessità del progetto. Tuttavia, tale metodologia richiede competenze solide in programmazione e una conoscenza approfondita dei principi fondamentali della data science, risultando quindi più adatta a professionisti con un elevato livello di preparazione tecnica.

- La seconda invece è basata su metodologie basate su piattaforme di intelligenza artificiale senza codice (no-code AI platforms): Le piattaforme di intelligenza artificiale no-code permettono la progettazione e l'implementazione di modelli senza ricorrere alla scrittura di codice, contribuendo a rendere l'AI maggiormente accessibile. Tali strumenti mettono a disposizione interfacce grafiche intuitive e user-friendly, attraverso le quali anche utenti privi di competenze tecniche possono sviluppare modelli di machine learning.

Il passaggio dalle metodologie fondate sulla programmazione a quelle basate su piattaforme no-code può essere assimilato all'evoluzione dai sistemi operativi a riga di comando, come il DOS, che richiedevano la conoscenza di istruzioni testuali specifiche, alle interfacce grafiche quali Windows, nelle quali le operazioni vengono eseguite tramite l'interazione con icone, menu e mouse.

Le due metodologie si differenziano in modo significativo e presentano entrambe vantaggi e limiti, rendendole adatte a contesti e esigenze differenti.

1.6.3 Confronto tra metodologie e criteri di scelta

Metodologie basate sulla scrittura di codice: Le metodologie fondate sulla programmazione presentano specifici vantaggi e svantaggi, che ne determinano l'idoneità in relazione alle caratteristiche del progetto e alle competenze disponibili.

Vantaggi:

1. **Elevato livello di personalizzazione:** consentono un controllo completo sull'intero processo di sviluppo, permettendo di intervenire su ogni componente del modello di machine learning.
2. **Scalabilità e flessibilità:** risultano particolarmente adatte alla gestione di elevati livelli di complessità e alla scalabilità del sistema in funzione delle esigenze del progetto.
3. **Ampie possibilità di ottimizzazione:** permettono l'applicazione di tecniche avanzate di ottimizzazione e di fine-tuning dei modelli.
4. **Supporto per algoritmi complessi:** rendono possibile l'implementazione di algoritmi di ricerca avanzati e di architetture altamente sofisticate.
5. **Controllo del processo di addestramento:** offrono la possibilità di gestire direttamente le modalità di addestramento del modello, adattandole alle specifiche necessità.

Svantaggi:

1. **Curva di apprendimento elevata:** richiedono competenze approfondite in programmazione e statistica, limitandone l'accessibilità a utenti non esperti.
2. **Tempi di sviluppo più lunghi:** la codifica manuale dei modelli e la loro configurazione possono risultare complesse e richiedere un investimento temporale maggiore.
3. **Necessità di manutenzione continua:** modelli e infrastrutture software devono essere aggiornati e mantenuti nel tempo per garantire efficacia e sicurezza.

4. **Maggiore rischio di errori:** la scrittura manuale del codice aumenta la probabilità di introdurre errori che possono compromettere le prestazioni del modello.

Metodologie basate su piattaforme di intelligenza artificiale senza codice: le piattaforme di intelligenza artificiale no-code presentano una serie di vantaggi e criticità che ne influenzano l'adozione in base al contesto applicativo.

Vantaggi:

1. **Accessibilità:** risultano facilmente utilizzabili anche da utenti privi di competenze di programmazione, riducendo le barriere di ingresso nel campo del machine learning.
2. **Rapidità di sviluppo:** permettono di sviluppare e distribuire i modelli in tempi più brevi grazie a interfacce grafiche intuitive e a flussi di lavoro automatizzati.
3. **Ridotta necessità di manutenzione:** in genere richiedono un livello inferiore di manutenzione rispetto ai modelli sviluppati internamente, poiché numerosi aspetti tecnici sono gestiti direttamente dalla piattaforma.
4. **Costi iniziali contenuti:** contribuiscono a ridurre i costi iniziali di configurazione e sviluppo, spesso mettendo a disposizione modelli preaddestrati.

Svantaggi:

1. **Limitata personalizzazione:** offrono minori possibilità di personalizzazione rispetto agli approcci basati sulla programmazione diretta, aspetto che può rappresentare un vincolo per applicazioni specifiche.
2. **Dipendenza dal fornitore:** comportano il rischio di lock-in tecnologico, con una forte dipendenza dalla piattaforma scelta per aggiornamenti e funzionalità.
3. **Scalabilità ridotta:** possono presentare limiti nella gestione di applicazioni di grandi dimensioni o particolarmente complesse.

4. **Controllo limitato sui dati:** possono imporre restrizioni sulle modalità di gestione e archiviazione dei dati, sollevando potenziali criticità in termini di sicurezza e tutela della privacy.

L'adozione delle diverse metodologie per la realizzazione di modelli di machine learning non risulta rigidamente vincolata né alle dimensioni dell'organizzazione né alle risorse economiche disponibili. La scelta dell'approccio più appropriato dipende infatti da un insieme di fattori che va oltre le sole considerazioni di costo o di scala aziendale.

La metodologia di sviluppo dei modelli di Machine Learning non può quindi essere considerata predefinita, ma deve essere selezionata in modo dinamico in funzione delle esigenze contingenti, delle competenze presenti all'interno dell'organizzazione e degli obiettivi strategici perseguiti, tenendo conto dei rispettivi vantaggi e limiti delle diverse soluzioni.

La flessibilità nell'adozione di approcci basati sia sulla scrittura di codice sia sull'impiego di piattaforme di intelligenza artificiale no-code consente alle organizzazioni di rispondere in maniera più efficace e mirata alle sfide emergenti, ottimizzando l'efficienza degli investimenti in tecnologie avanzate e favorendo il mantenimento di un vantaggio competitivo sostenibile nel tempo.

CAPITOLO II: L'uso del Machine Learning nel retail

I fondamenti teorici analizzati e affrontati nel Capitolo I mettono le basi per affrontare il presente capitolo, che si propone di indagare le applicazioni del Machine Learning nel retail, ponendo il focus sulle implicazioni operative e strategiche che ne derivano. Dopo aver analizzato il Machine Learning da un punto di vista teorico, l'attenzione si sposta ora sul piano applicativo.

Il retail risulta essere un contesto particolarmente adatto per le applicazioni del Machine Learning: l'elevata quantità di dati a disposizione, processi e strategie aziendali fortemente influenzati dalle dinamiche della domanda e dal comportamento dei consumatori risultano essere il campo più adatto per l'applicazione della tecnologia. Il capitolo pertanto esamina tre macroaree di applicazione del Machine Learning:

- il pricing dinamico
- la segmentazione della clientela
- la previsione della domanda

Il focus viene posto sia su aspetti tecnici che risvolti manageriali al fine di comprendere come tale strumento contribuisca alla creazione di modelli decisionali sempre più data-driven.

2.1 Introduzione alla Retail Analytics: dati, tecnologie e applicazioni

La Retail Analytics (RA) si è affermata come un elemento cruciale nel panorama contemporaneo del commercio al dettaglio, grazie ai progressi tecnologici, alla crescente disponibilità di fonti di dati eterogenee e alla digitalizzazione dei tradizionali punti vendita fisici. Questo ambito rappresenta un settore di trasformazione per l'industria retail, poiché si fonda sulla capacità di sfruttare grandi volumi di dati per ottimizzare i processi decisionali, migliorare l'esperienza del cliente e fornire analisi approfondite e operative sul comportamento dei consumatori e sulle dinamiche di vendita.

L'evoluzione della RA è stata caratterizzata dall'integrazione di tecnologie avanzate quali Machine Learning (ML), data mining, Big Data (BD) e Big Data Analytics (BDA). Questi strumenti hanno rivoluzionato il modo in cui i rivenditori gestiscono la pianificazione strategica, la segmentazione del mercato e le decisioni operative a livello di punto vendita.

In termini applicativi, la RA comprende un insieme di tecniche e metodologie basate sui dati che consentono di analizzare e ottimizzare le principali aree di gestione retail, tra cui l'analisi del comportamento dei consumatori, la previsione della domanda, la gestione dell'inventario, la disposizione dei prodotti e le strategie di relazione con i clienti (Bilgic et al., 2021).

La sua rilevanza è in costante crescita anche nel contesto dei negozi fisici tradizionali, che stanno adottando processi di digitalizzazione e soluzioni tecnologiche avanzate per mantenere un vantaggio competitivo (Becker et al., 2020).

Attraverso l'impiego della BDA e di strumenti sofisticati di apprendimento automatico, la RA consente di analizzare in modo approfondito i comportamenti di acquisto, offrendo informazioni utili alla personalizzazione delle esperienze dei clienti e all'ottimizzazione delle strategie operative (Arefin et al., 2024).

La raccolta e l'analisi di dati su larga scala, comprendenti informazioni transazionali e interazioni dei consumatori, supportano decisioni strategiche riguardanti l'assortimento dei prodotti, la gestione delle scorte e le politiche di fidelizzazione.

Queste innovazioni permettono ai rivenditori tradizionali di restare competitivi rispetto alle piattaforme online, fornendo una comprensione più profonda dei modelli di consumo, utile per rafforzare il coinvolgimento dei clienti e migliorare la comunicazione di marca (Gregorczyk, 2022).

2.1 Il Machine Learning nel retail

Nel settore retail, l'adozione del Machine Learning (ML) sta progressivamente trasformando i processi aziendali lungo l'intera catena del valore, coinvolgendo sia i punti vendita fisici sia le piattaforme di e-commerce. Questa tecnologia costituisce oggi una leva strategica per migliorare l'efficienza operativa e la qualità delle decisioni, contribuendo in modo decisivo alla capacità delle imprese di interpretare i dati e di reagire tempestivamente ai mutamenti del mercato.

Le applicazioni del Machine Learning coprono un ampio spettro di attività, che spaziano dalla pianificazione dell'offerta alla gestione delle scorte, dalla definizione dei prezzi alla personalizzazione dell'esperienza del cliente. Tale varietà dimostra come il ML non si configuri semplicemente come uno strumento tecnico, ma come un elemento strutturale di supporto alla governance aziendale e alla strategia decisionale.

La letteratura distingue chiaramente tra applicazioni offline e online: nei contesti fisici, le soluzioni di ML sono principalmente orientate all'articolo, al suo ciclo di vita e alla logistica; negli ambienti digitali, invece, l'attenzione si concentra sul cliente, sui suoi comportamenti di navigazione e sulle sue preferenze di acquisto. Questa distinzione riflette sia la diversa natura dei dati disponibili nei due contesti sia la finalità specifica dei processi, più operativa nel primo caso, più relazionale e predittiva nel secondo.

L'introduzione del ML all'interno dei sistemi informativi retail avviene come fattore trasversale, capace di incidere su aree differenti quali la pianificazione delle merci, la logistica, l'assortimento, il pricing e il controllo direzionale. La sua implementazione richiede una pipeline strutturata composta da fasi interconnesse: comprensione del contesto di business, analisi e preparazione dei dati, scelta e addestramento del modello, valutazione delle prestazioni e integrazione del modello nei processi decisionali. Tale sequenza operativa consente di trasformare i dati in conoscenza e la conoscenza in decisioni più mirate ed efficienti.

Le ricerche e le esperienze empiriche hanno identificato numerose aree applicative del ML nel retail, che includono sia attività operative, come la gestione dell'inventario e il riordino, sia attività di natura strategica e decisionale, quali la previsione della domanda e il supporto alle politiche di prezzo. Questa classificazione fornisce un riferimento utile

per le imprese interessate a comprendere in quali ambiti il ML possa generare il maggiore valore in funzione dei dati disponibili e degli obiettivi economici perseguiti.

Dal punto di vista metodologico, la scelta dell'algoritmo e l'ottimizzazione dei relativi parametri rappresentano passaggi fondamentali, poiché non esiste un modello universalmente superiore. Le prestazioni variano infatti in base al tipo di dati, alla categoria di prodotto e all'orizzonte temporale considerato.

Le evidenze raccolte sottolineano l'importanza di una corretta progettazione della pipeline dei dati e della sua integrazione nei processi aziendali. Le imprese che riescono a creare un flusso continuo tra raccolta, pulizia, modellazione e implementazione dei dati ottengono risultati più consistenti e decisioni più affidabili. È altresì fondamentale definire una strategia di gestione del rischio modello, che preveda l'utilizzo combinato di diversi algoritmi o approcci ibridi per ridurre la dipendenza da una singola soluzione.

Tra le principali implicazioni gestionali emergono la necessità di una definizione chiara degli obiettivi applicativi, la costruzione di dataset coerenti e completi, l'allineamento tra competenze tecniche e bisogni di business, nonché l'adozione di strumenti di monitoraggio continuo delle prestazioni dei modelli. Solo un approccio sistemico e adattivo consente di sfruttare pienamente il potenziale del ML nel retail, traducendo gli output analitici in valore economico tangibile, come la riduzione degli sprechi, l'ottimizzazione delle scorte e il miglioramento dell'esperienza del cliente.

Permangono tuttavia alcune criticità legate alla qualità e alla disponibilità dei dati, nonché alla capacità delle imprese di mantenere aggiornati i modelli nel tempo. La variabilità tra categorie di prodotto, la stagionalità e la volatilità dei prezzi rendono complessa la standardizzazione delle soluzioni. Per questo, l'applicazione efficace del ML nel retail richiede un approccio flessibile e sperimentale, basato sulla collaborazione tra esperti di dominio e analisti dei dati.

Il Machine Learning rappresenta quindi oggi un pilastro fondamentale per l'innovazione nel settore retail. La sua capacità di apprendere dai dati storici, anticipare la domanda e supportare decisioni strategiche lo rende una tecnologia abilitante per la trasformazione digitale delle imprese. Tuttavia, il suo impatto effettivo dipende non solo dai modelli adottati o dalla quantità di dati disponibili, ma anche dalla maturità

organizzativa e dalla capacità di integrare tali strumenti nei processi decisionali in modo coerente e sostenibile. In questa prospettiva, il ML non è soltanto una soluzione tecnologica, ma un cambiamento culturale nel modo di gestire i dati e di prendere decisioni consapevoli nel retail contemporaneo.

2.2 Il Machine Learning come strumento di supporto alle strategie di pricing dinamico nel retail

Nel contesto in costante evoluzione dell'e-commerce, la definizione dei prezzi rappresenta un elemento strategico per la redditività e la competitività delle imprese. L'aumento della complessità dei mercati digitali, caratterizzati da consumatori sempre più esigenti e da dinamiche concorrenziali in continuo mutamento, richiede l'adozione di approcci flessibili e basati sull'analisi dei dati, capaci di rispondere con tempestività alle variazioni del contesto economico.

In questo scenario, il pricing dinamico emerge come una strategia fondamentale, poiché consente l'adeguamento dei prezzi in tempo reale in funzione delle variazioni della domanda, dell'andamento del mercato e delle politiche dei concorrenti. L'integrazione del Machine Learning (ML) in tale processo consente di gestire grandi quantità di dati, individuare relazioni non lineari tra le variabili e ottimizzare le decisioni di prezzo con livelli di accuratezza e rapidità difficilmente ottenibili mediante i metodi tradizionali.

L'obiettivo principale di questo approccio consiste nel massimizzare i profitti mantenendo, al contempo, elevati livelli di soddisfazione del cliente e una sostenibilità competitiva nel lungo periodo. L'adozione dell'Intelligenza Artificiale (AI) e del Machine Learning (ML) sta infatti trasformando in modo significativo la gestione dei prezzi e della redditività nel settore retail, introducendo strategie dinamiche e data-driven che consentono di ottimizzare le politiche di prezzo e migliorare la performance economica complessiva delle imprese.

Tali tecnologie si basano su modelli di ottimizzazione robusti e su metodi analitici avanzati, tra cui la previsione della domanda storica e l'impiego di algoritmi di apprendimento automatico, finalizzati a individuare punti di prezzo ottimali, adattarsi rapidamente alle condizioni di mercato e supportare decisioni di pricing più efficaci in contesti altamente dinamici (Perakis et al., 2023; Subbarayudu et al., 2023).

In un mercato caratterizzato da forte pressione concorrenziale, da consumatori sempre più informati e da un'ampia disponibilità di dati, l'ottimizzazione del pricing non può più basarsi esclusivamente su metodi tradizionali o sull'intuizione manageriale. Al contrario, richiede l'adozione di strumenti analitici avanzati in grado di tradurre i dati in

conoscenza utile per sostenere decisioni di prezzo più accurate, tempestive e coerenti con le dinamiche del mercato contemporaneo.

2.2.1 Il pricing come un problema di regressione

La letteratura più recente propone di interpretare l'ottimizzazione dei prezzi come un problema di regressione, in cui la variabile target è il punto di prezzo ottimale per ciascun prodotto, definito considerando gli attributi dell'articolo, i comportamenti dei clienti e le dinamiche competitive. In questa prospettiva, l'impiego del Machine Learning consente di analizzare relazioni complesse e non lineari tra le variabili, migliorando la capacità predittiva e permettendo decisioni più informate e adattive rispetto agli approcci convenzionali.

Tra le tecniche di regressione applicate al pricing, le evidenze empiriche mostrano che il Random Forest Regressor (RFR) risulta tra i modelli più efficaci e versatili. Ciò è dovuto alla sua capacità di gestire grandi quantità di dati, ridurre l'overfitting e rappresentare pattern complessi. In diverse applicazioni, il modello ha raggiunto un'accuratezza del 94%, superando approcci come il Decision Tree e la Logistic Regression. L'uso di algoritmi ensemble consente inoltre di migliorare la qualità delle previsioni e di fornire un supporto concreto alle politiche di prezzo.

La definizione del prezzo rimane, tuttavia, un aspetto critico per la competitività nel settore retail, poiché richiede un continuo adattamento alle condizioni di mercato e alle strategie dei concorrenti. Metodi tradizionali quali la regressione lineare o l'Ordinary Least Squares (OLS) si dimostrano spesso inadeguati in contesti caratterizzati da rapidi cambiamenti, nei quali fattori come la disponibilità di stock, le variazioni dei prezzi dei competitor e le preferenze dei clienti incidono in modo significativo sulle decisioni di pricing.

Per superare tali limiti, il Random Forest Regressor viene addestrato su dati storici e utilizza come input principali i prezzi dei concorrenti, i livelli di inventario e le preferenze dei consumatori, stimando con elevata accuratezza i prezzi futuri dei prodotti. L'analisi tiene conto sia dell'impatto della concorrenza sui prezzi di vendita, elemento determinante per la competitività, sia della relazione tra disponibilità di scorte e politiche di prezzo: una riduzione dello stock può generare un aumento dei prezzi, mentre un eccesso può favorire l'adozione di strategie di sconto.

La valutazione delle prestazioni del modello è condotta tramite il Mean Squared Error (MSE), che nella previsione dei prezzi raggiunge un valore dell'1,11%, confermando l'elevata precisione ottenuta. Il fine-tuning degli iperparametri contribuisce a migliorare ulteriormente le performance predittive. Il modello inoltre integra un sistema di monitoraggio dei prezzi dei competitor, che permette di elaborare raccomandazioni per l'adeguamento dei prezzi e di visualizzare l'andamento dei prodotti rispetto alla concorrenza. Questo approccio consente alle imprese di assumere decisioni di pricing basate su dati oggettivi, garantendo la coerenza delle strategie commerciali e la sostenibilità del vantaggio competitivo nel tempo.

Un ulteriore elemento messo in luce dalla letteratura riguarda la relazione tra dinamiche di prezzo e domanda. Sebbene il prezzo influenzi direttamente la quantità domandata, nei mercati reali tale relazione risulta più articolata, poiché intervengono fattori quali la concorrenza, la stagionalità, il posizionamento del prodotto e la percezione del valore da parte del cliente. In presenza di mercati dinamici e domanda incerta, il pricing statico mostra limiti evidenti, mentre il pricing dinamico, supportato da modelli di machine learning, consente di adattare i prezzi alle condizioni di mercato in tempo quasi reale.

Attraverso l'analisi di dati storici e competitivi, tali modelli permettono di stimare l'elasticità della domanda, prevedere le reazioni dei clienti ai diversi livelli di prezzo e individuare il punto di equilibrio tra profitto e competitività. Inoltre, essi consentono di incorporare nei processi decisionali variabili ulteriori, quali il ciclo di vita del prodotto, la disponibilità delle scorte, l'impatto delle promozioni e la risposta del mercato alle variazioni di prezzo, migliorando così la coerenza e l'efficacia delle decisioni aziendali.

In questo quadro, i dati provenienti dal contesto e-commerce risultano particolarmente preziosi, poiché includono sia caratteristiche fisiche dei prodotti (prezzo unitario, peso, dimensioni, numero di immagini o descrizioni) sia informazioni su clienti e concorrenti. Ciò consente di cogliere sia la componente interna della domanda, legata alle preferenze di acquisto, sia la componente esterna, influenzata dalle strategie di prezzo della concorrenza.

Il Random Forest, rispetto ad altre tecniche, mostra inoltre la capacità di combinare più alberi decisionali in un sistema ensemble che riduce la varianza e migliora la

robustezza delle stime. Questo approccio è particolarmente utile nei mercati retail, caratterizzati da eterogeneità dei prodotti e volatilità della domanda. I risultati empirici dimostrano che il modello si adatta a diverse categorie merceologiche e mantiene stabilità anche in presenza di shock esterni o di variazioni improvvise del mercato.

Alcuni studi prevedono l'integrazione di modelli ulteriori, come LightGBM e LSTM, per la previsione congiunta di domanda e vendite, evidenziando che l'inclusione di variabili esogene, ad esempio fattori meteorologici, eventi o campagne promozionali, può aumentare ulteriormente l'accuratezza delle previsioni e migliorare l'affidabilità delle decisioni di prezzo.

Una volta stimata la relazione tra le variabili, la determinazione del prezzo ottimale avviene combinando le previsioni di domanda con le informazioni sull'elasticità e con gli obiettivi aziendali, quali la massimizzazione del margine, del ricavo o della quota di mercato. In ambito e-commerce, il processo operativo comprende la raccolta dei dati, il preprocessing, l'analisi esplorativa, l'addestramento dei modelli e la selezione del prezzo ottimale sulla base degli indicatori di performance.

In questo modo, il Machine Learning consente di passare da politiche di prezzo statiche a strategie dinamiche e adattive, in grado di rispondere rapidamente ai cambiamenti del mercato e alle esigenze dei clienti, migliorando al contempo redditività e competitività.

Dal punto di vista manageriale, l'adozione del Machine Learning nel pricing consente di migliorare la precisione delle decisioni, ridurre l'incertezza legata all'esperienza soggettiva, integrare i segnali dei concorrenti e reagire rapidamente ai cambiamenti di mercato. Inoltre, supporta la personalizzazione delle strategie di prezzo, adattandole alle caratteristiche dei prodotti, dei segmenti e dei periodi.

In conclusione, l'impiego del Machine Learning per l'ottimizzazione dei prezzi nel retail rappresenta un'evoluzione significativa rispetto agli approcci tradizionali. Consente di passare da politiche di prezzo statiche a strategie dinamiche e adattive, in grado di rispondere in tempo reale ai cambiamenti del mercato e alle esigenze dei clienti.

L'integrazione tra modelli predittivi, analisi della domanda e obiettivi economici consente alle imprese di prendere decisioni più consapevoli, migliorando redditività e

competitività. Pur richiedendo competenze tecniche e una gestione accurata dei dati, il Machine Learning si configura come una risorsa strategica per la trasformazione digitale del retail, capace di coniugare efficienza operativa, precisione analitica e capacità di adattamento in un mercato sempre più dinamico e orientato ai dati.

2.2.2 L'ottimizzazione dinamica dei prezzi nel retail online attraverso tecniche di Machine Learning

Nel panorama dinamico dell'e-commerce contemporaneo, la definizione dei prezzi rappresenta un elemento centrale per la redditività e la competitività delle imprese. L'aumento della complessità dei mercati digitali, caratterizzati da consumatori esigenti e da dinamiche concorrenziali in continuo mutamento, richiede approcci sempre più flessibili e basati sui dati. In tale scenario, il pricing dinamico emerge come una strategia fondamentale, in quanto consente l'adeguamento dei prezzi in tempo reale in risposta alle variazioni della domanda, all'andamento del mercato e alle azioni dei concorrenti.

L'integrazione del Machine Learning in questo processo offre la possibilità di gestire grandi quantità di dati, individuare relazioni non lineari e ottimizzare le decisioni di prezzo con livelli di accuratezza e tempestività impensabili con i metodi tradizionali. L'obiettivo principale di tale approccio è massimizzare i profitti mantenendo al contempo la soddisfazione del cliente e la sostenibilità competitiva.

L'ottimizzazione dinamica dei prezzi basata su modelli di apprendimento automatico si fonda su un processo articolato che comprende la raccolta, la pulizia e la normalizzazione dei dati provenienti da fonti eterogenee. I dataset utilizzati includono informazioni sulle vendite, come prezzi, volumi e variabili correlate, dati di mercato relativi ai prezzi dei concorrenti, alle fluttuazioni della domanda e agli indicatori macroeconomici, oltre a dati sui clienti, come la cronologia degli acquisti e le caratteristiche demografiche. La preparazione dei dati prevede la rimozione di valori anomali o mancanti e la costruzione di variabili derivate utili a catturare l'andamento stagionale e le tendenze di mercato.

A partire da queste basi, vengono applicati diversi modelli di Machine Learning per stimare e aggiornare i prezzi in modo ottimale. Tra gli approcci più efficaci figurano i modelli di reinforcement learning, come il Q-learning, che consentono l'adeguamento iterativo dei prezzi in funzione dei risultati ottenuti; i modelli di previsione delle serie

temporali, come ARIMA e LSTM; e i modelli di regressione, come la regressione lineare e il gradient boosting, impiegati per individuare le variabili che influenzano maggiormente la formazione del prezzo.

Il reinforcement learning, in particolare, permette di apprendere politiche di prezzo che massimizzano il ritorno atteso nel lungo periodo, attraverso un aggiornamento costante dei valori associati alle azioni intraprese in ciascuno stato. Parallelamente, l'applicazione di modelli di personalizzazione, come quelli basati sul collaborative filtering e sulla matrix factorization, consente di adattare le strategie di prezzo alle preferenze dei singoli consumatori, migliorando l'efficacia del pricing e la fidelizzazione della clientela.

La valutazione dell'efficacia dei modelli si basa su metriche quantitative che includono l'analisi dell'errore e la misurazione dei profitti ottenuti. In uno scenario simulato di trenta giorni, l'applicazione del modello ha mostrato una crescita progressiva dei profitti, con un incremento da 1.000 a 3.900 unità monetarie, evidenziando l'efficacia del pricing dinamico guidato da algoritmi di apprendimento automatico. Tale risultato suggerisce che l'impiego sistematico di modelli predittivi consente di ottimizzare le decisioni di prezzo e di migliorare la performance economica complessiva delle imprese online.

Oltre all'aspetto economico, si contribuisce a migliorare l'esperienza del cliente, poiché la personalizzazione dei prezzi e delle offerte rafforza la percezione di valore e favorisce la fidelizzazione. I modelli di pricing dinamico basati sul Machine Learning permettono inoltre di adattarsi rapidamente alle variazioni delle condizioni di mercato, assicurando una maggiore reattività strategica. Tuttavia, l'adozione di tali tecniche richiede una gestione attenta delle implicazioni etiche e normative, in particolare in relazione alla trasparenza dei criteri di determinazione dei prezzi, alla tutela della privacy e alla parità di trattamento dei consumatori.

In prospettiva, l'evoluzione di questi sistemi sarà influenzata dallo sviluppo di modelli di deep learning e reinforcement learning avanzato, dall'integrazione di flussi di dati in tempo reale e dall'interconnessione con dispositivi e sensori dell'Internet of Things. Questi progressi consentiranno una definizione del prezzo sempre più precisa, contestualizzata e personalizzata. Inoltre, l'applicabilità del pricing dinamico non si limita

al settore del retail online, ma può estendersi a campi come i trasporti, l'energia e i servizi di ospitalità, in cui la variabilità della domanda e la necessità di ottimizzazione economica rendono tali approcci particolarmente efficaci.

In conclusione, l'impiego del machine learning per l'ottimizzazione dinamica dei prezzi rappresenta un passo decisivo verso una gestione più intelligente e adattiva delle strategie commerciali. L'integrazione tra analisi predittiva, automazione decisionale e personalizzazione consente di coniugare efficienza operativa, incremento della redditività e miglioramento dell'esperienza del cliente, delineando un nuovo paradigma competitivo per il commercio elettronico contemporaneo.

2.2.3 L'integrazione di IoT e Machine Learning per l'analisi in tempo reale dell'elasticità dei prezzi

L'analisi in tempo reale dell'elasticità dei prezzi nel settore retail rappresenta un'evoluzione significativa delle strategie di pricing, resa possibile dall'integrazione tra tecnologie dell'Internet of Things (IoT) e modelli di apprendimento automatico. L'obiettivo principale di questo approccio è stimare con maggiore precisione la sensibilità della domanda alle variazioni di prezzo e consentire decisioni più tempestive e basate sui dati, migliorando al contempo la redditività e la soddisfazione del cliente.

Il sistema di analisi si fonda sulla raccolta continua di dati provenienti da sensori intelligenti, videocamere, scaffali digitali, etichette elettroniche e dispositivi mobili, che monitorano in tempo reale variabili come i livelli di inventario, i flussi di visitatori, le interazioni con i prodotti e le condizioni ambientali dei punti vendita. Queste informazioni vengono integrate con dati storici relativi a vendite, promozioni e prezzi, creando un insieme di dati coerente e strutturato che consente una rappresentazione accurata delle dinamiche di mercato e dei comportamenti dei consumatori.

All'interno di questo contesto, i modelli di Machine Learning, in particolare quelli basati su tecniche di apprendimento ensemble come il Gradient Boosting Machine (GBM), vengono utilizzati per individuare relazioni complesse tra variazioni di prezzo e risposta dei clienti. Tali modelli combinano previsioni di più alberi decisionali per migliorare l'accuratezza delle stime e ridurre gli errori predittivi, consentendo di stimare in modo affidabile l'elasticità della domanda e di adattare i prezzi in tempo reale alle condizioni di mercato.

Il processo analitico comprende diverse fasi: la preparazione dei dati attraverso operazioni di pulizia e normalizzazione, la selezione delle variabili più significative mediante tecniche di feature engineering, l'addestramento dei modelli su dati storici e la successiva validazione tramite procedure di cross-validation. Una volta completata la fase di addestramento, i modelli vengono alimentati da flussi di dati in tempo reale provenienti dai dispositivi IoT, producendo stime aggiornate dell'elasticità e suggerendo adeguamenti dinamici dei prezzi.

L'integrazione tra Machine Learning e IoT consente ai rivenditori di adottare strategie di pricing più reattive e personalizzate, capaci di rispondere alle variazioni della domanda, alle attività dei concorrenti e ai mutamenti delle preferenze dei consumatori. Inoltre, la presenza di un meccanismo di feedback continuo permette al sistema di aggiornare costantemente i modelli sulla base dei risultati osservati, garantendo un miglioramento progressivo della precisione predittiva e dell'efficacia delle decisioni di prezzo.

L'applicazione di tale approccio produce risultati significativi in termini di efficienza operativa: la gestione dei prezzi diventa più coerente con le dinamiche della domanda, la rotazione delle scorte migliora grazie alla riduzione di surplus e mancanze di prodotto, e le promozioni possono essere ottimizzate in base alla risposta effettiva dei consumatori. I modelli predittivi, analizzando grandi quantità di dati provenienti da fonti eterogenee, consentono di individuare le soglie di prezzo più redditizie e di calibrare in modo ottimale le politiche di sconto e incentivo.

Dal punto di vista gestionale, l'adozione di un sistema di analisi dell'elasticità dei prezzi in tempo reale favorisce il passaggio da strategie di pricing statiche a strategie adattive e orientate ai dati. Le imprese che implementano tali strumenti possono prendere decisioni più rapide e fondate, migliorando la capacità di anticipare le tendenze di mercato e di mantenere un vantaggio competitivo sostenibile.

Infine, l'evoluzione di queste tecnologie apre prospettive di sviluppo verso sistemi ancora più integrati e predittivi, nei quali la combinazione di dati provenienti da dispositivi IoT, modelli di Machine Learning e flussi informativi esterni, come indicatori economici o dati meteorologici, consentirà di affinare ulteriormente le strategie di prezzo e di rendere la gestione commerciale sempre più intelligente, efficiente e reattiva.

2.2.4 Prospettive evolutive e sfide

In prospettiva, l'evoluzione dei sistemi di pricing dinamico sarà fortemente influenzata dallo sviluppo di modelli di deep learning e di reinforcement learning avanzato, dall'integrazione di flussi di dati in tempo reale e dall'interconnessione con dispositivi e sensori appartenenti all'Internet of Things (IoT). Questi progressi permetteranno di realizzare una definizione dei prezzi sempre più precisa, contestualizzata e personalizzata, capace di adattarsi in modo continuo alle condizioni del mercato e alle preferenze dei consumatori.

L'applicabilità del pricing dinamico basato su AI non si limita al settore del retail online, ma si estende a diversi ambiti economici, quali i trasporti, l'energia e i servizi di ospitalità, nei quali la variabilità della domanda e la necessità di ottimizzazione economica rendono tali approcci particolarmente efficaci. Tuttavia, nonostante i numerosi benefici potenziali, l'implementazione di strategie di prezzo fondate sull'intelligenza artificiale presenta sfide significative. La costruzione di modelli accurati richiede infatti dati di elevata qualità e diversificazione, oltre a un rilevante investimento in risorse computazionali (Perakis et al., 2023).

Ulteriori criticità emergono dalla complessità della modellazione congiunta di prezzo e produzione, nonché dalla necessità di assicurare trasparenza ed equità nelle decisioni di prezzo automatizzate. Tali aspetti assumono particolare rilievo in relazione al mantenimento della fiducia dei consumatori, che rappresenta un fattore determinante per la sostenibilità delle strategie di pricing (Dehghanpour et al., 2018; Perakis et al., 2023).

Le prospettive di ricerca futura dovrebbero pertanto concentrarsi sullo sviluppo di modelli di AI più adattivi e meno dipendenti da grandi quantità di dati, favorendo l'integrazione tra le strategie di pricing automatizzato e l'analisi del comportamento dei clienti. Parallelamente, risulta necessario approfondire le implicazioni etiche legate all'utilizzo dell'intelligenza artificiale nella definizione dei prezzi, con l'obiettivo di garantire trasparenza, equità e conformità normativa (Dehghanpour et al., 2018; Perakis et al., 2023; Subbarayudu et al., 2023).

Dal punto di vista operativo, i rivenditori dovrebbero adottare una serie di approcci pratici volti a migliorare l'applicazione delle strategie di gestione dei prezzi e della

redditività basate sull'AI. L'uso di tecniche di data augmentation e di generazione di dati sintetici può contribuire a superare le limitazioni derivanti da dataset incompleti o distorti, incrementando l'affidabilità e la precisione dei modelli di prezzo. Allo stesso tempo, l'implementazione di strumenti di AI spiegabile (Explainable AI) risulta cruciale per assicurare trasparenza e tracciabilità nelle decisioni di pricing, rafforzando la fiducia dei consumatori e mitigando le preoccupazioni legate all'equità dei processi decisionali.

Un ulteriore elemento strategico riguarda l'investimento in infrastrutture computazionali avanzate, comprese le piattaforme cloud-based, che consentono di gestire efficacemente la complessità dei moderni algoritmi di pricing. L'integrazione della prezzatura automatizzata con l'analisi in tempo reale del comportamento dei clienti permette inoltre di sviluppare strategie di prezzo reattive e personalizzate, orientate al miglioramento della soddisfazione e della fedeltà della clientela.

Sul piano etico e regolamentare, risulta essenziale la definizione di linee guida per pratiche di prezzo trasparenti e non discriminatorie, al fine di garantire la conformità agli standard normativi e rafforzare la reputazione aziendale. Infine, la collaborazione interdisciplinare tra data scientist, economisti e professionisti del marketing può favorire lo sviluppo di strategie di prezzo più complete, bilanciate e sostenibili, capaci di coniugare obiettivi di redditività con il rispetto delle aspettative dei consumatori.

2.3 Il Machine Learning per la segmentazione della clientela nel retail

La segmentazione della clientela rappresenta una delle attività più rilevanti per la gestione strategica nel settore retail, in quanto consente di comprendere i comportamenti di acquisto e di definire politiche di marketing, pricing e fidelizzazione più mirate. In un contesto caratterizzato da una crescente complessità dei mercati e da una disponibilità sempre maggiore di dati, il machine learning offre strumenti avanzati per analizzare la clientela in modo più preciso e dinamico, superando i limiti delle tecniche tradizionali di segmentazione.

L'obiettivo della segmentazione non si limita più alla classificazione dei clienti in gruppi statici, ma si estende all'individuazione di schemi ricorrenti nei comportamenti di consumo e alla comprensione delle possibili evoluzioni nel tempo, al fine di orientare le decisioni aziendali in modo più consapevole e proattivo. In tale prospettiva, l'impiego di algoritmi di clustering non supervisionato, come K-means, clustering gerarchico e DBSCAN, consente di individuare gruppi omogenei di clienti a partire dai dati transazionali e comportamentali, analizzando variabili quali la frequenza e il valore degli acquisti, la spesa complessiva e la recente attività di consumo. Attraverso processi di data cleaning, trasformazione e analisi esplorativa, è possibile migliorare la qualità dei dati e selezionare le variabili più rilevanti per la segmentazione.

L'applicazione di tali metodologie evidenzia come il valore economico generato dalla clientela non sia distribuito in modo uniforme, ma presenti una marcata eterogeneità tra i diversi segmenti. In molti contesti retail, una parte numericamente limitata della base clienti contribuisce in misura significativa alla creazione di valore complessivo, mentre una quota più ampia genera un impatto economico più contenuto. Tale asimmetria riflette differenze strutturali nei comportamenti di acquisto, nella frequenza delle transazioni e nell'intensità della relazione con l'impresa, confermando la necessità di politiche di marketing differenziate per i diversi gruppi di clienti.

I clienti ad alto valore, pur rappresentando una componente numericamente ridotta, assumono un ruolo centrale sotto il profilo economico, in quanto caratterizzati da livelli di spesa più elevati e da una maggiore continuità nelle interazioni con l'azienda. La loro rilevanza non è riconducibile esclusivamente al contributo immediato ai ricavi, ma anche alla stabilità della relazione e al potenziale di generazione di valore nel tempo. Al

contrario, segmenti più ampi della clientela presentano un contributo economico inferiore, spesso associato a comportamenti di acquisto meno regolari o a una minore intensità del rapporto commerciale.

Questa configurazione sottolinea l'importanza di interpretare la segmentazione non soltanto come uno strumento descrittivo, ma come una base analitica per la valutazione del peso economico dei diversi gruppi di clienti. La distinzione tra segmenti consente infatti di riconoscere il diverso ruolo che ciascun gruppo riveste nella creazione di valore e di evitare approcci di marketing uniformi che non tengano conto di tali differenze. In tale ottica, risulta spesso utile integrare le tecniche di Machine Learning con modelli gestionali consolidati, come il modello RFM (Recency, Frequency, Monetary), che sintetizza in pochi indicatori chiave la relazione economica tra cliente e impresa. L'utilizzo congiunto di modelli di clustering e indici RFM permette di combinare la solidità analitica delle tecniche algoritmiche con l'immediatezza interpretativa dei modelli gestionali, offrendo una base più affidabile per la definizione delle strategie di marketing.

Parallelamente, l'evoluzione del Machine Learning consente di affrontare la segmentazione in una prospettiva sempre più dinamica e predittiva. L'integrazione di indicatori come RFM e Customer Lifetime Value (CLV) con modelli di classificazione supervisionata permette di anticipare i cambiamenti nei comportamenti dei clienti e di stimarne il valore futuro. In questo modo, la segmentazione non si limita a una rappresentazione del presente, ma diventa uno strumento di previsione utile per la pianificazione di azioni di fidelizzazione, campagne promozionali e strategie di allocazione delle risorse di marketing.

Il calcolo del CLV, inteso come valore atteso dei flussi futuri generati dal cliente su un determinato orizzonte temporale, rappresenta un ulteriore elemento di supporto alla segmentazione predittiva. Esso consente di stimare non solo il contributo passato di ciascun cliente, ma anche il potenziale economico futuro, permettendo alle imprese di definire priorità di investimento e strategie di retention più efficaci. I modelli predittivi basati sul machine learning, integrando i dati storici con variabili comportamentali, offrono inoltre la possibilità di individuare in anticipo i clienti più promettenti, contribuendo a una gestione più efficiente e redditizia del portafoglio clienti.

Affinché i risultati della segmentazione risultino affidabili e utilizzabili a fini decisionali, risulta fondamentale affiancare all'applicazione degli algoritmi una fase di valutazione della qualità dei cluster individuati. In tale contesto, l'impiego di metriche di validazione consente di analizzare il grado di coesione interna dei gruppi e la loro separazione reciproca, supportando la scelta della configurazione più appropriata in termini di numero di cluster e di algoritmo utilizzato. Il confronto tra le prestazioni dei diversi modelli permette così di selezionare l'approccio più idoneo rispetto alla struttura dei dati e agli obiettivi dell'analisi.

Nel complesso, le evidenze emerse mostrano come la qualità e la profondità dei dati rappresentino fattori determinanti per la costruzione di segmentazioni affidabili e interpretabili. Dataset completi e coerenti favoriscono una maggiore stabilità dei cluster, mentre una selezione mirata delle variabili consente di evidenziare pattern realmente significativi per le decisioni aziendali. L'integrazione tra valutazione statistica e interpretazione manageriale rafforza l'utilità operativa delle analisi, rendendo la segmentazione uno strumento concretamente applicabile.

In sintesi, la segmentazione della clientela basata su tecniche di Machine Learning rappresenta un'evoluzione significativa rispetto agli approcci tradizionali, consentendo il passaggio da una visione statica a una prospettiva dinamica e orientata al valore. L'integrazione tra clustering, indici RFM, stima del CLV e modelli predittivi fornisce un quadro analitico e gestionale completo, che permette alle imprese retail di differenziare le proprie strategie commerciali, migliorare la fedeltà dei clienti e accrescere la redditività nel lungo periodo. In questo senso, il Machine Learning si configura non solo come uno strumento di supporto all'analisi dei dati, ma come una leva strategica per la costruzione di vantaggi competitivi sostenibili in un contesto di mercato sempre più orientato ai dati e alla personalizzazione delle relazioni con la clientela.

2.3.1 1 La natura dinamica dei segmenti di clientela

Nel contesto competitivo contemporaneo, la segmentazione della clientela non può più essere interpretata come un processo statico e immutabile, ma deve essere considerata come un fenomeno intrinsecamente dinamico, soggetto a continui cambiamenti nel tempo. L'evoluzione dei comportamenti di acquisto, delle preferenze dei consumatori e

dell'intensità della relazione con l'impresa determina infatti variazioni significative nel valore economico dei clienti e nella loro appartenenza ai diversi segmenti.

La letteratura più recente evidenzia come i clienti possano transitare tra segmenti differenti nel corso del tempo, passando, ad esempio, da posizioni a basso valore a segmenti più redditizi o, al contrario, manifestando una progressiva riduzione del proprio contributo economico. Tali transizioni riflettono modifiche nei livelli di spesa, nella frequenza delle interazioni e nella continuità del rapporto con l'impresa, rendendo necessaria una visione evolutiva della segmentazione. In questa prospettiva, i segmenti non rappresentano categorie definitive, bensì stati temporanei che descrivono la fase della relazione cliente-impresa in un determinato momento.

L'attenzione verso la dimensione dinamica della segmentazione emerge in modo chiaro negli studi che analizzano i cambiamenti e le transizioni tra segmenti di clientela. Diversi contributi sottolineano come l'analisi delle variazioni nel tempo consenta di cogliere con maggiore accuratezza il comportamento dei clienti e di supportare decisioni di marketing più efficaci. L'integrazione di modelli basati su indicatori comportamentali, quali recency, frequency e monetary value, con tecniche di clustering e approcci di Machine Learning permette infatti di osservare l'evoluzione dei segmenti e di individuare pattern ricorrenti nei passaggi da un gruppo all'altro.

In tale contesto, la previsione del Customer Lifetime Value assume un ruolo centrale, poiché consente di collegare la segmentazione a una valutazione prospettica del contributo economico dei clienti. La stima del valore futuro permette non solo di identificare i segmenti più rilevanti in termini storici, ma anche di anticipare possibili cambiamenti nella composizione della base clienti. La capacità di prevedere le transizioni tra segmenti rende la segmentazione uno strumento strategico, orientato non solo alla descrizione della realtà attuale, ma anche al supporto delle decisioni future.

L'approccio dinamico alla segmentazione risulta particolarmente rilevante anche in ottica manageriale. La consapevolezza che i clienti possano modificare il proprio comportamento e il proprio valore nel tempo consente alle imprese di adottare strategie più flessibili e mirate, evitando interventi uniformi e poco efficaci. La gestione attiva dei segmenti, basata sull'anticipazione dei cambiamenti, favorisce un'allocazione più

efficiente delle risorse di marketing e una maggiore capacità di adattamento alle trasformazioni del mercato.

In sintesi, considerare la segmentazione della clientela come un processo dinamico rappresenta un'evoluzione fondamentale rispetto agli approcci tradizionali. L'analisi delle transizioni tra segmenti e la previsione del valore futuro dei clienti consentono di superare una visione statica della clientela, offrendo una base analitica più solida per la definizione di strategie di marketing orientate alla creazione di valore nel lungo periodo. In questo senso, la natura dinamica dei segmenti di clientela costituisce un elemento chiave per comprendere e gestire in modo efficace le relazioni tra impresa e consumatore in contesti di mercato caratterizzati da elevata competitività e continua evoluzione.

2.3.2 Machine learning per la segmentazione dei clienti e l'elaborazione di strategie di marketing

La segmentazione dei clienti rappresenta una fase centrale nella definizione di strategie di marketing efficaci, in quanto consente di suddividere la clientela in gruppi caratterizzati da comportamenti di acquisto omogenei. L'impiego delle tecniche di machine learning, in particolare degli algoritmi di apprendimento non supervisionato, permette di individuare in modo sistematico pattern e relazioni latenti nei dati, migliorando la comprensione dei comportamenti di consumo e aumentando la precisione delle decisioni di marketing.

Tra gli approcci più consolidati per l'analisi del comportamento dei clienti si colloca il modello RFM (Recency, Frequency, Monetary), basato su tre dimensioni chiave: il tempo trascorso dall'ultima transazione, la frequenza degli acquisti e il valore monetario complessivo generato dal cliente. La combinazione di elevata frequenza e spesa con una bassa recency consente generalmente di identificare clienti più attivi, fedeli e rilevanti sotto il profilo economico.

L'applicazione congiunta del modello RFM e degli algoritmi di clustering su ampi insiemi di dati consente di individuare gruppi di clienti con caratteristiche simili, all'interno dei quali emergono tipicamente profili distinti. Alcuni segmenti risultano caratterizzati da livelli contenuti di spesa e di interazione e da una relazione debole con l'impresa, mentre altri presentano un contributo economico più elevato e una maggiore

continuità nel rapporto con l'azienda. Accanto a questi, si collocano segmenti intermedi, contraddistinti da livelli moderati di coinvolgimento e da una recente attività di acquisto.

Questa articolazione della clientela fornisce una base informativa utile per la definizione di strategie di marketing differenziate. I clienti con un basso livello di attività possono essere destinatari di iniziative di riattivazione finalizzate a ristabilire il rapporto con l'impresa, mentre i clienti a maggiore valore richiedono politiche di mantenimento orientate alla personalizzazione dell'offerta e al rafforzamento della fedeltà. I segmenti intermedi, infine, rappresentano un ambito strategico su cui concentrare azioni volte ad aumentare progressivamente la frequenza di acquisto e la spesa complessiva.

In un contesto di mercato caratterizzato da elevata competitività e da una crescente disponibilità di dati, la segmentazione non può tuttavia essere interpretata esclusivamente come un'attività statica di classificazione. Al contrario, essa assume una valenza dinamica, strettamente connessa alla capacità di comprendere come i clienti evolvano nel tempo e come possano modificare la propria appartenenza ai diversi segmenti. In questa prospettiva, l'attenzione si sposta dall'analisi delle caratteristiche attuali della clientela all'osservazione delle possibili traiettorie di evoluzione dei comportamenti di acquisto e dei livelli di coinvolgimento.

L'approccio basato sul Machine Learning e sull'analisi RFM consente così di superare una visione puramente descrittiva della segmentazione, orientandola verso finalità previsionali e decisionali. La possibilità di individuare segnali di indebolimento della relazione con il cliente o, al contrario, potenziali percorsi di crescita del valore, supporta in modo più efficace le strategie di customer retention e la gestione delle relazioni di lungo periodo.

In tale contesto, la segmentazione orientata al valore diventa uno strumento essenziale per l'elaborazione di strategie di marketing coerenti con gli obiettivi di redditività e sostenibilità nel tempo. La stima del contributo economico dei clienti, sia in termini attuali sia prospettici, consente di allocare le risorse di marketing in modo più mirato, rafforzando la continuità del rapporto con la clientela e riducendo il rischio di perdita di valore.

Dal punto di vista gestionale, la segmentazione ottenuta mediante tecniche di Machine Learning facilita la traduzione delle analisi dei dati in azioni operative mirate. La possibilità di riconoscere clienti a maggiore valore e clienti potenzialmente a rischio di inattività consente di pianificare interventi differenziati, migliorando l'efficacia complessiva delle iniziative promozionali. Tuttavia, l'utilità di tali strumenti dipende dalla capacità di bilanciare le prestazioni dei modelli con la loro trasparenza e interpretabilità, affinché le analisi possano essere effettivamente integrate nei processi decisionali.

In una prospettiva di lungo periodo, considerare la segmentazione come uno strumento dinamico di supporto alla previsione e alla retention consente di superare una visione statica della clientela. Il Machine Learning si configura così non solo come un mezzo di supporto analitico, ma come una leva strategica per la definizione di politiche di marketing orientate alla creazione e alla gestione del valore nel tempo.

In un contesto di mercato caratterizzato da elevata competitività e da una crescente disponibilità di dati, la segmentazione supportata dal machine learning non può essere interpretata unicamente come un'attività statica di classificazione della clientela. Al contrario, essa assume una valenza dinamica e strategica, strettamente connessa alla capacità di comprendere l'evoluzione dei comportamenti di acquisto e le possibili transizioni dei clienti tra segmenti differenti nel tempo. In tale prospettiva, l'attenzione si sposta dall'osservazione delle caratteristiche attuali della clientela verso l'analisi delle traiettorie evolutive dei livelli di coinvolgimento e del contributo economico generato.

L'integrazione tra tecniche di machine learning, analisi RFM e segmentazione orientata al valore consente di superare una visione puramente descrittiva del marketing, rafforzandone la dimensione previsiva e decisionale. La possibilità di individuare segnali di indebolimento della relazione con il cliente o, al contrario, potenziali percorsi di crescita del valore, supporta in modo più efficace le strategie di customer retention e la gestione delle relazioni di lungo periodo. In questo quadro, la segmentazione diventa uno strumento operativo per la pianificazione delle azioni di marketing, coerente con gli obiettivi di redditività e sostenibilità nel tempo.

All'interno di tale approccio, la stima del Customer Lifetime Value assume un ruolo centrale come criterio di priorità strategica. La possibilità di valutare il contributo

economico dei clienti non solo in termini storici, ma anche prospettici, consente alle imprese di orientare in modo più consapevole l’allocazione delle risorse di marketing. L’utilizzo del CLV permette infatti di identificare i clienti a maggiore rilevanza economica attesa e di concentrare su di essi gli sforzi di fidelizzazione, riducendo al contempo il rischio di una gestione poco selettiva degli investimenti.

La conoscenza delle dinamiche di cambiamento dei segmenti di clientela, integrata con la valutazione del valore nel tempo, favorisce inoltre una maggiore coerenza tra obiettivi strategici e azioni operative. La segmentazione orientata al valore consente di personalizzare le iniziative di marketing in funzione delle priorità economiche, rafforzando la continuità del rapporto con i clienti più rilevanti e migliorando l’efficacia complessiva delle politiche promozionali. In tale ottica, il Customer Lifetime Value si configura come elemento di raccordo tra segmentazione, previsione e strategie di retention, contribuendo a una gestione della clientela più consapevole, selettiva e orientata alla creazione di valore nel lungo periodo.

2.3.3 Il ruolo del Machine Learning nell’analisi del comportamento dei clienti

Se la segmentazione della clientela basata su tecniche di Machine Learning consente di individuare gruppi omogenei di consumatori e di supportare la definizione di strategie di marketing mirate, l’analisi del comportamento dei clienti rappresenta un livello di approfondimento ulteriore, finalizzato a comprendere in che modo tali modelli incidano sui processi decisionali e sulle risposte del consumatore.

In ambito retail, il Machine Learning assume pertanto un ruolo centrale nell’interpretazione dei comportamenti di acquisto, in particolare con riferimento alla personalizzazione dell’esperienza e all’influenza esercitata sulle decisioni dei clienti. L’elaborazione di ampi volumi di dati comportamentali consente infatti ai modelli di Machine Learning di identificare pattern ricorrenti e di anticipare le preferenze individuali, favorendo lo sviluppo di interazioni personalizzate e contribuendo al rafforzamento della fedeltà al marchio (Ho & Chow, 2023; Rana et al., 2024; Sharma et al., 2024).

Le soluzioni basate su Machine Learning, tra cui i sistemi di decisione autonoma e i modelli di raccomandazione, permettono di analizzare non solo i comportamenti osservabili, ma anche aspetti riconducibili alle dimensioni cognitive ed emotive del consumatore. Ciò offre ai rivenditori la possibilità di adattare le strategie di marketing in modo più mirato, con ricadute dirette sul livello di coinvolgimento del cliente, sulla propensione all'acquisto d'impulso e sulle intenzioni di riacquisto (Arachchi & Samarasinghe, 2023; Rodgers et al., 2021).

Accanto ai benefici derivanti dall'impiego del machine learning, l'integrazione di tali tecnologie nei processi di analisi del comportamento dei clienti presenta alcune criticità rilevanti. In particolare, le preoccupazioni legate alla tutela della privacy dei dati, alla trasparenza dei modelli e al livello di fiducia nei sistemi automatizzati possono incidere sull'accettazione da parte dei consumatori e, di conseguenza, sull'efficacia delle soluzioni adottate (Canhoto et al., 2024; Lu et al., 2024). A queste problematiche si aggiunge la variabilità delle risposte dei clienti, influenzata da fattori culturali e sociali, che rende complessa l'applicazione uniforme dei modelli di machine learning in contesti di mercato differenti (S. Sharma et al., 2024).

Alla luce di tali elementi critici, la ricerca futura è chiamata a concentrarsi sullo sviluppo di modelli di Machine Learning in grado di adattarsi alla natura dinamica del comportamento dei consumatori. Ciò richiede l'integrazione di tipologie di dati eterogenee, quali dati comportamentali in tempo reale e informazioni biometriche, nonché una maggiore attenzione ai fattori culturali e sociali che influenzano l'adozione di queste tecnologie nei diversi mercati (Rodgers et al., 2021; Sharma et al., 2024). Parallelamente, risulta essenziale migliorare l'interpretabilità e la precisione dei modelli, al fine di garantire l'affidabilità degli insight generati e di consolidare la fiducia nei confronti delle analisi basate sul machine learning (Santoro et al., 2019).

Le implicazioni etiche connesse all'utilizzo del Machine Learning nell'analisi del comportamento dei clienti costituiscono un ulteriore ambito di riflessione, in particolare per quanto riguarda il bilanciamento tra il grado di personalizzazione offerto e la tutela della privacy, nonché il rafforzamento delle misure di protezione dei dati personali (Canhoto et al., 2024; Carolan, 2018). In tale prospettiva, l'integrazione di analisi quantitative basate su modelli di machine learning con approfondimenti di natura

qualitativa consente di sviluppare una comprensione più articolata delle preferenze e dei comportamenti dei consumatori (Evans & Kitchin, 2018; Videla-Cavieres & Ríos, 2014).

Per affrontare in modo efficace le sfide legate all'adozione del Machine Learning nell'analisi del comportamento dei clienti, i rivenditori possono adottare un framework orientato alla trasparenza, alla protezione dei dati e all'adattabilità dei modelli. L'implementazione di sistemi di crittografia avanzata e di politiche sulla privacy chiare e accessibili può contribuire a mitigare le problematiche di fiducia, mentre l'impiego di modelli di Machine Learning culturalmente adattivi favorisce la rilevanza delle soluzioni nei diversi contesti di mercato. Inoltre, attribuire priorità all'interpretabilità dei modelli, anche attraverso l'utilizzo di strumenti di Explainable AI, consente di aumentare la chiarezza dei processi decisionali. Infine, la combinazione di dati biometrici con informazioni qualitative permette di approfondire la comprensione dei bisogni dei clienti, supportando lo sviluppo di strategie di personalizzazione efficaci e coerenti con elevati standard etici in un contesto di mercato sempre più sensibile alle tematiche della privacy.

2.4 Previsione della domanda nel retail: approcci di Machine Learning e implicazioni gestionali

La previsione accurata della domanda nel settore retail riveste un ruolo centrale per garantire livelli di stock adeguati, prevenire le rotture di magazzino, limitare gli eccessi di inventario e allineare in modo più efficace l'offerta alle dinamiche del mercato. Essa orienta le decisioni di approvvigionamento, produzione, distribuzione e pianificazione commerciale, con effetti diretti sui costi, sui livelli di servizio e sull'affidabilità complessiva della supply chain. In tale contesto, l'Intelligenza Artificiale e il Machine Learning consentono di superare i limiti degli approcci tradizionali, offrendo strumenti in grado di catturare relazioni non lineari tra un ampio insieme di variabili e di produrre stime più affidabili, soprattutto quando vengono integrate informazioni di contesto quali dati meteorologici, calendario, caratteristiche dei punti vendita, indicatori economici e livelli di vendita storici.

L'evoluzione dell'analitica predittiva e della modellazione nel retail è strettamente legata all'adozione di modelli avanzati di Machine Learning, che hanno dimostrato una capacità superiore rispetto ai metodi di regressione tradizionale nella previsione delle vendite, nella gestione dell'inventario e nel supporto alle decisioni di pricing. L'utilizzo di tecniche come le random forest e le reti neurali profonde consente di migliorare la precisione delle previsioni e di analizzare l'impatto di fattori esterni, tra cui le condizioni meteorologiche, favorendo una maggiore adattabilità dei modelli a contesti caratterizzati da elevata variabilità.

Tuttavia, l'adozione dell'analitica predittiva nel retail presenta ancora criticità rilevanti, legate alla necessità di disporre di dati di elevata qualità, alle difficoltà di integrazione di fonti informative eterogenee e alla presenza di sistemi legacy. In questo quadro, la ricerca e la pratica applicativa sono orientate allo sviluppo di modelli più adattivi e alla combinazione di approcci predittivi differenti, al fine di rafforzare il processo decisionale e migliorare il controllo della qualità dei dati.

L'impostazione generale del capitolo è orientata a fornire un supporto concettuale e operativo alle decisioni di pianificazione nel retail, con particolare riferimento all'approvvigionamento e alla gestione delle scorte nei punti vendita. In tale prospettiva, vengono esaminati i principali approcci di machine learning utilizzati nella previsione

della domanda, evidenziandone le modalità di impiego e il ruolo nel supporto alle decisioni. L'analisi prende in considerazione sia modelli per serie temporali sia modelli di regressione, al fine di illustrare come differenti soluzioni possano essere applicate per descrivere l'evoluzione delle vendite in presenza di stagionalità, variabilità locale della domanda e cambiamenti nelle condizioni di mercato.

Per ottenere risultati affidabili è essenziale adottare una pipeline dati rigorosa, che includa la raccolta e la pulizia dei dati, la gestione sistematica di valori mancanti e duplicati, l'individuazione e il trattamento dei valori anomali, la costruzione di variabili temporali derivate, quali ritardi, medie mobili e indicatori di stagionalità settimanale e mensile, e una corretta separazione temporale tra insiemi di addestramento, validazione e test.

La valutazione delle prestazioni deve essere condotta rispettando l'ordine temporale delle osservazioni, stimando ogni previsione utilizzando esclusivamente le informazioni disponibili fino a quel momento, secondo la logica del forward chaining, così da riprodurre in modo fedele il processo decisionale reale. L'integrazione di variabili esogene, come la temperatura o la dimensione del punto vendita, consente di incrementare sensibilmente la capacità predittiva rispetto ai modelli basati unicamente sullo storico delle vendite.

Le applicazioni discusse evidenziano come la previsione della domanda, se supportata da modelli di Machine Learning adeguati e da una pipeline dati strutturata, rappresenti un elemento chiave per il governo integrato delle decisioni operative nel retail.

Alla luce di questo inquadramento, di seguito vengono analizzati gli approcci di Machine Learning e le pipeline dati impiegate per la costruzione di modelli previsivi della domanda nel retail.

2.4.1 Approcci di Machine Learning e pipeline dati per la previsione della domanda

Un primo approccio analizzato utilizza tecniche di clustering applicate ai dati storici di vendita per gruppi di prodotti. Metodi come il clustering gerarchico agglomerativo permettono di raggruppare articoli caratterizzati da andamenti di vendita simili, anche in presenza di domanda intermittente o altamente variabile. Questo tipo di aggregazione

consente di ottenere previsioni più stabili in presenza di serie rumorose, di migliorare la robustezza nei casi di volumi ridotti o irregolari e di garantire una maggiore scalabilità quando il numero di articoli è elevato.

Un'ulteriore strategia è rappresentata dalla previsione basata su cluster ottenuta tramite K-means. In questo caso, i prodotti vengono raggruppati in base a profili di vendita simili e la scelta del numero di cluster viene effettuata mediante criteri come l'Elbow Method. Le vendite aggregate a livello di cluster vengono quindi utilizzate come informazione di supporto per la previsione delle vendite dei singoli articoli, riducendo l'impatto del "rumore" nelle serie individuali e migliorando la stabilità delle stime. Dal punto di vista operativo, tale approccio favorisce una pianificazione delle scorte più coerente, consentendo di gestire in modo coordinato prodotti caratterizzati da dinamiche di domanda analoghe.

Un ulteriore approccio prende in esame le vendite a livello di prodotto e punto vendita, utilizzando dataset che includono sia caratteristiche degli articoli sia caratteristiche dei negozi. Il flusso di lavoro comprende una fase di pulizia approfondita dei dati, la trasformazione di alcune variabili per migliorarne l'utilità informativa e l'applicazione di diversi algoritmi di machine learning, con l'obiettivo di confrontarne le prestazioni in termini di accuratezza predittiva. Tra i modelli considerati figurano alberi decisionali, regressione lineare, regressione ridge e metodi di boosting come XGBoost e LightGBM.

Gli alberi decisionali offrono una rappresentazione interpretabile delle relazioni tra variabili, sotto forma di regole decisionali, ma presentano anche limiti quali la tendenza al sovradattamento e la sensibilità alla multicollinearità. La regressione lineare modella la relazione tra vendite e variabili esplicative minimizzando gli scarti quadratici, mentre la regressione ridge introduce un termine di penalizzazione per contenere l'overfitting e rendere il modello più robusto in presenza di un numero elevato di variabili. I metodi di boosting, in particolare XGBoost e LightGBM, combinano iterativamente più alberi decisionali per migliorare progressivamente l'accuratezza delle previsioni. XGBoost si distingue per la capacità di gestire dati mancanti e per l'elevata accuratezza predittiva, mentre LightGBM migliora ulteriormente l'efficienza computazionale grazie a una

crescita dell'albero di tipo leaf-wise, risultando particolarmente adatto a contesti ad alta dimensionalità.

Sulla base di questi elementi viene delineata un'architettura per un sistema di previsione delle vendite che comprende la raccolta dei dati da fonti interne ed esterne, la fase di pulizia e trasformazione, l'addestramento dei modelli di machine learning e un livello applicativo in grado di fornire previsioni quasi in tempo reale a supporto dei processi decisionali. Tale architettura è orientata a garantire accuratezza, scalabilità e un efficace supporto operativo nella pianificazione delle scorte e nella gestione dell'assortimento.

Le prospettive di sviluppo includono l'estensione dei modelli mediante l'integrazione di ulteriori variabili esterne e l'esplorazione di soluzioni ibride che combinino tecniche di machine learning con approcci statistici tradizionali, al fine di cogliere andamenti di domanda particolarmente complessi. Parallelamente, si prospetta un'evoluzione verso sistemi previsionali sempre più vicini al tempo reale, basati su aggiornamenti continui dei modelli in funzione delle nuove osservazioni.

In sintesi, l'utilizzo congiunto di variabili esterne, tecniche di clustering e modelli avanzati come XGBoost e LightGBM consente di ottenere stime più affidabili rispetto agli approcci tradizionali e di migliorare significativamente la capacità di pianificazione commerciale. L'accuratezza previsionale si traduce in ordini più correttamente dimensionati, scorte più efficienti, una riduzione delle rotture e delle eccedenze di magazzino e un migliore coordinamento lungo l'intera catena di approvvigionamento. In questa prospettiva, la previsione della domanda si configura come un elemento abilitante non solo per la gestione dell'inventario, ma anche per l'ottimizzazione complessiva delle operazioni e per il miglioramento dell'efficienza e della soddisfazione del cliente nel retail.

2.4.2 Applicazione del Machine Learning alla previsione della domanda giornaliera nel retail

L'applicazione del Machine Learning alla previsione della domanda giornaliera nel retail mostra in modo concreto come l'apprendimento automatico riesca a modellare scenari operativi caratterizzati da forte variabilità locale e picchi di domanda legati a giorni particolari. L'attenzione è rivolta ai giorni "speciali" di calendario, come festività

ed eventi locali, che generano andamenti di vendita atipici e difficili da descrivere con gli approcci tradizionali.

L'obiettivo operativo è ottenere previsioni giornaliere della domanda a livello di punto vendita e per diverse categorie di prodotto, in modo da supportare attività quotidiane quali produzione, approvvigionamento, distribuzione e gestione del personale. Il problema viene trattato come un compito di apprendimento supervisionato, confrontando diversi algoritmi, tra cui reti neurali artificiali (ANN), reti ricorrenti (LSTM) e alberi decisionali potenziati (GBRT), e introducendo la possibilità di riformulare la previsione come problema di classificazione anziché di regressione.

Il passaggio dalla regressione alla classificazione viene utilizzato per migliorare l'accuratezza soprattutto nei giorni con andamenti anomali. L'idea è di sostituire la stima diretta di una quantità continua con l'assegnazione della domanda prevista a classi discrete, ciascuna associata a un intervallo di valori. Tale formulazione consente di ottenere distribuzioni di probabilità sui diversi livelli di domanda, riducendo l'impatto degli errori estremi nelle situazioni più critiche, come i picchi di acquisto nelle festività.

La costruzione del modello segue una procedura strutturata: trasformazione delle serie temporali di vendita in insiemi di dati per l'addestramento, gestione del rischio di overfitting attraverso la separazione tra insiemi di training, validazione e test, e utilizzo di modelli "globali" in grado di apprendere pattern comuni da serie diverse. In questo contesto la feature engineering assume un ruolo centrale. Oltre ai dati storici di vendita vengono integrate variabili esogene quali informazioni di calendario (giorni festivi, vacanze scolastiche), metadati sui punti vendita (localizzazione, orari di apertura, tipologia) e fattori promozionali (ad esempio l'uso di coupon o iniziative commerciali locali).

L'evidenza empirica mostra che i modelli di Machine Learning superano gli approcci statistici tradizionali in termini di accuratezza, in particolare nella gestione dei giorni speciali. I modelli basati su classificazione e le combinazioni ibride risultano i più efficaci grazie alla capacità di fornire distribuzioni di probabilità più informative e di ridurre la frequenza di errori gravi. Questo si traduce in una migliore capacità di pianificazione della produzione e della logistica e in una riduzione degli sprechi e delle rotture di stock.

Un elemento conclusivo riguarda la gestione nel tempo di questi sistemi previsionali. È necessario monitorare periodicamente le prestazioni dei modelli e aggiornarli quando cambiano le condizioni strutturali della domanda, poiché non esiste un algoritmo universalmente superiore per tutti i contesti e per tutti gli orizzonti temporali. La previsione della domanda nel retail, soprattutto a livello giornaliero, richiede quindi non solo un modello accurato, ma anche una governance continua del modello stesso.

2.4.3 Previsioni di domanda per la gestione dello stock nel retail: approcci di Machine Learning

La gestione dello stock nel settore retail richiede previsioni della domanda affidabili al fine di prevenire sia le rotture di stock sia le eccedenze di magazzino, particolarmente critiche nelle categorie di prodotti deperibili. In questo contesto, il Machine Learning fornisce un contributo rilevante poiché consente di apprendere dai dati storici pattern complessi quali stagionalità, tendenze e irregolarità della domanda, permettendo una calibrazione più accurata delle decisioni di riordino rispetto agli approcci tradizionali.

Un'applicazione empirica nel contesto della vendita al dettaglio ha analizzato scontrini giornalieri provenienti da 90 supermercati francesi nel periodo 2017–2022, concentrandosi su 150 articoli appartenenti alle categorie dei latticini e dei prodotti ittici. Il processo metodologico adottato ha previsto una fase di raccolta e pulizia dei dati, la costruzione di variabili temporali e di prodotto, come indicatori di stagionalità e ciclicità, il confronto tra diverse famiglie di modelli e una valutazione delle prestazioni condotta nel rispetto dell'ordine temporale. Ogni previsione è stata stimata utilizzando esclusivamente le informazioni disponibili fino al momento considerato, secondo la logica del forward chaining, al fine di riprodurre in modo fedele il contesto decisionale reale.

Nel confronto tra algoritmi sono stati considerati modelli basati su alberi decisionali, come XGBoost, e modelli di deep learning per serie temporali, tra cui LSTM, Transformer e loro varianti quali Informer e Autoformer. I modelli fondati su meccanismi di attenzione e sulla scomposizione della serie nel tempo, in particolare Autoformer, hanno evidenziato una maggiore stabilità nell'identificazione dei profili stagionali e dei cicli della domanda. I Transformer hanno frequentemente registrato gli scostamenti medi

più contenuti tra vendite previste e osservate, caratteristica rilevante quando l'obiettivo operativo è la riduzione dell'errore medio. XGBoost si è dimostrato particolarmente robusto su orizzonti previsivi più lunghi e tende a superare le prestazioni dei modelli LSTM nei casi in cui trend e stagionalità si combinano con un elevato livello di rumore nei dati; al contrario, LSTM risulta più sensibile a tali condizioni e richiede un pre-processing accurato per esprimere prestazioni soddisfacenti.

Dal punto di vista gestionale, una maggiore affidabilità delle previsioni si traduce in ordini più correttamente dimensionati, in una riduzione delle eccedenze e delle rotture di stock e in un minore ricorso a promozioni di tipo "anti-spreco", con effetti positivi sul livello di servizio e sulla redditività complessiva. Tuttavia, la scelta del modello non può essere uniforme per tutti i contesti, ma deve essere adattata alla specifica categoria merceologica, all'orizzonte di pianificazione e alle priorità di business, quali la minimizzazione dello scostamento medio, la riduzione degli errori estremi o la massima stabilità delle previsioni nel tempo.

Per garantire la sostenibilità dei benefici nel lungo periodo è necessario definire una governance del ciclo di vita dei modelli, che includa il monitoraggio periodico delle prestazioni, il riaddestramento in presenza di cambiamenti nelle condizioni di mercato e controlli continui sulla qualità dei dati. Questo approccio consente di preservare l'affidabilità delle previsioni anche in presenza di variazioni della stagionalità, cambiamenti nel mix di prodotti o shock esterni.

L'adozione di una pipeline strutturata, la valutazione comparativa di modelli differenti e l'utilizzo congiunto di segnali informativi interni ed esterni permettono di superare una logica di riordino puramente reattiva, favorendo strategie proattive basate sui dati. In questa prospettiva, la previsione della domanda assume il ruolo di elemento abilitante per una gestione coordinata delle scorte, dell'assortimento, della disponibilità a punto vendita e della pianificazione operativa lungo l'intera catena del valore dello stock nel retail.

CAPITOLO III: Il caso studio Carrefour Italia

Il precedente capitolo ha evidenziato come il Machine Learning influenzi particolarmente le decisioni aziendali e strategiche negli ambiti di pricing, segmentazione della clientela e previsione della domanda, evidenziando come la creazione di valore passi anche attraverso l'utilizzo di queste nuove tecnologie, adottando decisioni sempre più data driven.

Il presente capitolo propone un approfondimento empirico attraverso l'analisi del caso di studio di Carrefour Italia, con l'obiettivo di esaminare come le soluzioni di Machine Learning si applichino in un contesto aziendale strutturato.

Il focus è posto sul suo utilizzo per la segmentazione della clientela e la previsione della domanda, con lo scopo di analizzare le modalità di implementazione della tecnologia in azienda, le motivazioni di business e aziendali alla base di questa scelta, così come i benefici e le sfide che ne conseguono. L'obiettivo è quello di offrire una chiave applicativa che consenta di collegare la letteratura con la pratica manageriale.

3.1: Evoluzione storica del Gruppo Carrefour

Il Gruppo Carrefour nasce nel 1959 dall'incontro tra Marcel Fournier, commerciante attivo ad Annecy, e la famiglia Badin-Defforey, operante nel settore dell'ingrosso alimentare a Lagnieu. Questa collaborazione dà avvio a un progetto imprenditoriale orientato all'innovazione dei modelli distributivi e alla sperimentazione di nuove formule commerciali nel panorama francese.

Dopo una prima fase sperimentale basata sul principio del self-service, nel 1960 viene inaugurato ad Annecy il primo supermercato Carrefour. Il processo di innovazione prosegue con l'apertura, il 15 giugno 1963, del primo ipermercato francese a Sainte-Geneviève-des-Bois, caratterizzato da una superficie di vendita di 2.500 m², un ampio assortimento, prezzi competitivi e 400 posti auto gratuiti. Tale iniziativa rappresenta un momento di svolta per la grande distribuzione organizzata in Francia. Pochi anni dopo, in occasione dell'apertura dell'ipermercato di Vénissieux, viene ideato il logo aziendale, destinato a divenire uno degli elementi più riconoscibili dell'identità del Gruppo. Nel 1970 Carrefour viene quotata alla Euronext Paris, segnando un passaggio significativo per il settore della distribuzione al dettaglio.

A partire dagli anni Settanta, l'azienda avvia un progressivo processo di ridefinizione dell'offerta commerciale. Nel 1976 introduce i cosiddetti "prodotti liberi", caratterizzati da confezioni essenziali e da un posizionamento di prezzo inferiore rispetto alle marche nazionali, mantenendo al contempo standard qualitativi comparabili. Questa strategia viene affiancata, nel 1981, dal lancio della carta PASS, che integra funzioni di pagamento e fidelizzazione e registra un'ampia adesione nei primi anni di diffusione.

Nel corso degli anni Novanta Carrefour rafforza il proprio impegno in materia di qualità e sicurezza alimentare, introducendo nel 1992 le Linee Qualità e i primi prodotti biologici a marchio proprio. Parallelamente prende avvio una fase di espansione internazionale, con l'apertura dei primi punti vendita in Italia nel 1993, in Cina nel 1995 e in Polonia nel 1997. In questo stesso periodo il Gruppo avvia collaborazioni con i Banchi Alimentari per contribuire alla riduzione dello spreco e al sostegno delle persone in condizioni di vulnerabilità e amplia la propria offerta con il marchio Reflets de France, dedicato alla valorizzazione delle tradizioni gastronomiche regionali.

Un momento di particolare rilievo si verifica nel 1999 con la fusione con Promodès, operazione che consente al nuovo gruppo di posizionarsi come secondo operatore mondiale della distribuzione, con circa 240.000 dipendenti e 9.000 punti vendita. L'anno successivo viene lanciato il supermercato online Ooshop, a testimonianza dell'attenzione del Gruppo verso le potenzialità emergenti del commercio elettronico, mentre nel 2001 viene aperto il primo punto vendita in Romania.

Nei primi anni duemila Carrefour consolida ulteriormente la propria presenza internazionale attraverso acquisizioni mirate in diversi Paesi. In tale contesto, nel 2005 il Gruppo acquisisce in Italia le attività di GS, rafforzando in modo significativo il proprio radicamento nel mercato nazionale. Contestualmente, vengono effettuate operazioni analoghe in Francia, Romania, Belgio, Polonia, Brasile, Argentina e Spagna, delineando una strategia di crescita per le linee esterne finalizzata al consolidamento delle posizioni competitive.

Nel 2008 viene avviato un ampio programma di rinnovamento della rete distributiva, volto a uniformare l'identità dei punti vendita: il marchio Champion viene progressivamente sostituito da Carrefour Market e numerosi negozi vengono ristrutturati e integrati nel programma di fidelizzazione del Gruppo. Nel 2013, in occasione del cinquantesimo anniversario del primo ipermercato, Carrefour avvia un piano di modernizzazione delle strutture in Francia e intraprende una collaborazione con CFAO per lo sviluppo di diversi formati di distribuzione in Africa occidentale e centrale. L'anno successivo viene costituita Carmila, società specializzata nella gestione e valorizzazione dei centri commerciali adiacenti agli ipermercati in Francia, Spagna e Italia; nello stesso periodo il Gruppo acquisisce in Francia i punti vendita Dia e integra 128 negozi Coop Alsace.

Il percorso di trasformazione prosegue nel 2016 con il rafforzamento della strategia digitale attraverso l'acquisizione di Rue du Commerce e di Greenweez, oltre al lancio di nuove attività online in diversi mercati e ad ulteriori acquisizioni in Romania e in Spagna. Nel 2018 viene presentato il piano di trasformazione "Carrefour 2022", che pone la transizione alimentare al centro delle priorità strategiche del Gruppo, accompagnato dal programma "Act for Food" e dall'introduzione della tecnologia blockchain per la tracciabilità di specifiche linee di prodotto.

Nel 2019, anno del sessantesimo anniversario dalla fondazione, Carrefour inserisce nei propri Statuti una dichiarazione di missione, formalizzando l'obiettivo di affermarsi come leader della transizione alimentare. Nello stesso periodo il Gruppo procede alla cessione delle proprie attività in Cina, in coerenza con il percorso di riorientamento strategico intrapreso.

Nel dicembre 2025 si perfeziona il closing dell'operazione che determina la separazione di Carrefour Italia dal Carrefour Group. A seguito di tale operazione, l'intera realtà di Carrefour Italia viene acquisita dal gruppo New Princes, segnando una discontinuità nella struttura proprietaria e organizzativa della country rispetto al Gruppo internazionale.



3.2: Visione tecnologica del Gruppo Carrefour

La visione tecnologica del Gruppo Carrefour si fonda sugli asset sviluppati a seguito della profonda trasformazione avviata nel 2018 e si articola attorno a un approccio *data-centric, digital first*, che colloca il digitale e l'utilizzo sistematico dei dati al centro del modello operativo e dei processi di creazione del valore.

“Con la conclusione del primo piano di trasformazione, che ha riscosso grande successo, vogliamo ora trasformare Carrefour, un retailer tradizionale con competenze nell'e-commerce, in una Digital Retail Company, che pone il digitale e i dati al centro di tutte le sue operazioni e del suo modello di creazione di valore. Questo profondo cambiamento, che intendiamo realizzare entro il 2026, libererà tutto il potenziale dell'omnicanalità, che oggi è il DNA di Carrefour e una risorsa unica nel settore. “
(Alexandre Bompard, Presidente e CEO)

All'interno di questo percorso, Carrefour si propone di triplicare il Gross Merchandise Value dell'e-commerce entro il 2026, raggiungendo i 10 miliardi di euro, e prevede che il digitale contribuirà con ulteriori 600 milioni di euro al risultato operativo ricorrente rispetto ai livelli del 2021. Per sostenere tali obiettivi, il Gruppo ha pianificato un incremento di circa il 50% degli investimenti digitali, attraverso un piano dedicato di 3 miliardi di euro nel periodo 2022–2026, che porta l'impegno annuo complessivo a circa 1,7 miliardi di euro. In parallelo, in coerenza con le proprie politiche di responsabilità sociale e ambientale, Carrefour ha annunciato l'obiettivo di raggiungere la neutralità carbonica delle attività e-commerce entro il 2030, anticipando di dieci anni il traguardo complessivo fissato per il Gruppo.

La strategia digitale si sviluppa lungo quattro direttrici principali. La prima riguarda l'accelerazione dell'e-commerce, con l'intento di consolidare la leadership nei formati a più elevato tasso di crescita, quali la consegna express e il *quick commerce*, anche attraverso partnership con operatori specializzati come Uber Eats. A ciò si affiancano lo sviluppo del segmento B2B, sostenuto dal potenziale di Atacadão in Brasile, e l'espansione dell'offerta non alimentare attraverso marketplace, social commerce e live shopping.

La seconda direttrice riguarda il rafforzamento delle attività di Data & Retail Media, ambito in cui Carrefour ambisce a posizionarsi come leader europeo. In questo contesto,

la piattaforma Carrefour Links consente ai partner industriali di attivare campagne di marketing su tutti gli asset del Gruppo (siti web, applicazioni e punti vendita) e di misurarne l'impatto lungo l'intera catena del valore, dalla visibilità alle transazioni di vendita. Tale modello si basa sull'impiego di dati proprietari caratterizzati da elevato volume e qualità, raccolti in un data lake unico alimentato in tempo reale dalle transazioni fisiche e digitali e dalle informazioni provenienti dai servizi finanziari. L'ecosistema è ulteriormente rafforzato da collaborazioni con leader tecnologici globali quali Criteo, Google e LiveRamp. Il Gruppo prevede che questa attività genererà un incremento del risultato operativo pari a 200 milioni di euro nel 2026 rispetto al 2021.

Una terza area di intervento riguarda la digitalizzazione dei servizi finanziari. Carrefour ha costruito una presenza significativa in questo ambito attraverso cinque istituti bancari e diversi accordi commerciali. In particolare, la banca del Gruppo in Brasile opera come centro di competenza per l'innovazione, consentendo lo sviluppo di nuovi prodotti e servizi finanziari e assicurativi per clienti B2C e B2B. L'integrazione dei dati dei clienti e la digitalizzazione dei processi permettono inoltre di ottimizzare le attività operative, migliorare le pratiche di concessione del credito, potenziare i sistemi di scoring e gestire in modo più efficiente il costo del rischio.

La quarta direttrice è rappresentata dalla trasformazione profonda delle attività retail tradizionali attraverso il digitale. Dal 2018 Carrefour ha avviato un processo di migrazione dei sistemi informativi verso il Cloud, con l'obiettivo di diventare un'organizzazione interamente cloud-based entro il 2026. Questa evoluzione consente di aumentare l'agilità dei sistemi, ridurre i tempi di sviluppo di nuovi servizi e applicazioni e valorizzare i dati operativi attraverso soluzioni di intelligenza artificiale. L'adozione di una cultura *data-centric* è destinata a incidere in modo significativo su processi chiave quali la definizione dei prezzi, la gestione degli assortimenti, le previsioni di attività, la logistica, i flussi di approvvigionamento e le procedure amministrative, contribuendo al miglioramento dell'esperienza del cliente e dell'efficienza operativa sia a livello centrale sia nei punti vendita.

A supporto dell'attuazione della strategia digitale, il Gruppo mobilita risorse umane e finanziarie su larga scala. Entro il 2024, tutti i dipendenti saranno coinvolti in programmi di formazione digitale tramite la Digital Retail University, sviluppata in

collaborazione con Google. Parallelamente, per favorire la comunicazione interna e sostenere l'innovazione, Carrefour adotta la piattaforma Workplace di Meta Platforms. Tali iniziative sono integrate in un ecosistema di open innovation che comprende un fondo di venture capital dedicato, uno studio di innovazione e un piano di investimenti digitali da 3 miliardi di euro nel periodo 2022–2026. In questo quadro si colloca il lancio, nel 2022, del fondo Dastore, realizzato in partnership con Daphni, con una dotazione iniziale di 80 milioni di euro destinati a partecipazioni di minoranza in startup early stage attive nel digital retail. Oltre al sostegno finanziario, Carrefour mette a disposizione competenze operative, accesso ai mercati internazionali e dati utili alla crescita delle imprese coinvolte.

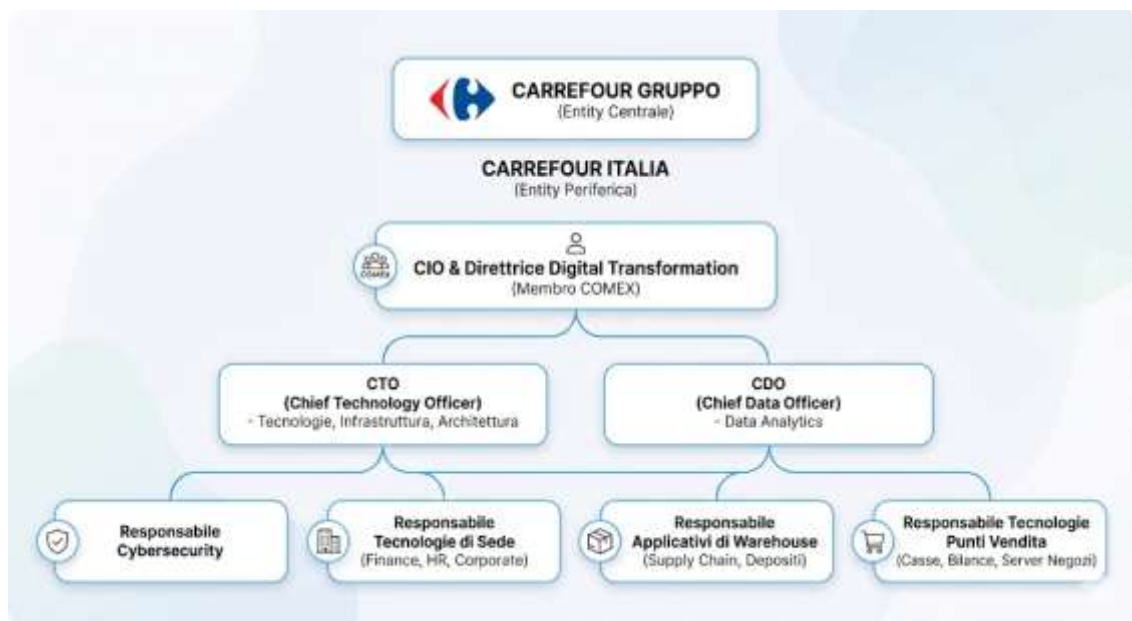
La strategia tecnologica del Gruppo si inserisce infine in un più ampio quadro di responsabilità sociale e ambientale. In tale prospettiva, Carrefour ha definito l'obiettivo di rendere neutrali in termini di emissioni di CO₂ le proprie attività e-commerce entro il 2030, impegnandosi a neutralizzare l'impatto ambientale dell'intero processo di acquisto, dalla fase di ordine online fino alla consegna finale.

3.2.1 Struttura IT Italia

L'area IT di Carrefour Italia si colloca all'interno del contesto organizzativo più ampio del Carrefour Group. In tale modello, il Gruppo rappresenta l'entità centrale, mentre le singole country costituiscono le entità periferiche, corrispondenti ai diversi Paesi in cui il Gruppo opera. Ciascuna entità nazionale è responsabile del proprio perimetro operativo, mentre il Gruppo svolge un ruolo di coordinamento, senza imporre obiettivi di business o tecnologici. La funzione centrale si limita a definire linee guida e best practice, con l'obiettivo di favorire economie di scala, creare sinergie e promuovere la condivisione di soluzioni e idee replicabili in altri contesti nazionali.

Con riferimento specifico al caso italiano, l'organizzazione del reparto IT è strutturata come segue: è presente una Chief Information Officer, che ricopre anche il ruolo di Direttrice della Digital Transformation; un Chief Technology Officer, con responsabilità trasversali su tutte le funzioni aziendali e incaricato della gestione delle tecnologie, dell'infrastruttura e dell'architettura complessiva; una Chief Data Officer, responsabile dell'ambito di data analytics, anch'esso trasversale all'intera organizzazione.

Sono inoltre individuate tre figure responsabili delle diverse aree tecnologiche: una dedicata alle tecnologie di sede, che comprende gli applicativi utilizzati dalle funzioni Finance (AFC), HR e Corporate; una responsabile degli applicativi di warehouse, relativi ai depositi e ai processi di approvvigionamento e supply chain; e una focalizzata sulle tecnologie e soluzioni dei punti vendita, che includono sistemi di cassa, bilance e server installati nei negozi. Completa l'organigramma una responsabile della cybersecurity.



L'ecosistema tecnologico attualmente in uso si fonda su una data platform centralizzata, sviluppata progressivamente nel tempo, che svolge il ruolo di data hub. Tale piattaforma raccoglie i dati provenienti da tutti gli applicativi aziendali inclusi quelli relativi ai punti vendita, ai warehouse e alle funzioni di sede, i quali generano e utilizzano informazioni in modo intrinseco nei rispettivi processi operativi.

La data platform ha il compito di aggregare queste informazioni, organizzarle e normalizzarle. Essa rappresenta una delle componenti fondative per l'implementazione degli use case basati sui dati. Su questa infrastruttura vengono costruite le diverse soluzioni data driven, che spaziano dalla business intelligence e dalla reportistica operativa, ai modelli di machine learning, fino alle iniziative di data monetization e ad altre applicazioni affini.

Attualmente le principali applicazioni riguardano la BI e la reportistica operativa. Gli ambiti più innovativi sono invece rappresentati dal machine learning e

dall'intelligenza artificiale, per i quali sono stati sviluppati diversi proof of concept e use case altamente mirati; tuttavia, tali soluzioni non presentano ancora un livello di diffusione paragonabile a quello delle piattaforme di BI già consolidate.

3.2.2 Il ruolo del Machine Learning in Carrefour Italia

Il Machine Learning risulta essere una delle tecnologie chiave utilizzate da Carrefour Italia nel percorso di trasformazione digitale. Il suo impiego si concentra su due tra gli ambiti strategici trattati nei capitoli precedenti: la segmentazione della clientela e la previsione della domanda. L'uso del Machine Learning risulta essere cruciale, per poter andare a prendere decisioni strategiche e operative sempre più data driven.

È importante sottolineare come le tecnologie, quindi anche il Machine Learning, si inseriscano in un contesto aziendale molto maturo ed avanzato dal punto di vista digitale come quello di Carrefour Italia. Il Machine Learning è quindi uno strumento integrato all'interno dell'azienda e dei suoi processi.

Aspetto fondamentale è la logica che guida i processi di utilizzo dell'Intelligenza Artificiale all'interno di Carrefour Italia. Non è la tecnologia a guidare le scelte aziendali, bensì il contrario: si parte dall'identificazione di un problema reale o di un'opportunità di miglioramento e solo successivamente si individua la soluzione tecnologica più adatta per raggiungere il risultato desiderato. La domanda fondamentale da porsi è quindi: "Qual è il problema di business che vogliamo risolvere e quale tecnologia può aiutarci a farlo in modo efficace?". Nel contesto attuale la chiave di lettura è quindi trovare il fit corretto tra tecnologia ed azienda, per poter trovare le soluzioni migliori sfruttando la tecnologia più adatta.

3.3 La segmentazione della clientela in Carrefour Italia

L'utilizzo del machine learning per la segmentazione della clientela si colloca nel contesto operativo del team CRM (Customer Relationship Management), che gestisce una base dati di dimensioni molto rilevanti. Le principali fonti informative derivano dalle carte Payback, che permette di accumulare punti per ogni spesa effettuata sia in punto vendita che sul sito e-commerce, e dal programma di fidelizzazione, attraverso le quali vengono raccolti dati transazionali dettagliati. Per ciascun cliente, e per il relativo nucleo familiare associato alla medesima utenza, è disponibile lo storico completo degli acquisti e delle transazioni.

L'esigenza di business che ha motivato l'adozione del machine learning riguarda principalmente il miglioramento della comprensione del comportamento dei clienti, per implementare strategie più mirate ed efficaci. L'obiettivo è la creazione di offerte promozionali personalizzate per segmenti di clientela molto ristretti, che possono includere non solo sconti diretti sul prezzo, ma anche bundle, meccanismi del tipo "compra tre, paghi due" e iniziative analoghe, erogate attraverso canali e tempistiche differenziate in base ai diversi gruppi di clientela.

L'introduzione di tali modalità richiede analisi estremamente approfondite, caratterizzate da un numero elevato di variabili (feature). Rispetto alle tecniche di segmentazione più tradizionali, quali RFM o il valore medio del cliente, l'approccio basato su Machine Learning consente di considerare un insieme molto più ampio di fattori e utilizzare una base dati molto più estesa, elementi che portano a risultati molto più affidabili. La motivazione principale dell'adozione di questi modelli risiede quindi nella possibilità di integrare un maggior numero di feature, permettendo la definizione di strategie promozionali altamente mirate su volumi elevati di clienti.

La finalità complessiva è la creazione di offerte coerenti con le esigenze evolutive del singolo utente o del gruppo di utenti associati, massimizzando l'efficacia delle promozioni, sempre in un'ottica sostenibile sul piano di costi benefici.

Concetti consolidati quali RFM e Customer Lifetime Value rimangono pienamente validi e vengono utilizzati come base informativa all'interno dei modelli di segmentazione basati sul Machine Learning. Tali indicatori non sono superati, ma

rappresentano la base di partenza su cui fondare e allenare il modello di Machine Learning.

La segmentazione ottenuta non opera a livello di singolo individuo (hyper-personalization), bensì su gruppi di clienti molto piccoli e specifici. Sebbene esistano sul mercato soluzioni orientate alla personalizzazione individuale, tale approccio non è attualmente adottato, in quanto non sostenibile rispetto al modello di business. Una personalizzazione eccessivamente sofisticata comporterebbe infatti un disequilibrio tra costi e benefici.

I costi associati includono non solo quelli computazionali legati all'esecuzione dei job e al retraining dei modelli, ma anche i costi di sviluppo tecnologico, i costi operativi, legati alla gestione e alla comunicazione interna ed esterna di livelli estremamente granulari di targetizzazione, e costi di tempo. Si tratta pertanto di costi distribuiti sull'intera catena del valore, non esclusivamente di natura tecnica.

Per quanto riguarda l'aggiornamento dei modelli, la frequenza di retraining non è elevata. Tale scelta è guidata da una valutazione costo-beneficio: sebbene la segmentazione sia dinamica, il mercato e la base clienti non presentano una volatilità tale da giustificare riaddestramenti molto frequenti (ad esempio trimestrali o settimanali). Pur esistendo una componente di stagionalità, le fondamenta della customer base rimangono sostanzialmente stabili nel tempo. Di conseguenza, i modelli non sono statici, ma neppure aggiornati con cadenza ravvicinata, poiché ciò non genererebbe un valore aggiunto significativo.

Le strategie di marketing sono guidate dai risultati della segmentazione e non si limitano alla scontistica. Oltre agli sconti sul prezzo, vengono impiegati coupon dedicati e forme di comunicazione targettizzata, differenziate per canale, frequenza e tempistiche. Tali leve vengono modulate in funzione dei diversi segmenti di clientela, sebbene il dettaglio delle differenze operative tra un segmento e l'altro non sia esplicitato.

L'adozione del machine learning ha inoltre consentito di individuare gruppi di utenti specifici, in precedenza non identificabili con approcci tradizionali. Per ciascuno di questi gruppi vengono attivate leve di marketing differenziate, contribuendo a decisioni operative che non sarebbero state possibili senza l'impiego di tali tecnologie.

L'efficacia delle azioni intraprese, in particolare delle iniziative di marketing, viene valutata attraverso il concetto di incrementalità, ossia misurando i risultati delle campagne in termini di incremento delle vendite rispetto ai volumi attesi. In questo contesto, l'incrementalità rappresenta il numero di vendite aggiuntive generate dall'intervento promozionale, con una particolare attenzione metodologica all'esclusione dei clienti che avrebbero effettuato l'acquisto indipendentemente dalla campagna.

Tale approccio costituisce una metodologia standard nell'analisi delle performance di marketing, finalizzata a isolare l'effettivo contributo delle azioni adottate. Al fine di ottimizzare le strategie future, i risultati osservati vengono analizzati in modo sistematico per estrarre learning rilevanti. In presenza di segmenti di clientela o periodi temporali analoghi, tali evidenze vengono utilizzate per formulare assunzioni e ipotesi operative, che vengono successivamente testate nelle campagne successive, in un processo iterativo basato sull'apprendimento dai risultati precedenti.

L'uso del Machine Learning ha permesso quindi una segmentazione più capillare e articolata della clientela, supportando strategie promozionali mirate, tenendo sempre in considerazione quelli che sono i costi benefici.

3.3.1 Segmentazione comportamentale, KPI e leve di marketing

La segmentazione attraverso il Machine Learning si pone l'obiettivo di trovare cluster di clienti che prima era molto difficile individuare; una delle segmentazioni che ha avuto il maggior successo, nel contesto di Carrefour Italia, è stata quella basata sui profili comportamentali legati ai bisogni dei clienti, che ha permesso di individuare dei gruppi di clientela, più o meno ampi, basati sulla categoria di prodotti che questi ultimi acquistano.

In questo ambito vengono ad essere individuate specifiche categorie di clienti:

- clienti family, caratterizzati da un'elevata spesa in prodotti per l'infanzia
- clienti specializzati, interessati a categorie molto specifiche come ad esempio i prodotti BIO
- clienti etnici, con spesa su categorie di prodotto etniche.

Questo tipo di segmentazione viene ad essere integrata con variabili comportamentali, con l'obiettivo di qualificare il valore del cliente, tra cui la frequenza d'acquisto e il CLV (customer lifetime value).

Le azioni di marketing sono il fine ultimo del processo di segmentazione della clientela. Con l'individuazione di gruppi di clienti in base alla categoria di prodotti acquistati, le azioni di marketing si incentrano su questo aspetto. Vengono ad essere inserite azioni quali coupon e offerte di sconto sui prodotti che il cluster di clienti acquista maggiormente, ovvero prodotti per bambini per il gruppo family, prodotti BIO per i clienti specializzati e prodotti etnici per il gruppo di clienti interessato a questa categoria.

Queste azioni vengono poi ad essere integrate con programmi loyalty, ossia programmi dedicati con meccanismi premianti come ad esempio l'attribuzione di punti fedeltà aggiuntivi, per accedere a premi esclusivi, e attività di comunicazione mirata, sempre specifica per il segmento individuato, con frequenza e canale ottimizzate in base al comportamento del cliente (email, sms, app, coupon digitali e fisici). Gli obiettivi principali che si vogliono raggiungere sono aumentare la retention, incrementare il valore medio dello scontrino e aumentare la frequenza d'acquisto.

La valutazione delle performance avviene attraverso l'utilizzo di KPI specifici, che vanno a misurare sia l'efficacia della segmentazione comportamentale, sia l'efficacia delle azioni di marketing ad essa connessa. Alcuni dei KPI più importanti che vengono ad essere utilizzati sono l'incremento delle vendite, la variazione del margine medio, la variazione del valore medio dello scontrino, il margine medio, il valore medio dello scontrino e il tasso di redemption.

3.3.2 Il caso Carrefour Italia rispetto alla letteratura

Analizzando quanto emerso dalle interviste, si possono effettuare alcune riflessioni importanti sui risvolti pratici dell'adozione del Machine Learning, in relazione a quanto evidenziato sul piano teorico nei capitoli precedenti.

Nel contesto di Carrefour Italia, il Machine Learning risulta la tecnologia più adatta a rispondere alle esigenze di business legate alla segmentazione della clientela. La tecnologia consente di individuare gruppi di clienti altamente omogenei e di dimensioni ridotte, superando i limiti della segmentazione tradizionale.

Questo porta alla creazione di strategie di marketing molto mirate e differenziate, per soddisfare e rispondere a tutte le esigenze di ogni gruppo di clienti individuato. Il risultato è quello di una personalizzazione molto elevata, che tuttavia non viene spinta a livello del singolo individuo, non per limiti tecnologici ma per uno sbilanciamento dei costi benefici.

Sebbene la letteratura evidenzi come la base clienti non debba essere considerata come un'entità statica ma dinamica, emerge come nel contesto in cui opera Carrefour Italia questa distinzione non sia del tutto rilevante. La base cliente con cui opera l'azienda, infatti risulta essere abbastanza stabile nel tempo, non giustificando un retrain del modello con periodicità molto ravvicinate, poiché la volatilità dei cluster risulta essere molto bassa.

I dati assumono un ruolo centrale all'interno dell'intero processo. I cluster vengono creati a partire dalle informazioni recuperate attraverso la carta fedeltà (carta Payback), mentre metriche fondamentali come RFM e Customer Lifetime Value si confermano essere alla base per l'addestramento del modello di Machine Learning, consentendo di individuare clienti con pattern comportamentali d'acquisto simili. La disponibilità di grandi volumi di dati risulta essere un fattore abilitante, rendendo Carrefour Italia un'azienda particolarmente adatta all'adozione del Machine Learning.

Dal punto di vista metodologico, si evince che i passaggi da seguire debbano essere sequenziali e strutturati. In primo luogo, è essenziale individuare un problema di business (in questo caso, la segmentazione della clientela) e, successivamente, la tecnologia più adatta per risolverlo. La preparazione della base dati su cui lavorare è fondamentale, un'operazione possibile grazie alla data platform aziendale, che consente la pulizia e la normalizzazione di tutte le informazioni raccolte. Solo in seguito è possibile procedere alla selezione del modello di Machine Learning più adatto, i cui output portano all'elaborazione di decisioni strategiche data driven, orientate alla definizione di promozioni e offerte personalizzate volte al miglioramento della customer experience.

Quello che emerge è come il Machine Learning non risulti essere una tecnologia universale, ma uno strumento abilitante che richiede un forte allineamento con gli obiettivi di business e con il livello di maturità dell'azienda. In contesti caratterizzati da un'elevata disponibilità di dati e da una solida base tecnologica, come nel caso di

Carrefour Italia, il Machine Learning diventa una leva strategica per una comprensione più profonda del cliente e una personalizzazione efficace dell'offerta.

3.4 La previsione della domanda in Carrefour Italia

La previsione della domanda svolge un ruolo centrale nei processi operativi aziendali, in particolare nelle attività di riordino a livello di punto vendita e, di conseguenza, nell'approvvigionamento e nella gestione dello stock lungo l'intera filiera, inclusi i magazzini. L'intero processo inizia dalla stima della domanda del cliente finale, costruita prevalentemente a partire dallo storico delle vendite.

Per la maggior parte delle categorie merceologiche vengono adottati modelli previsionali relativamente standard. Tuttavia, le principali criticità emergono nell'ambito dei prodotti freschi, in particolare nell'ortofrutta, caratterizzati da una maggiore rotazione, da una shelf life significativamente più breve, da una forte stagionalità e da una marcata variabilità della supply. Queste caratteristiche rendono la previsione della domanda e la gestione del riordino decisamente più complesse rispetto ai prodotti a lunga conservazione, come lo scatolame.

Poiché lo stock dei magazzini è direttamente correlato a quello dei punti vendita, le difficoltà non si manifestano tanto nel confronto tra magazzino e negozio, quanto piuttosto tra le diverse categorie di prodotto, con l'ortofrutta che rappresenta il contesto più sfidante anche a causa della non standardizzazione degli articoli.

I modelli previsionali integrano diverse variabili, tra cui elementi di calendario (come festività rilevanti quali Natale e Pasqua), promozioni e prezzo. Sono stati inoltre condotti test per includere fattori meteorologici, come la temperatura esterna, al fine di valutare il loro impatto sulle vendite estive di frutta e verdura; tuttavia, tali feature non hanno prodotto miglioramenti significativi nell'accuratezza delle previsioni e non sono state quindi incorporate stabilmente nei modelli di machine learning.

La qualità dei dati rappresenta un fattore abilitante fondamentale. Pur riconoscendo che, nel contesto operativo, non sempre è possibile disporre di dataset completi, è considerato essenziale lavorare su dati rappresentativi. In questo quadro, la fase di data preparation assume un ruolo centrale: in presenza di lacune informative, è necessario

definire strategie adeguate per simulare e colmare i gap in modo coerente, garantendo la robustezza e l'accuratezza delle analisi.

I picchi di domanda legati a eventi speciali, festività e stagionalità sono parte integrante del funzionamento dei punti vendita, la cui operatività è strutturata per assorbire tali variazioni. La principale sfida tecnologica consiste nel rappresentare questi picchi in modo affidabile all'interno dei modelli previsionali. In assenza di una sufficiente profondità storica o di feature adeguate, tali eventi tendono a essere sistematicamente sovra o sottostimati. Per ottenere stime più accurate è pertanto necessario disporre di una profondità storica significativa, attualmente pari ad almeno tre anni, a partire dalla costruzione della data platform aziendale, oppure di un insieme di variabili in grado di correlarsi efficacemente con tali fenomeni.

Le differenze tra i modelli applicati allo scatolame e quelli utilizzati per i freschi riflettono principalmente la diversa variabilità della domanda. I prodotti confezionati presentano volumi più stabili e facilmente prevedibili, oltre a una shelf life più lunga; di conseguenza, gli effetti di situazioni di out-of-stock o di overorder si manifestano con meno frequenza. Al contrario, nei freschi, qualsiasi carenza di prodotto si traduce immediatamente in perdite di vendite, mentre un eccesso di riordino genera rapidamente sprechi. Per questo motivo, nello scatolame è possibile adottare modelli più tradizionali, basati principalmente sulle vendite medie, mentre nei freschi si ricorre a modelli più avanzati che integrano feature aggiuntive per catturare la maggiore variabilità della domanda. In particolare, nel comparto ortofrutticolo assumono un ruolo rilevante fattori esterni quali stagionalità, meteo, prezzi e promozioni, e ogni variabile rappresentativa contribuisce a migliorare la capacità del modello di replicare il comportamento reale delle vendite.

I maggiori benefici derivanti dall'utilizzo del machine learning sono stati riscontrati proprio nell'ortofrutta e nel reparto freschi, sebbene con risultati eterogenei anche all'interno di queste categorie. Per i prodotti di nicchia, caratterizzati da volumi ridotti e picchi concentrati in brevi periodi, i modelli non hanno raggiunto un livello di affidabilità sufficiente. Le performance migliori sono invece emerse per i prodotti con volumi più elevati e dati storici più consistenti.

L'obiettivo iniziale prevedeva l'introduzione del riordino automatico per le categorie a maggiore volume; tale traguardo, tuttavia, non è stato pienamente raggiunto, non per limiti tecnologici, ma per ragioni legate al change management e all'adattamento delle operazioni. È emerso infatti un certo scetticismo nell'adozione completa di metodologie automatizzate. Attualmente vengono quindi fornite raccomandazioni di riordino che, in alcuni casi, richiedono semplicemente un'approvazione da parte degli operatori, senza arrivare a una piena automazione del processo.

I benefici concreti includono una maggiore precisione nelle quantità ordinate, con una riduzione sia degli sprechi sia delle perdite di venduto, oltre a una semplificazione operativa del riordino: rispetto al passato, in cui era necessario inserire manualmente tutte le quantità, le raccomandazioni consentono di ridurre significativamente il carico operativo. Le categorie che hanno tratto il maggiore vantaggio sono quelle ad alto volume, mentre l'analisi è stata condotta principalmente su punti vendita di grandi dimensioni (ipermercati e market), escludendo i formati express.

L'introduzione del Machine Learning per prevedere la domanda impatta anche sull'organizzazione e sull'operatività dei punti vendita; nel caso di Carrefour Italia, un progetto si è basato sull'utilizzo di tale tecnologia con l'obiettivo di ridurre il tempo destinato alle attività di riordino, senza tuttavia generare un impatto negativo sullo scontrino, garantendo quindi che le vendite continuassero a seguire il loro normale andamento.

L'efficacia dei modelli di Machine Learning nella previsione della domanda viene valutata attraverso indicatori di affidabilità, in particolare tramite il calcolo dell'errore medio ponderato tra il venduto previsto e il venduto effettivo, misurato ex post per stimare la precisione delle previsioni.

3.4.1 Il caso Carrefour Italia rispetto alla letteratura

Quanto emerso dalle interviste il caso Carrefour Italia conferma quanto evidenziato nella sezione dedicata alla teoria, mostrando come l'utilizzo del Machine Learning per prevedere la domanda porti a importanti benefici misurabili per le aziende operanti nel retail.

Viene ad essere confermato come l'utilizzo del Machine Learning impatti direttamente in maniera positiva per quanto riguarda l'aspetto della gestione delle scorte, sulla pianificazione della supply chain e sulla riduzione degli sprechi. L'accuratezza delle previsioni consente infatti di bilanciare in modo più efficace disponibilità dei prodotti e livelli di stock, riducendo sia il rischio di rotture di assortimento sia l'eccesso di inventario.

Il caso di studio conferma quanto emerso durante l'analisi della letteratura. La previsione della domanda si fonda su uno schema base ben delineato, il modello di Machine Learning viene costruito partendo da serie storiche di vendita, con profondità di almeno tre anni in questo caso, integrato con variabili aggiuntive quali stagionalità, promozioni, calendario e altri fattori contestuali. Queste informazioni vanno a costituire le feature del modello, mentre la variabile target è rappresentata dalla domanda prevista per specifici prodotti o categorie merceologiche.

Dal punto di vista metodologico il processo osservato ricalca le fasi di costruzione del modello analizzate in precedenza: definizione del problema di business, raccolta e preparazione dei dati, selezione dell'algoritmo, addestramento, validazione e successiva implementazione operativa e strategica. La qualità della base dati di partenza risulta un fattore cruciale per il successo, così come la presenza di informazioni storiche strutturate. La data platform di Carrefour Italia svolge, quindi, anche qui, un ruolo fondamentale per pulire e normalizzare i dati, al fine di aumentare l'affidabilità dei modelli previsionali.

Gli output generati vengono ad essere integrati all'interno dei processi decisionali aziendali, in particolare al fine di supportare le attività di riordino e pianificazione dello stock. In questo senso, la previsione della domanda assume un ruolo fondamentale per guidare le decisioni aziendali, contribuendo alla miglior efficienza operativa e a ridurre l'inefficienza lungo la catena del valore. Il valore del Machine Learning quindi in questo ambito non risiede esclusivamente nelle capacità predittive del modello, ma soprattutto nella possibilità di tradurre le previsioni in azioni concrete che incidono sulla disponibilità dei prodotti e sull'esperienza del cliente finale.

Nel quadro teorico è emerso come la previsione della domanda sia caratterizzata da forte incertezza, derivante da fattori esterni. In ambito retail il caso studio conferma come la domanda venga ad essere influenzata da fattori quali stagionalità, promozioni, e prezzo

di vendita, mentre i fattori meteo non risultano essere così impattanti come si pensava in primo luogo.

Il caso studio dimostra come gli standard raggiungibili dalle tecnologie, come il Machine Learning, siano molto elevate. Nel caso specifico di Carrefour Italia il fine ultimo della previsione della domanda è quello di arrivare a poter effettuare dei riordini automatici di merce. A livello tecnologico si potrebbe già percorrere questa strada, ma non si fa per scetticismo e scarsa fiducia nei confronti della tecnologia.

La dipendenza dai dati, sia per quantità che per qualità, risulta essere di cruciale importanza. Nel caso di Carrefour Italia emerge come per categorie di prodotto molto stabili nelle vendite e non particolarmente colpiti da fattori esterni come la stagionalità, come i prodotti di scatolame, risulti essere molto più semplice la costruzione di un modello di Machine Learning affidabile per prevedere la domanda. Per le categorie merceologiche più influenzate da fattori esterni la previsione risulta più complessa, come nel caso dell'ortofrutta, o addirittura impossibile per prodotti altamente di nicchia, con volumi di vendita molto bassi che, di conseguenza, portano a una minore quantità di dati a disposizione.

L'applicazione del Machine Learning alla previsione della domanda in Carrefour Italia conferma quanto emerso dal framework teorico: il valore di tali tecnologie dipende in larga misura dalla loro integrazione nei processi organizzativi e dalla chiarezza degli obiettivi di business. In un contesto caratterizzato da elevata disponibilità di dati e da una maturità tecnologica avanzata, la previsione della domanda diventa una leva strategica importante per ottimizzare la gestione delle scorte, migliorare il livello di servizio e ridurre gli sprechi.

Il Machine Learning si conferma elemento chiave per il supporto alle decisioni operative che riguardano la previsione della domanda nel campo del retail. Al tempo stesso, emerge la necessità di un approccio equilibrato, in cui tecnologia, dati e competenze umane convergano verso un obiettivo comune di creazione di valore, ribadendo che il Machine Learning rappresenta un abilitatore strategico piuttosto che una soluzione autonoma.

3.5 Implicazioni organizzative e sfide

Le principali difficoltà incontrate nell'adozione del machine learning, sia nell'ambito della segmentazione della clientela sia in quello della previsione della domanda, riguardano innanzitutto la disponibilità di dati sufficienti e di qualità adeguata, aspetto che ha reso necessaria una fase di preparazione preliminare particolarmente articolata. A questo si è affiancata una sfida rilevante sul piano del change management, inteso come processo di costruzione della fiducia nei confronti dei nuovi modelli, supportato da attività di comunicazione volte a chiarire i benefici attesi e le logiche di funzionamento delle soluzioni implementate.

In tale contesto, l'interpretabilità dei modelli emerge come un fattore determinante per favorirne l'adozione. Sebbene il successo del change management non dipenda esclusivamente dalla comprensibilità degli algoritmi, ma anche dall'accompagnamento dell'utente finale e dalla capacità di rendere esplicito il valore generato, la possibilità di spiegare il funzionamento delle soluzioni in modo semplice e accessibile risulta cruciale, soprattutto in contesti caratterizzati da un'elevata esperienza operativa ma da competenze tecnologiche non necessariamente avanzate.

Un'ulteriore criticità è rappresentata dall'integrazione dei modelli all'interno dell'ecosistema applicativo aziendale, spesso caratterizzato dalla presenza di sistemi legacy e da una forte frammentazione delle applicazioni, tipico delle aziende operanti nel settore del retail. L'inserimento delle soluzioni di Machine Learning in tale contesto comporta una complessità significativa, legata alla necessità di garantire l'interoperabilità tra sistemi eterogenei.

Per quanto concerne gli aspetti di privacy e governance del dato, nell'ambito della previsione della domanda non sono emerse particolari problematiche, poiché l'analisi si basa esclusivamente su dati di vendita a livello di prodotto e quantità, senza coinvolgere informazioni riconducibili ai clienti. Diversamente, nel contesto della customer analytics, pur trattandosi di dati più sensibili, le informazioni vengono sempre gestite in forma aggregata e non è prevista alcuna possibilità di accesso ai dati del singolo individuo, nemmeno nell'ambito del CRM.

Considerando l'evoluzione futura del machine learning in azienda, questa tecnologia è considerata uno strumento utile, ma non un fine in sé. Il machine learning

non rappresenta il “cosa”, bensì il “come”: la sua applicazione è giustificata solo in presenza di problemi chiaramente identificati per i quali tale metodologia risulti appropriata. Poiché tali soluzioni comportano costi non trascurabili, sia in termini di consumo computazionale sia di sviluppo, risulta fondamentale individuare a priori use case in grado di generare benefici sufficientemente rilevanti da compensare l’investimento richiesto. In questo senso, il machine learning costituisce una delle metodologie disponibili, ma non l’unica.

Più in generale, i dati e il loro utilizzo rivestono un ruolo strategico per l’organizzazione. Tuttavia, questo approccio non è più percepito come un vero e proprio vantaggio competitivo, quanto piuttosto come un requisito minimo (“bare minimum”), ormai ampiamente diffuso. L’azienda presenta già un certo livello di maturità sia dal punto di vista dei dati sia delle soluzioni adottate; resta tuttavia essenziale mantenere un monitoraggio costante dell’evoluzione del mercato, in particolare nell’ambito del machine learning e dell’intelligenza artificiale, preservando consapevolezza delle nuove opportunità tecnologiche ed essendo ricettivi rispetto ai potenziali use case applicabili al contesto aziendale.

CONCLUSIONI

Il presente elaborato ha evidenziato l'applicazione del Machine Learning (ML) nei processi aziendali del retail. L'intero processo è stato guidato dalle tre domande di ricerca iniziali ovvero in quali ambiti del retail il Machine Learning è maggiormente applicato, quali tecniche risultano più efficaci nei diversi contesti operativi, quali sfide e opportunità emergono dall'adozione di tali tecnologie. L'intero processo di documentazione, revisione della letteratura e sviluppo del caso aziendale sono stati fatti per rispondere a queste tre domande.

Attraverso la revisione della letteratura è emerso come gli ambiti aziendali dove viene ad essere maggiormente applicato il ML nelle realtà retail risultino essere tre:

- il pricing dinamico
- la segmentazione della clientela
- la previsione della domanda.

Il caso studio di Carrefour Italia pone l'enfasi in particolare sull'uso del ML per la segmentazione della clientela e la previsione della domanda; in particolare nell'ambito della customer analytics e della gestione della supply chain, con applicazioni orientate alla personalizzazione delle iniziative di marketing e all'ottimizzazione dei processi di riordino.

In relazione alla seconda domanda di ricerca, che pone il focus sulle tecniche più efficaci in relazione ai diversi contesti operativi, è emerso come le caratteristiche del problema che si vuole risolvere risultino essere di fondamentale importanza per la scelta del modello da utilizzare.

In relazione ad ognuna delle tre aree gestionali analizzate si evidenzia come ogni modello debba essere utilizzato per risolvere specifici problemi: per le applicazioni riguardanti il pricing dinamico e il demand forecasting i modelli di ML di regressione supervisionata risultano essere i più adatti, mentre i modelli di clusterizzazione risultano essere più appropriati per segmentare la clientela. Viene evidenziato anche come modelli più complessi e avanzati, quali Random Forest, Gradient Boosting e reti neurali artificiali, permettano di migliorare l'accuratezza delle previsioni.

La terza domanda di ricerca pone l'attenzione su quelle che sono le opportunità, ma anche sulle sfide che emergono nell'adozione del Machine Learning. Attraverso il caso studio appare evidente quelli che sono i benefici ma anche le difficoltà che accompagnano l'adozione del ML in azienda. Il miglioramento dell'efficienza operativa, la maggiore accuratezza delle decisioni in ambito marketing e supply chain e la possibilità di sviluppare strategie sempre più orientate ai dati risultano le migliori più evidenti.

Al contempo però, emergono anche le criticità organizzative che accompagnano l'uso del machine learning in azienda, come le problematiche legate alla disponibilità e qualità dei dati, all'integrazione dei modelli all'interno di ecosistemi applicativi spesso frammentati e alla gestione del cambiamento organizzativo.

Un elemento di particolare rilevanza del presente elaborato è rappresentato dal contributo del caso studio di Carrefour Italia, che ha consentito di validare empiricamente quanto sviluppato precedentemente nel framework teorico.

L'analisi condotta ha mostrato come le applicazioni del Machine Learning alla segmentazione della clientela e alla previsione della domanda non costituiscano solo ipotesi teoriche, ma trovino concreta attuazione in un contesto reale di grande distribuzione organizzata (GDO).

Nel caso specifico di Carrefour Italia, la segmentazione basata sui modelli di Machine Learning ha evidenziato la possibilità di superare i limiti delle metodologie tradizionali, consentendo l'individuazione di gruppi di clienti omogenei e la definizione di strategie di marketing mirate.

Parallelamente, l'applicazione di modelli predittivi per la previsione della domanda ha dimostrato il ruolo strategico del Machine Learning nel supportare la pianificazione operativa e la gestione dello stock, contribuendo alla riduzione delle inefficienze e al miglioramento del livello di servizio.

Il caso studio ha inoltre permesso di evidenziare alcuni aspetti critici, quali la centralità della qualità dei dati, l'importanza di un'infrastruttura tecnologica adeguata e la necessità di un forte allineamento tra tecnologia e obiettivi di business.

In particolare, è emerso che il Machine Learning non rappresenta una soluzione universale applicabile indistintamente, ma uno strumento abilitante il cui valore è

strettamente connesso al livello di maturità dell'organizzazione e alla capacità dell'impresa di integrare competenze analitiche e decisionali.

Il change management e l'interpretabilità dei modelli si confermano fattori chiave per favorire l'adozione delle soluzioni da parte degli utenti finali. Si evidenzia inoltre che gli aspetti di privacy e governance del dato debbano sempre essere trattati in relazione al caso specifico; infatti, si emerge che queste tematiche risultano meno critiche nella previsione della domanda, mentre assumono maggiore rilevanza nell'ambito della customer analytics, ma non comportano problematiche, poiché le informazioni vengono comunque trattate esclusivamente in forma aggregata.

Il caso di studio di Carrefour Italia conferma come il Machine Learning, se inserito in una strategia aziendale coerente e supportato da una solida governance del dato, può costituire una leva strategica determinante per la creazione di valore nel settore retail. Il caso analizzato rafforza dunque le evidenze teoriche emerse dalla revisione della letteratura, dimostrando come l'adozione consapevole e mirata di tali tecnologie possa tradursi in benefici concreti sia sul piano operativo sia su quello strategico.

Nel complesso, i risultati dell'analisi suggeriscono che il Machine Learning non debba essere considerato un fine in sé, bensì uno strumento da applicare in modo consapevole e mirato, a partire da problematiche di business chiaramente definite e da una valutazione preventiva del rapporto tra costi e benefici. Il valore generato dipende dalla capacità dell'organizzazione di integrare competenze analitiche, infrastrutture tecnologiche e sistemi di supporto decisionale all'interno di una strategia data-driven più ampia.

In conclusione, il Machine Learning si configura oggi come una componente ad alto livello strategico per le imprese del settore retail. Il caso di Carrefour Italia evidenzia un livello di maturità già significativo, ma sottolinea al contempo la necessità di adottare un approccio basato su sperimentazione, apprendimento e adattamento, condizioni essenziali per trasformare il potenziale tecnologico in valore concreto.

BIBLIOGRAFIA

- Abidar, L., Zaidouni, D., Asri, I. E., & Ennouaary, A. (2023). Predicting Customer Segment Changes to Enhance Customer Retention: A Case Study for Online Retail using Machine Learning. *International Journal of Advanced Computer Science and Applications*, 14(7). <https://doi.org/10.14569/ijacsa.2023.0140799>
- Agbemadon, K. B., Couturier, R., & Laiymani, D. (2023). Overstock Prediction Using Machine Learning in Retail Industry. *2023 3rd International Conference on Computer, Control and Robotics (ICCCR), 2023*, 439–444. <https://doi.org/10.1109/icccr56747.2023.10194060>
- Alqhatani, A., Ashraf, M. S., Ferzund, J., Shaf, A., Abosaq, H. A., Rahman, S., Irfan, M., & Alqhtani, S. M. (2022). 360° retail business analytics by adopting hybrid machine learning and a business intelligence approach. *Sustainability*, 14(19), 11942. <https://doi.org/10.3390/su141911942>
- Alzubi, J., Nayyar, A., & Kumar, A. (2018). Machine Learning from Theory to Algorithms: An Overview. *Journal of Physics Conference Series*, 1142, 012012. <https://doi.org/10.1088/1742-6596/1142/1/012012>
- Arefin, S., Parvez, R., Ahmed, T., Ahsan, M., Sumaiya, F., Jahin, F., & Hasan, M. (2024). Retail Industry Analytics: Unraveling Consumer Behavior through RFM Segmentation and Machine Learning. *IEEE International Conference on Electro Information Technology*, 2024, 545–551. <https://doi.org/10.1109/eit60633.2024.10609927>
- Ashraf, A., Rayed, C. A., Awad, N. A., & Sabry, H. M. (2025). A framework for customer segmentation to improve marketing strategies using machine learning. *Procedia Computer Science*, 260, 616–625. <https://doi.org/10.1016/j.procs.2025.03.240>
- Barbierato, E., Gatti, A., Incremona, A., Pozzi, A., & Toti, D. (2025). Breaking away from AI: The Ontological and ethical evolution of Machine Learning. *IEEE Access*, 13, 55627–55647. <https://doi.org/10.1109/access.2025.3553032>
- Brackmann, C., Hütsch, M., & Wulfert, T. (2023). Identifying application areas for machine learning in the retail sector. *SN Computer Science*, 4(5), 426. <https://doi.org/10.1007/s42979-023-01888-w>
- Bolognesi, F., (2025), *Intelligenza artificiale. Istruzioni per l'uso. Come il Machine Learning e l'IA Generativa possono trasformare le attività e generare vantaggi competitivi. Completo di manuali di prompt-engineering e di costruzione di modelli di Machine Learning II edizione*, Roma, EPC EDITORE.
- Deng, C., Liu, X., Zhang, J., Mo, Y., Li, P., Liang, X., & Li, N. (2025). Prediction of retail commodity hot-spots: a machine learning approach. *Data Science and Management*, 8(4), 414–422. <https://doi.org/10.1016/j.dsm.2025.02.003>

- Gao, X., Shen, C., Jiang, W., Lin, C., Li, Q., Wang, Q., Li, Q., & Guan, X. (2024). Fairness in machine learning: definition, testing, debugging, and application. *Science China Information Sciences*, 67(9). <https://doi.org/10.1007/s11432-023-4060-x>
- Gao, X. (2023). Artificial intelligence applied to supermarket intelligent replenishment robot based on machine vision. *2023 Asia-Europe Conference on Electronics, Data Processing and Informatics (ACEDPI)*, 290–294. <https://doi.org/10.1109/acedpi58926.2023.00063>
- Gately, C. (2017). Vekia: pioneering machine learning in retail supply chain. *Small Enterprise Research*, 24(3), 326–332. <https://doi.org/10.1080/13215906.2017.1396243>
- Girimurugan, B., K, G., Sasank, M., Pokuri, V. N., Kurra, N. K., & Reddy, V. (2024). Leveraging Artificial Intelligence And Machine Learning For Advanced Customer Relationship Management In The Retail Industry. *2024 2nd International Conference on Disruptive Technologies (ICDT)*, 2024, 51–55. <https://doi.org/10.1109/icdt61202.2024.10488981>
- Hassan, D. O., & Hassan, B. A. (2024). A comprehensive systematic review of machine learning in the retail industry: classifications, limitations, opportunities, and challenges. *Neural Computing and Applications*, 37(4), 2035–2070. <https://doi.org/10.1007/s00521-024-10869-w>
- Huber, J., & Stuckenschmidt, H. (2020). Daily retail demand forecasting using machine learning with emphasis on calendric special days. *International Journal of Forecasting*, 36(4), 1420–1438. <https://doi.org/10.1016/j.ijforecast.2020.02.005>
- Jian, L., Guo, S., & Yu, S. (2023). Effect of artificial intelligence on the development of China's wholesale and retail trade. *Sustainability*, 15(13), 10524. <https://doi.org/10.3390/su151310524>
- Jiang, H., Ruan, J., & Sun, J. (2021). Application of Machine Learning Model and Hybrid Model in Retail Sales Forecast. *2021 IEEE 6th International Conference on Big Data Analytics (ICBDA)*, 2021, 69–75. <https://doi.org/10.1109/icbda51983.2021.9403224>
- Lu, J., Zheng, X., Nervino, E., Li, Y., Xu, Z., & Xu, Y. (2023). Retail store location screening: A machine learning-based approach. *Journal of Retailing and Consumer Services*, 77, 103620. <https://doi.org/10.1016/j.jretconser.2023.103620>
- Matuszelański, K., & Kopczewska, K. (2022). Customer churn in Retail E-Commerce Business: Spatial and machine learning approach. *Journal of Theoretical and Applied Electronic Commerce Research*, 17(1), 165–198. <https://doi.org/10.3390/jtaer17010009>
- Mitra, A., Jain, A., Kishore, A., & Kumar, P. (2022). A Comparative Study of demand Forecasting Models for a Multi-Channel Retail Company: A novel hybrid Machine

learning approach. *Operations Research Forum*, 3(4). <https://doi.org/10.1007/s43069-022-00166-4>

- Naskinova, I., Kolev, M., & Lazarova, M. (2024). Forecasting Strategies in Retail: Utilizing Advanced Machine Learning Methods while Safeguarding Privacy. *Journal of Physics Conference Series*, 2910(1), 012008. <https://doi.org/10.1088/1742-6596/2910/1/012008>
- Nasseri, M., Falatouri, T., Brandtner, P., & Darbanian, F. (2023). Applying Machine Learning in Retail Demand Prediction—A comparison of Tree-Based Ensembles and Long Short-Term Memory-Based Deep Learning. *Applied Sciences*, 13(19), 11112. <https://doi.org/10.3390/app131911112>
- Rahman, M. A., Modak, C., Mozumder, M. a. S., Miah, M. N. I., Hasan, M., Sweet, M. M. R., Roy, S. F. F., Hossan, M. Z., Roy, M. P., & Alam, M. (2024). Advancements in retail price optimization: Leveraging machine learning models for profitability and competitiveness. *Journal of Business and Management Studies*, 6(3), 103–110. <https://doi.org/10.32996/jbms.2024.6.3.11>
- Ranganathan, C. S., Rajasekaran, M., Meenakshi, R., A, A. P., GaneshBabu, T. R., & Sujatha, S. (2024). Real-Time Price Elasticity Analysis in Retail Using IoT and Machine Learning. *2024 First International Conference on Innovations in Communications, Electrical and Computer Engineering (ICICEC), 2024*, 1–6. <https://doi.org/10.1109/icicec62498.2024.10808288>
- Talbi, S., Achour, S., & Abkary, B. (2020). Journal of Business and Management Studies. *Journal of Business and Management Studies*. <https://doi.org/10.32996/jbms>
- Shankar, V., Kalyanam, K., Setia, P., Golmohammadi, A., Tirunillai, S., Douglass, T., Hennessey, J., Bull, J., & Waddoups, R. (2020). How Technology is Changing Retail. *Journal of Retailing*, 97(1), 13–27. <https://doi.org/10.1016/j.jretai.2020.10.006>
- Singhal, K., Singh, V., & Kaul, A. (2024). Smart Retail: Utilizing Machine Learning for Demand Prediction, Price Strategy, and Inventory Management. *Proceedings (International Confernce on Computational Intelligence and Communication Networks)*, 2024, 485–489. <https://doi.org/10.1109/cicn63059.2024.10847534>
- Subbarayudu, Y., Reddy, G. V., Raj, M. V. K., Uday, K., Fasiuddin, M., & Vishal, P. (2023). An efficient novel approach to E-commerce retail price optimization through machine learning. *E3S Web of Conferences*, 391, 01104. <https://doi.org/10.1051/e3sconf/202339101104>
- Suh, J., & Lee, J. (2025). Machine learning-based customer segmentation: advances and applications in retail. *Applied Economics Letters*, 1–5. <https://doi.org/10.1080/13504851.2025.2566879>

- Turkmen, B. (2022). Customer segmentation with machine learning for online retail industry. *The European Journal of Social & Behavioural Sciences*, 31(2), 111–136. <https://doi.org/10.15405/ejsbs.316>
- V, S., N, K., Saivenkat, R., R, G., R, T. M., & J, Z. H. (2025). Smart Sales Forecasting Machine Learning Models for Demand Prediction in Retail. *2025 3rd International Conference on Intelligent Data Communication Technologies and Internet of Things (IDCIoT)*, 2025, 2139–2143. <https://doi.org/10.1109/idciot64235.2025.10915120>
- Velásquez, J. D. (2025). An analysis of trends, challenges, and opportunities in retail analytics. *International Journal of Market Research*, 67(4), 394–422. <https://doi.org/10.1177/14707853251315585>
- Vukovic, D. B., Spitsina, L., Griбанова, E., Spitsin, V., & Lyzin, I. (2023). Predicting the performance of retail market firms: Regression and machine learning methods. *Mathematics*, 11(8), 1916. <https://doi.org/10.3390/math11081916>
- Yamuna, G., Dhinakaran, D. P., Vijai, C., Kingsly, P. J., Raynukaazhakarsamy, & Devi, S. R. (2024). Machine Learning-Based Price Optimization for Dynamic Pricing on Online Retail. *2024 Ninth International Conference on Science Technology Engineering and Mathematics (ICONSTEM)*, 2024, 1–5. <https://doi.org/10.1109/iconstem60960.2024.10568763>

SITOGRAFIA

<https://www.carrefour.com/en/group/history>

<https://www.carrefour.com/en/digital-retail-strategy-2026>