

POLITECNICO DI TORINO

Corso di Laurea Magistrale in Ingegneria della Produzione
Industriale e dell'Innovazione Tecnologica

Tesi di Laurea Magistrale

Riprogettazione di un processo aziendale di logistica



Anno Accademico 2019/2020

Relatore
Maurizio Morisio

Candidata
Maria Laura Iovino

Indice

ABSTRACT.....	4
ABSTRACT.....	5
RINGRAZIAMENTI.....	6
1. INTRODUZIONE.....	7
1.1 PREMESSA.....	7
1.2 OBIETTIVO.....	8
1.3 STRUTTURA.....	8
2. LA GESTIONE DEL CAMBIO.....	10
2.1 DEFINIZIONE.....	10
2.2 STORIA.....	11
2.3 LA GESTIONE DEL CAMBIO NELLE ORGANIZZAZIONI.....	12
2.4 IL CAMBIAMENTO ED IL RUOLO DEL MANAGEMENT NELLE ORGANIZZAZIONI.....	13
2.5 FONTI DI RESISTENZA.....	14
3. STATO DELL'ARTE DELLA GESTIONE DEL CAMBIO.....	15
3.1 IL MODELLO DI LEWIN:.....	15
3.2 IL MODELLO ADKAR.....	17
3.3 PROSCI ENTERPRISE CHANGE MANAGEMENT.....	18
3.4 BOSTON CONSULTING GROUP (BCG) CHANGE DELTA.....	22
4. RIPROGETTAZIONE DEL PROCESSO DI ACQUISTO.....	25
4.1 DESCRIZIONE DELL'AZIENDA.....	25
4.2 PROGETTO TRASFORMAZIONE HANGAR.....	26
4.3 CONSAPEVOLEZZA DELLA NECESSITÀ DI UN CAMBIO IT.....	26
4.4 RIPROGETTAZIONE DEI PROCESSI (<i>PROCESS REENGINEERING</i>).....	27
4.5.1 Identificazione del processo di acquisto:.....	27
4.5.2 Scoperta del processo:.....	27
4.5.3 Mappatura processo AS-IS.....	28
4.5.4 Mappatura processo TO-BE:.....	29
4.5.5 Implementazione del processo.....	30
5. SITUAZIONE ATTUALE, PROBLEMA E SOLUZIONE.....	31
5.1 DESCRIZIONE DISTRIBUZIONE PRODOTTI ATTUALE:.....	31
5.2 SITUAZIONE ATTUALE CD.....	32
5.3 PROBLEMA STANDARD ATTUALE CD.....	34
5.4 SOLUZIONE STANDARD PRE-PACKS.....	34
6. MACHINE LEARNING.....	35
6.1 CONTESTO.....	35
6.2 NOTAZIONE E FUNZIONE f	36
6.3 FUNZIONE f	37
6.4 INFERENZA.....	37
6.5 PREDIZIONE.....	37
6.6 STIMA DI f	38
6.7 PARADIGMI.....	40
7. ALBERI DECISIONALI E CLASSIFICATORI AVANZATI.....	42
7.1 ALBERI DECISIONALI.....	42
7.2 TECNICHE AVANZATE DI CLASSIFICAZIONE.....	44
7.2.1 Bagging: Random Forest.....	45
7.2.2 Boosting.....	46

8.	CREAZIONE DEL MODELLO CON XGBOOST E ANALISI DELLA PREDIZIONE.....	51
8.1	DEFINIZIONE TASK DA RISOLVERE	51
8.2	RACCOLTA DATI.....	52
8.3	PRE-PROCESSAMENTO.....	52
8.4	SPIEGAZIONE ALGORITMO.....	53
8.5	CALCOLO COLLI STANDARD: PRE-PACKS.....	57
8.6	ANALISI: PREDIZIONE VS. REALTÀ	61
	<i>Percentuale di colli manipolati</i>	62
	<i>FTE</i>	64
	<i>Costo manipolazione dei colli</i>	66
9.	CONCLUSIONE E SVILUPPI FUTURI.....	67
9.1	CONCLUSIONE	67
9.2	SVILUPPI FUTURI	69
	REFERENZE.....	70
	APPENDICE.....	73

ABSTRACT

Il seguente elaborato ha lo scopo di mostrare un pratico esempio di come le sinergie tra logistica, IT e machine learning possano influenzare positivamente la gestione del processo del cambio.

La prima parte dell'elaborato si focalizza sullo state of the art della gestione del cambio e sulla Riprogettazione dei Processi (Process Reengineering) applicata al processo aziendale di Acquisto.

La seconda parte dell'elaborato sull'analisi dello stato dell'arte di alcune tecniche di machine learning e su come esse possono essere impiegate per supportare un'organizzazione nell'ottimizzazione delle prestazioni di un processo.

Nella terza parte viene presentato lo stato attuale dell'azienda fornendo una panoramica sul processo di acquisto aziendale e sul suo imminente cambiamento operato a partire da decisioni basate sull'analisi dei dati. In particolare, ci si focalizza sul cambiamento di un micro-processo basato sull'adozione di un formato standardizzato dei colli aziendali che andrebbe a sostituire il formato correntemente in uso.

Attualmente il contenuto e le dimensioni dei colli sono poco standardizzati e comportano problemi logistici (di pallettizzazione) e distributivi (una mancata distribuzione dei colli personalizzati per ogni cliente finale comporta una successiva manipolazione degli stessi per permettere che il loro contenuto venga inviato ad altri clienti).

Con la nuova standardizzazione si fisserebbe sia il contenuto dei colli, che loro dimensione. Il cambiamento verrà complementato dalle predizioni di un algoritmo di machine learning, che consentirà di predire la quantità di colli da manipolare, a partire da una certa configurazione del contenuto dei colli stessi. Ciò, pertanto, consentirà all'azienda di eseguire diversi scenari sul contenuto dei colli, così da minimizzare il numero di colli manipolati.

Il modello utilizzato è il cosiddetto *XGBoost*; questo algoritmo infatti è molto robusto e garantisce ottime performance. Inoltre, consente di gestire con efficacia i dati mancanti, diminuire i tempi computazionali tramite la parallelizzazione e regolarizzare i dati così da prevenire l'*overfitting*.

La sezione finale dell'elaborato contiene i risultati della simulazione basata sui risultati dell'approccio proposto. Al fine di misurare il miglioramento si è effettuato un confronto tra la predizione del modello e la situazione corrente, analizzando il miglioramento in termini di 'percentuale di colli manipolati', 'costo manipolazione dei colli' e 'FTE'. Le conclusioni del lavoro dimostrano che l'adozione della nuova metodologia standardizzata comporterebbe un aumento del numero di colli manipolati, e un conseguente aumento dei costi.

Come spunto futuro si sottolinea dunque la possibilità di effettuare esperimenti iterativi cambiando il contenuto dei colli, così da fornire al modello più scenari da analizzare. Ciò consentirebbe di migliorare il potere predittivo dello stesso, così da permettere un incremento dell'efficienza del processo.

Oltretutto, tramite i diversi esperimenti l'azienda potrebbe trovare la configurazione ottimale del contenuto dei colli così da ridurre al minimo la manipolazione.

Parole chiave

Colli, Gestione del cambio, Riprogettazione dei processi, Intelligenza artificiale, Machine Learning, Metodi Ensemble, XGBoost

ABSTRACT

The following paper aims to show a practical example of how the synergies between logistics, IT and machine learning can positively influence the management of a change process.

The first part of the paper focuses on the state of the art of change management and on Process Reengineering applied to the "Purchase" business process.

The second part of the paper focuses on the analysis of the state of the art of some machine learning techniques and how they can be used to support an organization in optimizing process performances.

In the third part, the current status of the company is presented, providing an overview of the company's purchasing process and its imminent change operated starting from decisions based on data analysis. In particular, the focus is on the change of a micro-process based on the adoption of a standardized format of company packages which would replace the format currently in use. Currently, the content and dimensions of packages are not standardized and involve logistical problems (palletizing) as well as distribution problems (a failure to distribute those personalized packages to each end-customer entails their subsequent manipulation in order to allow to send their content to another customer).

With the new standardization, both the content of the packages and their size would be fixed. The change will be complemented by the predictions of a machine learning algorithm, which will allow to predict the quantity of packages to be handled, starting from a certain configuration of the content of the packages themselves. This, therefore, will allow the company to perform different scenarios on the contents of the packages, so as to minimize the number of packages handled. The model used is the so-called *XGBoost*; this algorithm is in fact very robust and guarantees excellent performance. Furthermore, it allows you to effectively manage missing data, reduce computational time by parallelizing and regularize data so as to prevent overfitting.

The final section of the paper contains the results of the simulation based on the results of the proposed approach. In order to measure the improvement, a comparison was made between the prediction of the model and the current situation, analyzing the improvement in terms of "percentage of packages handled", "cost of handling the packages" and "FTE". The conclusions of the work show that the adoption of the new standardized methodology would lead to an increase in the number of packages handled, and a consequent increase in costs.

As a future starting point, the possibility of performing iterative experiments by changing the contents of the packages is underlined, so as to provide the model with more scenarios to be analyzed. This would allow to improve the predictive power of the same, allowing an increase in the efficiency of the process. Moreover, through the various experiments the company could find the optimal configuration of the contents of the packages so as to minimize handling.

Keywords

Packs, Change Management, Process Reengineering, Artificial Intelligence, Machine Learning, Ensemble methods, XGBoost

Ringraziamenti

In primo luogo, vorrei ringraziare il Prof. Morisio, relatore di questa tesi di laurea magistrale, per la sua disponibilità e per l'aiuto fornitomi. I suoi consigli e la sua pazienza nel risolvere i miei dubbi durante il periodo di stesura, così come la sua prontezza nell'indirizzarmi per effettuare il labor limae sono stati preziosi. Un altro ringraziamento va al Prof. Zucca per la sua disponibilità e gentilezza durante tutti questi anni al Politecnico come referente del corso di laurea.

Ci terrei anche a ringraziare la mia famiglia per essermi sempre stata accanto e, in particolare negli ultimi due anni di laurea magistrale che, come ben sappiamo, non sono stati facili.

Un ringraziamento speciale va a mio fratello Giovanni, che tutt'ora continua a rimanere il mio mentore e il mio punto di riferimento e che sono sicura rimarrà tale anche in futuro.

Infine, vorrei ringraziare il mio ragazzo Sergi per il supporto datomi durante questi mesi all'estero, soprattutto durante quei momenti di felicità, così come di solitudine dettati dal fatto che non mi trovo vicino alla mia famiglia.

Senza di voi questo percorso non sarebbe stato fattibile e per questo motivo lo dedico ad ognuno di voi.

1. Introduzione

1.1 Premessa

Gli ultimi decenni di storia sono stati caratterizzati da progressi tecnologici e sociali che hanno completamente ridefinito il mondo. Il mondo odierno è più veloce, connesso, smart e globalizzato; inoltre, il crescente peso delle economie in via di sviluppo pone un interrogativo su come i paesi più industrializzati potranno mantenere il proprio primato economico e tecnologico.

La vita media di un'azienda quotata sull'indice SP500 è diminuita da quasi 60 anni nel 1950 a meno di 20 anni; continue evoluzioni tecnologiche, difficoltà nel prevedere le tendenze di mercato, e scarsa capacità di adattamento sono solo alcune delle cause che hanno portato a questo feroce meccanismo di selezione naturale. Pertanto, è ormai fondamentale che le aziende diventino più flessibili e agili così da potersi adattare, continuare a sopravvivere e innovare.

Oggi, immaginare il mondo della logistica senza l'apporto del settore IT sarebbe assolutamente impossibile. Tale sinergia infatti ha consentito di implementare su vasta scala programmi di gestione del cambio; ciò consente alle aziende di migliorare i propri profitti, essere più agili e rispondere con maggiore prontezza alle sfide sempre più stringenti poste da un mercato sempre più competitivo, in continua evoluzione, e in cui la disponibilità istantanea di merci e servizi è ormai considerata come un prerequisito.

A tal fine, come mai prima d'ora diventa critico prevedere con incredibile precisione prestazioni o eventi futuri, così da poter intervenire prima che l'evento di verifichi.

I recenti progressi nel campo del machine learning consentono di ottenere predizioni accurate. Ciò permette quindi di utilizzare i dati aziendali per modellare problemi complessi. Negli anni, le aziende hanno accumulato un'incredibile quantità di dati, che attualmente costituisce ciò che viene definito patrimonio informativo. L'utilizzo di tecniche di machine learning e data analytics consente quindi alle aziende di far leva su questi dati quando esse devono operare scelte precise e puntuali.

1.2 Obiettivo

Nel seguente elaborato ci si focalizza sul processo di acquisto aziendale e sul suo imminente cambiamento. In concreto, si pone attenzione al cambiamento di un micro-processo basato sull'adozione di un formato standardizzato dei colli aziendali che andrebbe a sostituire il formato correntemente in uso. Attualmente il contenuto e le dimensioni dei colli sono poco standardizzati e comportano problemi logistici (di pallettizzazione) e distributivi (una mancata distribuzione dei colli personalizzati per ogni cliente finale comporta una successiva manipolazione degli stessi per permettere che il loro contenuto venga inviato ad altri clienti).

Con la nuova standardizzazione si andrebbe a fissare sia il contenuto dei colli, che loro dimensione. Il cambiamento verrà complementato dalle predizioni di un algoritmo di machine learning e sarà utilizzato per predire la quantità di colli da manipolare, a partire da una certa configurazione del contenuto dei colli stessi.

L'obiettivo dell'elaborato è comprendere se con suddetta configurazione si riesce ad ottenere un miglioramento dei colli manipolati o se risulta necessario all'azienda eseguire diversi scenari con un contenuto differente dei colli fino ad arrivare ad una minimizzazione del numero di colli manipolati.

1.3 Struttura

L'elaborato consiste in 9 capitoli e segue la seguente struttura:

2° capitolo: viene introdotto il concetto di gestione del cambio focalizzandosi sulla sua definizione, storia e applicazione odierna. Successivamente, ci si concentra su un esempio di approccio strutturato che le aziende possono seguire per gestire il cambiamento e sulle possibili fonti di resistenza a cui quest'ultime possono andare incontro.

3° capitolo: si descrive lo stato dell'arte della gestione del cambio con le tecniche e metodologie utilizzate finora: Lewin, ADKAR, Prosci e BCG Change Delta.

4° capitolo: si introduce l'azienda presso la quale si è svolta la tesi (MANGO), così come il suo progetto di gestione del cambio IT denominato Trasformazione Hangar. Successivamente, ci si sofferma su come MANGO abbia raggiunto la consapevolezza della necessità di suddetto cambio e si ripercorrono i passi eseguiti nella Riprogettazione del processo di acquisto: dal processo attuale al suo imminente cambiamento.

5° capitolo: si descrive il micro-processo della fase di acquisto attuale, focalizzandosi sul problema causato dal formato dei colli attuali e presentando la soluzione individuata da MANGO che consiste in un nuovo formato dei colli con contenuto e dimensioni standard.

6° capitolo: si definiscono i concetti base del Machine Learning introducendo le notazioni matematiche e la classificazione degli algoritmi di ML nelle tre categorie di apprendimento: supervisionato, non supervisionato e per rinforzo.

7° capitolo: si approfondisce l'apprendimento supervisionato concentrandosi in particolare sulla metodologia di classificazione denominata Albero decisionale e sulle tecniche avanzate di classificazione *Ensemble*, che basicamente aggruppano vari sistemi classificatori per ottenerne uno finale più preciso: *Boosting* e *Bagging*. Infine, ci si sofferma sulla tecnica più evoluta di *Boosting* chiamata *XGBoost* e sulle sue caratteristiche.

8° capitolo: si definisce il motivo per cui è scelto di utilizzare il metodo di predizione *Ensemble XGBoost*, si spiega com'è avvenuta la raccolta dati del database e come quest'ultimo è stato pre-processato per pulirlo dai dati grezzi.

Si descrive l'algoritmo creato passo per passo e il calcolo effettuato per conoscere il numero di colli creati con il nuovo formato (Pre-Packs) usato come input della predizione. Infine, si analizzano i risultati predetti confrontandoli con i risultati reali della collezione Autunno-Inverno 2018 usando i seguenti indicatori: 'percentuale di colli manipolati', 'costo manipolazione dei colli' e 'FTE'.

9° capitolo: si traggono le dovute conclusioni e si espongono gli spunti per il futuro.

2. La gestione del cambio

Nel seguente capitolo si introduce la gestione del cambio focalizzandosi sulla sua definizione, storia e applicazione odierna. Successivamente, ci si concentra sulla gestione del cambio nelle organizzazioni definendo un approccio strutturato volto alla sua applicazione e accennando le più comuni fonti di resistenza al cambiamento.

2.1 Definizione

Il termine Change Management, detto anche gestione del cambio, si riferisce a un approccio articolato al cambiamento nei soggetti, associazioni e società che permette e/o guida la transizione da un ordinamento corrente ad un futuro ordinamento desiderato. In particolare, somministra gli strumenti e processi per identificare e cogliere il cambiamento e gestire l'impatto umano di un cambiamento. Di per sé, un cambiamento implica una fase di transizione dove si è consapevoli della sfida intrinseca legata alla necessità e/o volontà di trasformare una condizione esistente in una nuova. Per poter ottenere un cambiamento efficace, è fondamentale essere consci della rilevanza di definire lo stato corrente (punto A: dove siamo), lo stato desiderato (punto B: dove vogliamo arrivare) e il percorso più conveniente.



Fig.2.1.1: rappresentazione del percorso di cambiamento

2.2 Storia

La gestione del cambio ebbe inizio intorno agli anni '90 quando nel 1948, Lester Coch e John French Jr. scoprirono che nonostante gli individui venissero addestrati su nuovi strumenti e metodi, si presentava sempre un problema motivazionale che li induceva a respingere il cambiamento. Dunque, in quegli anni apparve per la prima volta il termine di resistenza al cambiamento, inteso come elemento cruciale nella gestione del cambiamento. Inoltre, Lester Coch e John French Jr. scoprirono anche che suddetta resistenza al cambiamento era molto più diffusa tra gli alti dirigenti che tra il personale junior e dunque suggerirono un approccio dove la direzione si impegnava a comunicare l'importanza del cambiamento organizzativo per i dipendenti e li coinvolgeva nella pianificazione del cambiamento.

Negli anni '50, Kurt Lewin ed Edgar Schein crearono il "Modello a tre stadi", che verrà trattato in seguito nell'elaborato. Nonostante il suo approccio ad altissimo livello per affrontare i cambiamenti organizzativi, questa tecnica dette inizio ad una ristrutturazione dei cambiamenti conducendo alla ricerca di Everett Rogers negli anni '60 e '70 su un processo definito di "adozione", che coinvolgeva "Early Adopters" (i primi ad adottare il cambiamento) e "Change Champions" (persone che promuovono il cambiamento). Rogers di fatto creò un nuovo modello di gestione delle modifiche, focalizzato su 5 fasi distinte: consapevolezza, interesse, valutazione, prova e adozione. Il modello viene tutt'ora utilizzato nell'ambito della gestione del cambio.

Nello stesso periodo, la disciplina iniziò ad assumere un aspetto più umanistico. Questa svolta fu per la maggior parte guidata da Elizabeth Kubler-Ross, un'assistente sociale che lavorava con malati terminali. Attraverso il suo lavoro, Elizabeth fu in grado di riconoscere uno schema specifico di dolore quando comunicava ai propri pazienti che stavano per morire. Documentò dunque queste fasi e creò il modello di dolore a cinque fasi: negazione, rabbia, contrattazione, depressione e accettazione.

Le sue considerazioni aprirono la strada alla creazione di un ulteriore modello chiamato "Curva di cambio". Suddetto modello si focalizza maggiormente sull'individuo ma risulta controverso poiché non prende in considerazione l'esperienza, la quale però influisce direttamente sull'atteggiamento degli impiegati (un nuovo impiegato reagisce in maniera differente rispetto ad un veterano davanti ad un cambiamento).

Negli anni '80, Warner Burke e George Litwin iniziarono ad analizzare i cambiamenti in modo diverso rispetto a Kubler-Ross. Invece di concentrarsi sull'individuo, spostarono la propria attenzione sull'organizzazione esaminando 12 elementi organizzativi - tra cui Mission, Leadership, External Environment e Systems e l'impatto di questi elementi sul successo di un'iniziativa di cambiamento organizzativo. Questa tendenza portò al successivo intervento di Fred Davis con i modelli sull'adozione tecnologica (TAM / TAM2).

Suddetti modelli TAM e TAM2 sono in realtà la premessa centrale utilizzata per la maggior parte (se non tutti) i cambiamenti IT, e modellizzano come gli utenti arrivano all'accettazione e all'utilizzo di una nuova tecnologia. In particolare, affermano l'esistenza di due fattori primari che portano al successo nell'adozione di un cambiamento:

- 1) L'utilità percepita, definita da Davis come il grado in cui l'utente ritiene che un particolare sistema aumenterà le sue prestazioni lavorative.
- 2) La facilità d'utilizzo percepita, definita come il grado in cui l'utente ritiene che l'utilizzo di un particolare sistema sarebbe libero da sforzi.

Negli anni '90 la filosofia sulla gestione del cambiamento mutò e si iniziò a considerare come un processo a più fasi. La prima fase prevedeva l'adozione del cambiamento da parte del decisore e degli influenzatori organizzativi chiave. Solo allora, si poteva passare alla seconda fase dell'adozione, gli utenti finali. Durante il cambio le società di consulenza intervenivano nei cambiamenti organizzativi riunendosi con i dipendenti di una determinata azienda valutando, progettando e spingendo il cambio. I loro interventi risultavano però poco apprezzati e per questo motivo le aziende iniziarono a rivolgersi ad altre aziende specializzate nell'integrazione di sistemi.

Intorno a questo periodo, John Kotter pubblicò il suo libro "Leading Change", ritenuto attualmente come l'opera più importante sulla gestione del cambio organizzativo.

È importante notare che negli ultimi dieci anni l'approccio di gestione del cambio si è destrutturato. Al giorno d'oggi vi sono alcune organizzazioni che considerano il Change Management un problema di comunicazione, e altre che lo considerano esclusivamente dal lato umanistico. Altre ancora lo vedono come una disciplina distinta e separata rispetto ad alcune che lo incorporano nell'ufficio Project Management.

Attualmente, i cambiamenti organizzativi risultano essere incrementali (evolutivi) rispetto a cambiamenti organizzativi su larga scala (rivoluzionari). Si tende dunque a non consultare il personale su questi cambiamenti evolutivi dato che risultano naturali, al contrario dei cambiamenti rivoluzionari che però risultano essere pochi e distanti tra loro.

Nonostante la società odierna sia aperta al cambiamento e desideri lavorare per organizzazioni in continuo mutamento, si sta notando una riduzione di questo entusiasmo poiché si sta notando che il cambio non riesce ad essere gestito in modo efficace dalle aziende.

Pertanto, secondo molte scuole di pensiero, i responsabili dei cambiamenti dovrebbero strutturare i propri cambiamenti organizzativi evitando la gestione del cambiamento "ad hoc". Dovrebbero dunque guardare al cambiamento organizzativo con una prospettiva programmatica e sfruttare gli esperti in materia attorno agli impatti dei cambiamenti focalizzandosi sul "cambiamento oltre il cambiamento".

Oltretutto, la trasformazione digitale e la gestione del cambio vanno avanti di pari passo. La stessa trasformazione digitale è ormai uno dei principali drivers del cambiamento organizzativo come nel caso di MANGO, preceduto solo da iniziative di miglioramento dell'efficienza aziendale e nuove esigenze della clientela.

2.3 La gestione del cambio nelle organizzazioni

Nella sezione precedente si è menzionato di frequente il cambiamento organizzativo. Infatti, in termini di utilità dell'elaborato, risulta rilevante contestualizzare il cambiamento nell'ambito di un'organizzazione commerciale. Accennando al case study dell'azienda MANGO, si sottolineerà come la volontà di adottare un nuovo tipo di tecnologia comporti una revisione dei processi aziendali così come un cambiamento della cultura aziendale da diffondere sia internamente che esternamente.

In generale, gli sforzi e la diligenza necessarie a gestire un cambiamento sono direttamente proporzionali all'entità di quest'ultimo e per poterlo attuare è consigliabile rifarsi a un approccio strutturato, normalmente suddiviso in tre fasi:

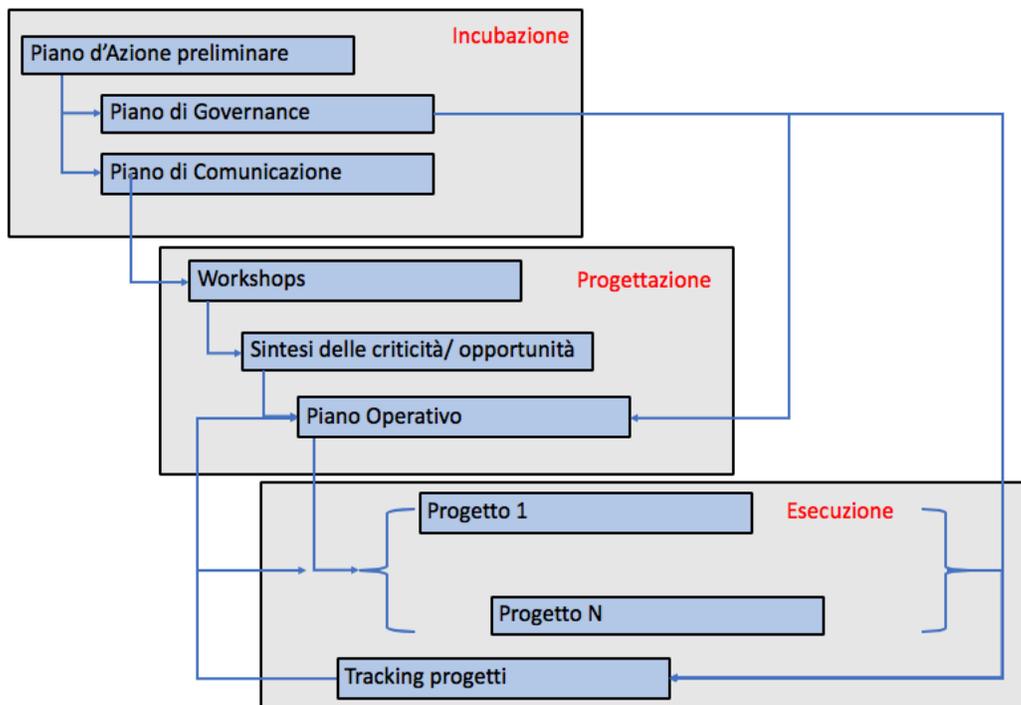


Fig.2.3.1: Macro-fasi e micro-fasi dell'approccio strutturato

- 1) **la fase di incubazione**, che rappresenta una bozza:
 - del Piano d'Azione che stabilisce gli obiettivi, l'approccio e l'ambito dell'intervento;
 - del Piano di Governance che decreta i meccanismi di partecipazione e di verifica dell'intervento;
 - del Piano di Comunicazione che sancisce il calendario delle iniziative, comprese quelle divulgative e di supporto.
- 2) **la fase di progettazione** comprende:
 - Workshops per coinvolgere il personale
 - Sintesi delle criticità/ opportunità individuate nei Workshops
 - Piano Operativo nel quale le sintesi del punto precedente vengono convogliate per poter delineare e descrivere nel dettaglio le azioni/ progetti e guidare la messa in opera del Programma.
- 3) **la fase di esecuzione** che contempla il lancio e l'attuazione dei singoli progetti, la loro verifica, la valutazione dei risultati e la preparazione di azioni correttive per assicurare la concretizzazione degli obiettivi.

2.4 Il cambiamento ed il ruolo del management nelle organizzazioni

Per poter implementare suddetto approccio, il dipartimento di Management svolge un ruolo cruciale. Una delle sue maggiori responsabilità riguarda l'identificazione precoce dei cambiamenti rilevanti riscontrati sia nell'ambiente interno che nell'ambiente esterno aziendale, così come l'impostazione tempestiva di programmi utili a guidare i cambiamenti o a contrastarli.

Un fattore da non tralasciare in qualsiasi tipo di trasformazione è l'impatto che avrà sul piano umano, sociale, dei processi e delle tecnologie. Ciò comporta ulteriori responsabilità come:

- la previsione delle reazioni che si manifesteranno in conseguenza alle trasformazioni;
- la convalida di azioni/progetti adeguati ad accompagnare/implementare la transizione;
- la preparazione dei dipendenti al nuovo assetto e l'agevolazione durante la fase di accettazione del cambiamento.

Inoltre, per quanto riguarda le operazioni di cambiamento avviate, sarà fondamentale la loro diffusione in profondità nell'organizzazione e il monitoraggio della loro efficacia effettuando delle eventuali modifiche. Oltretutto, un concetto chiave da tener a mente durante la gestione del cambio riguarda il fatto che la partecipazione all'interno di un'organizzazione deve essere intesa anche come condivisione, ovvero l'asserzione di una visione e di una strategia che vengono create, espone e accolte come le migliori possibili per quell'organizzazione in quel contesto e in quel dato momento.

2.5 Fonti di resistenza

Di seguito si elencano alcune delle fonti di resistenza note in letteratura circa la gestione del cambio:

- **Cambio degli individui:** se i membri dell'azienda non modificano il proprio atteggiamento e modo di operare, intervenendo anche su compiti e mansioni, è chiaro che il cambiamento a livello organizzativo non si potrà realizzare o si limiterà ad essere meramente formale.
- **Cultura organizzativa:** come afferma lo stesso Kotter, la cultura è l'aspetto più difficile da modificare in un'organizzazione e, dunque, nello sviluppo di un processo di cambiamento, è di certo più vantaggioso tenerne costantemente conto. Ancorare alla cultura i metodi più recenti dovrebbe essere l'ultimo passaggio.
- **Soggetti di etnie e culture differenti:** può essere un punto di forza nell'organizzazione, poiché permette a persone di formazione diversa di dare il proprio contributo nella risoluzione di problemi e nell'applicazione di nuove metodologie, ma, d'altro lato, può far insorgere inconvenienti a causa di incomprensioni fra figure appartenenti a svariate culture.

3. Stato dell'arte della gestione del cambio

Nel corso degli anni sono stati sviluppati un gran numero di modelli per gestire i cambiamenti. Un insieme di procedure e frameworks creati con l'intenzione di dare una mano alle organizzazioni e migliorare la loro risposta ai cambiamenti improvvisi e gradualmente.

Dunque, nel seguente capitolo dell'elaborato verrà analizzato lo stato dell'arte della gestione del cambio, soffermandosi sulle metodologie e modelli noti nella letteratura di suddetta disciplina.

3.1 Il modello di Lewin:

Risulta essere uno degli approcci più popolari soprattutto considerando la possibilità di suddividere il processo di cambio in tre stadi, rendendo dunque possibile la rottura di cambi ingombranti in parti più maneggevoli che riguardano sia i processi che i dipendenti di un'azienda.

1° stadio: Scongelo del processo e delle percezioni

Avviene dopo che l'azienda si è resa conto del bisogno di effettuare un cambiamento e dunque procede a scongelare il processo attuale per poter effettuare un'analisi dettagliata di ogni fase e interazione umana alla ricerca di potenziali miglioramenti. Questo tipo di analisi risulta assolutamente necessaria per

l'eliminazione di ogni tipo di pregiudizio e di errore comunemente accettato, dando la giusta prospettiva per cambiare la causa stessa dei problemi e non solo i sintomi.

Inoltre, suddetto scongelamento si riferisce anche alle percezioni aziendali circa il cambio imminente e quindi a una naturale resistenza ad esso. Considerando che solitamente i cambi repentini alimentano risentimento, preparare il team ad affrontarli risulta fondamentale. Oltretutto, il modello sottolinea il fatto che deve sempre risultare chiaro cos'è sbagliato nel processo corrente, come mai si deve cambiare, quali sono i cambi proposti e i benefici che apporteranno all'azienda per poter convincere i dipendenti e incoraggiarli ad aderire al nuovo processo.

2° stadio: Cambiamento

In questo stadio la comunicazione, il supporto e l'educazione risultano vitali, dato che si cerca di limitare qualsiasi tipo di difficoltà e di affrontare qualsiasi problema non appena si presenta. I dipendenti devono dunque sottostare a una formazione extra a seconda delle esigenze aziendali. Inoltre, è vitale avere una persona/ posto di riferimento per i dipendenti nel caso sia necessario un ulteriore supporto (per esempio un incontro regolare con il proprio mentore/ manager). E, per ultimo, è necessario comunicare regolarmente con i dipendenti per poter raccogliere il loro feedback e reagire con prontezza per risolvere i problemi evidenziati.

3° stadio: Ricongelamento

Dopo aver applicato i cambiamenti, si ricongela il nuovo status quo. Questo stadio è vitale in qualsiasi modello di Change Management, dato che le vecchie abitudini non possono riemergere.

Sono anche necessarie delle revisioni regolari per comprovare la corretta applicazione delle nuove metodologie, ricompensando coloro che seguono con costanza il cambiamento e che si sforzano a supportarlo.

Ovviamente, nel caso siano stati applicati i feedback raccolti in precedenza, il cambio in sé viene facilitato dato che i dipendenti si sentono più coinvolti. Poiché le loro opinioni sono state prese in considerazione, gli risulta naturale desiderare il successo del progetto. Oltre a ciò, qualsiasi nuova documentazione riguardante il cambio deve essere controllata e aggiornata fino a quando non diventa un'abitudine.

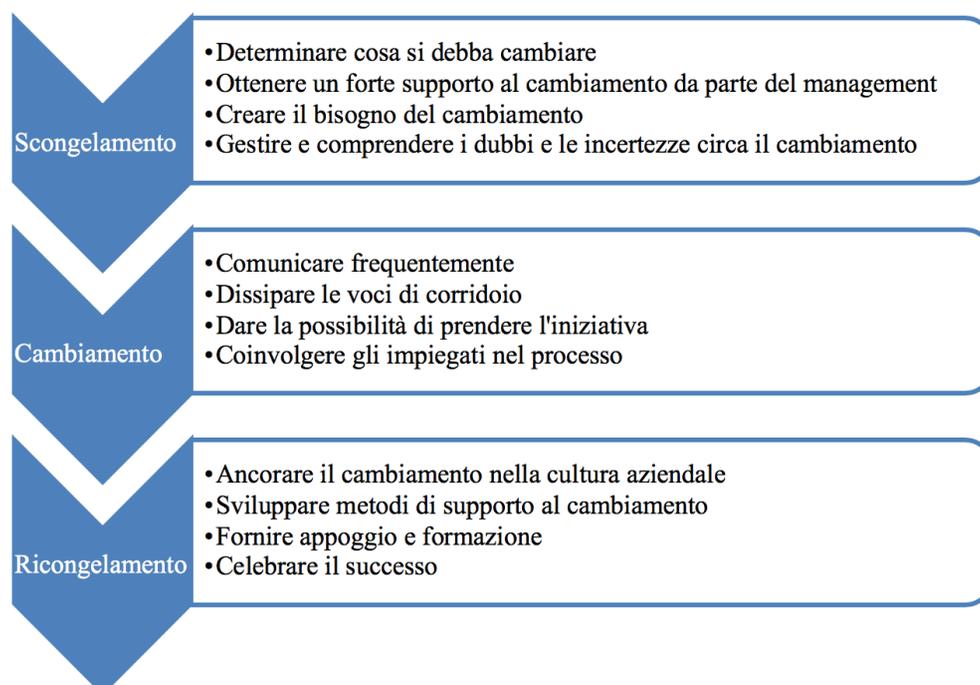


Fig.3.1.1: Fasi del modello di Lewin e descrizione delle diverse attività relazionate con ogni fase

Sicuramente, il modello di Lewin permette di trovare errori nascosti grazie alla profonda analisi richiesta. Risulta senz'altro una buona alternativa durante un Business Process Reengineering però potrebbe risultare complicato e richiedere molto tempo considerando la portata dello stadio di scongelamento e

dunque sfociare in un problema quando si eseguono dei cambiamenti piccoli dato che non permette di sfruttare in maniera efficiente le risorse aziendali.

Oltretutto, essendo un modello adatto ai cambiamenti su larga scala, potrebbe comportare un'alienazione da parte dei dipendenti, dato che il processo originale viene cambiato drasticamente. Dunque, sicuramente è un modello da considerare nel caso si voglia stravolgere completamente il processo esistente, prestando però particolare attenzione alle fasi iniziali del modello e mantenendo l'entusiasmo dei dipendenti soprattutto nella fase di ricongelamento.

3.2 Il modello ADKAR

Creato da Jeffrey Hiatt, è alla base della metodologia di Prosci che verrà descritta nelle seguenti pagine. Il modello ADKAR consiste in un set di obiettivi da raggiungere per poter implementare con successo un cambiamento sia a livello individuale che a livello aziendale. Ognuno di essi forma l'acronimo ADKAR:

- **Awareness:** consapevolezza della necessità di un cambio
- **Desire:** desiderio di partecipare e supportare il cambio
- **Knowledge:** conoscenza su come effettuare il cambio
- **Ability:** abilità per implementare le competenze richieste
- **Reinforcement:** sostegno per il cambio

Awareness

Detta anche fase di sensibilizzazione, consiste nel far raggiungere la consapevolezza agli individui circa la necessità di un cambiamento. Solitamente, vengono organizzate delle riunioni aziendali dove si sottolinea lo stato attuale delle cose e in che modo le modifiche proposte potrebbero giovare all'azienda. La principale difficoltà riguarda il fatto che il cambiamento difficilmente viene accettato senza che gli individui creino dei problemi e, per questo motivo, risulta fondamentale giustificarlo utilizzando prove concrete e dati solidi. In realtà, il fatto stesso di dover giustificare il cambio comporta una prima scrematura che evidenzia quali azioni sembrino corrette e quali no.

Desire

È considerato l'obiettivo più difficile da ottenere dato che fa appello sia al lato logico che a quello emotivo dei dipendenti, entrambi necessari per acquisire quella dedizione totale utile a implementare la modifica. Uno dei metodi migliori per accrescere il desiderio è la promozione dei benefici del cambiamento rilevanti per gli individui coinvolti. Ciò è ottenibile fornendo esempi reali degli scenari post-cambiamento e confrontandoli con la situazione corrente, ascoltando i feedback e implementando qualsiasi consiglio utile per condividere la responsabilità nella creazione del cambiamento.

Knowledge

Si assicura che tutti gli individui coinvolti nel cambio sappiano come sarà effettuato e nello specifico come dovranno svolgere i propri compiti. Dunque, si tende a suddividere il cambiamento in diversi passaggi per analizzare la conoscenza utile ai vari dipendenti per poterli completare.

Ability

Considerando che il tempo necessario che trascorre dall'acquisizione della conoscenza alla sua applicazione vera e propria può essere immenso, vi è un effettivo divario tra il sapere come si effettua un compito all'essere oggettivamente bravi a svolgerlo. È dunque necessario verificare le capacità di ciascun

dipendente e valutare se necessita di esperienza e/o conoscenza extra al fine di completare in modo affidabile i propri compiti.

Vi sono metodologie per ridurre suddetto divario come la creazione di un processo documentato facilmente eseguibile, indipendentemente dal set di competenze o dall'esperienza che rende le modifiche eseguite più coerenti e misurabili, dato che la maggior parte delle variabili può essere bloccata in uno stato costante.

Reinforcement

Con il termine 'Rinforzo' si intende l'implementazione di incentivi e premi per assicurarsi che il cambiamento venga mantenuto fino a quando non si converte in una nuova norma. Durante questa fase si cerca di identificare gli errori il prima possibile, cercando di impedire che un metodo imperfetto diventi la normalità per i dipendenti.

Pertanto, il modello ADKAR si focalizza sui dipendenti aumentando la velocità con cui i cambiamenti vengono implementati in maniera affidabile e di conseguenza portando a una maggiore percentuale di successo delle modifiche apportate. Risulta un framework flessibile dato che fornisce un set di obiettivi applicabili a quasi ogni situazione appartenente alla realtà aziendale.

Inoltre, suddetta flessibilità lo rende ideale per implementare cambi incrementali, che risultano così meno dirompenti e pianificabili in modo tale da ottenere un cambiamento maggiore attraverso vari cicli ADKAR.

3.3 Prosci Enterprise Change Management

Descrive i diversi livelli di capacità di gestione del cambiamento all'interno delle organizzazioni tramite una metodologia chiamata Modello di maturità. Consta di cinque livelli, ognuno con un livello differente di attenzione e gestione del cambiamento dal punto di vista delle persone.

Questa diversificazione è dettata dal fatto che la letteratura della gestione del cambiamento ha dimostrato che un approccio "taglia unica" non funziona, poiché ogni modifica e ogni gruppo interessato è differente. Tuttavia, una metodologia comune costruita sulla consapevolezza circa la situazione e sulla personalizzazione consente all'intera organizzazione di spostarsi di livello in livello mantenendo la flessibilità nei singoli dipartimenti.

In seguito, vengono descritte le varie fasi e i passi da intraprendere per passare dal livello 1 al livello 5 del modello.

Livello 1:

Al Livello 1 del modello di maturità, i teams coinvolti nel progetto di cambiamento non sono consapevoli e non considerano la gestione del cambiamento come un approccio formale. I progetti a questo livello possono avere una o più delle seguenti caratteristiche:

- La leadership del progetto si concentra solo sugli aspetti "concreti" o tangibili del progetto, compresi il finanziamento, la pianificazione, il rilevamento dei problemi e la gestione delle risorse.
- Le comunicazioni da parte delle risorse coinvolte nel progetto sono in genere poco frequenti.
- I dipendenti scoprono il cambiamento attraverso voci e pettegolezzi, piuttosto che attraverso delle presentazioni strutturate.
- Il sostegno esecutivo rimane quasi in sottofondo ed è reso noto solo attraverso l'autorizzazione del finanziamento e l'allocazione delle risorse, ma non vi è una sponsorizzazione attiva e visibile.
- I supervisori e i managers hanno poche o praticamente nessuna informazione sul cambiamento e non hanno competenze necessarie per istruire i dipendenti attraverso il processo di cambiamento.
- I dipendenti reagiscono al cambiamento con sorpresa e la resistenza può essere diffusa.

- La produttività rallenta e il turnover aumenta man mano che il cambiamento si avvicina alla piena implementazione.

Di norma, questo livello viene utilizzato come ultima risorsa quando la resistenza dei dipendenti mette a repentaglio il successo del progetto. Inoltre, non si assiste a nessuna integrazione della gestione del cambio con la gestione del progetto all'inizio del progetto stesso.

Secondo la metodologia, per poter passare al livello successivo, si devono seguire i seguenti passaggi:

- 1) Partecipare ad eventi di formazione per la gestione del cambiamento, acquisire risorse per una sua gestione o coinvolgere consulenti che siano esperti del campo.
- 2) Applicare la gestione del cambiamento a dei progetti isolati. Dunque, utilizzare le tecniche di gestione del cambio per dare una spinta a quei progetti che si trovano in difficoltà proprio a causa di una resistenza al cambiamento.

Livello 2:

Iniziano ad emergere degli elementi di gestione del cambio ma solamente in parti isolate dell'organizzazione. Inoltre, l'impegno nella gestione delle persone durante il cambio risulta poco frequente, raro e non centralizzato. Le caratteristiche di questo livello sono:

- L'esistenza di una grande varietà di pratiche di gestione del cambiamento tra i vari progetti aziendali con una moltitudine di approcci differenti della gestione del cambio applicati sporadicamente in tutta l'organizzazione; alcuni progetti potrebbero riuscire a gestire efficacemente il cambiamento mentre altri si trovano ancora nel Livello 1.
- La presenza di elementi per pianificare la comunicazione, ma con poca sponsorizzazione o formazione all'interno dell'organizzazione circa la gestione del cambiamento.
- La mancanza di una formazione formale sulla gestione del cambiamento per i managers e i supervisori per poter istruire i propri dipendenti durante il processo di cambiamento.
- La gestione del cambio viene utilizzata per contrastare un evento negativo.
- Una scarsa interazione tra i gruppi coinvolti nella gestione del cambio: ogni nuovo progetto deve "riapprendere" le competenze basilari di gestione del cambiamento.

Nel Livello 2, la gestione del cambio non è completamente integrata nella gestione del progetto però nei progetti dove è coinvolta, i teams sono consapevoli di che cosa essa sia. In alcuni casi, un difensore della gestione del cambio può incoraggiare l'integrazione di quest'ultimo con la gestione dei progetti.

Per poter passare al livello successivo, si devono seguire i seguenti passaggi:

- 1) Creare una base di conoscenza circa le diverse iniziative di gestione del cambiamento utilizzate nell'organizzazione e avviare ricerche sulle migliori pratiche di gestione del cambiamento.
- 2) Creare cluster di gruppi che applichino i principi di gestione del cambiamento ed iniziare la raccolta di conoscenze e strumenti in tutta l'organizzazione.
- 3) Celebrare i successi collegati alla gestione del cambiamento.
- 4) Iniziare a costruire un supporto per l'utilizzo della gestione del cambiamento con dirigenti e senior leaders che supervisionano più progetti.

Livello 3:

Emergono alcuni gruppi che iniziano a utilizzare un processo di gestione del cambiamento strutturato, che rimane comunque presente solo in particolari gruppi o aree dell'organizzazione. Le organizzazioni a questo livello possono avere una o più delle seguenti caratteristiche:

- I processi di gestione delle modifiche strutturati vengono utilizzati in più progetti con molteplici approcci e metodologie.
- I gruppi iniziano a condividere alcune parti della propria conoscenza in alcuni dipartimenti o divisioni.

- Nonostante la gestione delle modifiche sia applicata più frequentemente, non esistono standard o requisiti organizzativi.
- Gli alti dirigenti assumono un ruolo più attivo nella sponsorizzazione del cambiamento e considerano questo nuovo ruolo come parte delle proprie responsabilità, ma non esiste un programma formale a livello aziendale per addestrare i leaders, i managers o i coaches sulla gestione del cambiamento.
- Formazione e strumenti diventano disponibili per i responsabili dei progetti e i membri dei gruppi; i managers ricevono formazione e gli strumenti necessari per istruire i dipendenti di prima linea sui futuri cambiamenti.

In questo livello la gestione del cambiamento si utilizza all'inizio di alcuni progetti, sebbene la maggior parte delle volte sia utilizzata più che altro per reagire alla resistenza dei dipendenti durante l'implementazione. Inoltre, la pianificazione della comunicazione è integrata nella fase di pianificazione. Per poter passare al livello successivo, si devono seguire i seguenti passaggi:

- 1) Reclutare il supporto esecutivo per applicare la gestione del cambiamento ad ogni progetto e per costruire competenze di cambiamento a tutti i livelli dell'organizzazione.
- 2) Selezionare una metodologia comune che possa essere utilizzata in tutta l'organizzazione ed iniziare ad acquisire gli strumenti e la formazione necessari per implementare una metodologia comune.

Livello 4:

L'organizzazione seleziona un approccio comune e implementa gli standards per l'utilizzo della gestione del cambio su ogni nuovo progetto tramite gli strumenti appropriati per ogni cambio specifico. Le organizzazioni a questo livello possono avere una o più delle seguenti caratteristiche:

- Riconoscimento a livello aziendale su cosa sia la gestione del cambio e sul motivo per cui è importante che abbia successo.
- Selezione di una metodologia di gestione del cambiamento comune ed elaborazione di piani per l'introduzione della metodologia nell'organizzazione.
- Formazione e strumenti disponibili per i dirigenti, gruppi, leaders del cambiamento, managers e supervisor. Oltretutto, i dirigenti e i supervisor ricevono una formazione formale sulla gestione del cambiamento.
- La possibilità di creare un gruppo funzionale per supportare iniziative di cambiamento, con ruoli come "Director of Change Management". In questo livello, le organizzazioni tendono a creare un "centro di eccellenza" - individui, gruppi o posizioni amministrative dedicate a sostenere gli sforzi di gestione del cambiamento e sviluppare abilità di gestione del cambiamento.
- I dirigenti assumono il ruolo di sponsor del cambiamento in ogni nuovo progetto.
- Resistenza e non conformità sono previste solamente in casi isolati dato che alcuni gruppi non comprendono ancora per quale motivo si stia usando la gestione delle modifiche. L'adozione non è ancora al 100% e lo sviluppo di competenze di gestione del cambiamento in tutta l'organizzazione è un work-in-progress.

Inoltre, a questo livello i gruppi utilizzano regolarmente un approccio di Change management sin dall'inizio del loro progetto. Dunque, la gestione del cambiamento inizia direttamente già nella fase di pianificazione del progetto. Oltretutto, la gestione dei progetti e delle modifiche sono integrate dall'inizio, a tal punto da risultare inseparabili. Per poter passare al livello successivo, si devono seguire i seguenti passaggi:

- 1) Creare una posizione formale o un gruppo formato da un personale responsabile per un'efficace implementazione, formazione e miglioramento delle competenze di gestione del cambiamento.
- 2) Correggere la non conformità analizzando le parti dell'organizzazione che non applicano la metodologia selezionata e sviluppando piani per implementare dei miglioramenti e facilitare l'applicazione della metodologia.

Livello 5:

Le competenze di Change management sono parte del set di competenze dell'organizzazione. Le organizzazioni a questo livello possono avere una o più delle seguenti caratteristiche:

- La gestione efficace del cambiamento è un obiettivo strategico dichiarato esplicitamente e che i dirigenti aziendali hanno reso una priorità.
- Tutti i dipendenti comprendono la gestione del cambiamento, per quale motivo ne è importante il successo e in che modo svolgono un ruolo nel successo del cambiamento.
- Il cambio di gestione è così comune da risultare quasi inseparabile dalle iniziative aziendali.
- I managers e i supervisori utilizzano regolarmente tecniche di gestione delle modifiche per supportare un'ampia gamma di iniziative, dai cambiamenti di strategia al miglioramento dei singoli dipendenti.
- L'organizzazione raccoglie dati per consentire miglioramenti continui alla metodologia, agli strumenti e alla formazione della gestione del cambio.
- Esiste una formazione approfondita a tutti i livelli dell'organizzazione.
- Maggiore ROI, minore perdita di produttività e resistenza dei dipendenti sono evidenti in tutta l'organizzazione.

In questo caso, la gestione del cambio inizia addirittura prima dell'inizio dei vari progetti aziendali. Inoltre, quando le organizzazioni sviluppano un alto livello di competenza nella gestione del cambiamento, i passaggi volti ad implementare il cambio risultano completamente integrati nella gestione del progetto. Le fasi di pianificazione e progettazione contengono sia elementi di gestione del progetto che di modifica e sono viste come una prassi.

Livello 5	Competenza organizzativa	La competenza della gestione del cambio è evidente in ogni livello della compagnia ed è parte della sua proprietà intellettuale e del suo vantaggio competitivo	Miglioramento continuo del processo	Redditività e risposta più elevate
Livello 4	Standards organizzativi	Standards e metodi diffusi a livello dell'organizzazione largamente utilizzati per gestire e dirigere il cambio	Selezione di approcci comuni	↑ ↓
Livello 3	Multipli progetti	Approccio completo per gestire il cambio applicato a multipli progetti	Esempi di pratiche migliori evidenti	
Livello 2	Progetti isolati	Alcuni elementi della gestione del cambio sono applicati in progetti isolati	Tattiche diverse usate in modo discordante	
Livello 1	Adhoc o assente	Poco o nessun tipo di gestione del cambio viene applicata	Dipende dalle persone senza nessun tipo di pratica formale o piano	Alto tasso di fallimento del progetto, turnover e perdita di produttività

Fig.3.3.1: descrizione livelli metodologia Prosci

Dunque, per una corretta applicazione del modello, risulta fondamentale comprendere qual è il livello di maturità della propria azienda e uno dei metodi più utilizzati per individuarlo è un questionario. Questo compito potrebbe risultare oneroso dal punto di vista delle tempistiche, però vi è la possibilità di affidarsi a delle società di consulenza che possiedono dei questionari ad hoc basati su diverse aree di competenza.

A livello informativo, in letteratura sono presenti questionari basati sulle seguenti aree:

- **Leadership:** fa riferimento allo sforzo effettuato per creare le competenze e le capacità utili alla gestione del cambio.

- **Applicazione:** si focalizza sull'utilizzo di processi, strumenti e principi della gestione del cambio in determinati progetti ed iniziative.
- **Competenze:** si concentra sul set di abilità e competenze presenti nell'organizzazione a partire dagli alti dirigenti fino ad arrivare ai dipendenti di prima linea.
- **Standardizzazione:** fa riferimento all'adozione di approcci e strumenti comuni.
- **Socializzazione:** si concentra sulla costruzione del buy-in e dell'impegno dei dipendenti verso la gestione del cambiamento in tutta l'organizzazione.

Oltretutto, l'utilizzo del modello PROSCI dipende dalle esigenze dell'azienda dato che risulta utile come:

- **Strumento di comunicazione** nell'organizzazione poiché facilita la diffusione della situazione corrente e futura a tutti gli individui dell'organizzazione.
- **Framework** per la costruzione di un programma di gestione del cambio.
- **Meccanismo di supporto** per gli sforzi di miglioramento continuo.
- **Strumento per parlare con i dirigenti** poiché dimostra ai leaders l'importanza della gestione del cambio, il loro ruolo di sponsors e la necessità di allocare le risorse necessarie a trattare con le persone per gestire il cambio.
- **Strumento di standardizzazione** della gestione del cambio in tutta l'organizzazione.
- **Strumento strategico** a supporto degli obiettivi dell'organizzazione.

3.4 Boston Consulting Group (BCG) Change Delta

Deriva da una moltitudine di studi su programmi di cambio di dimensioni rilevanti in aziende provenienti da ogni parte del mondo. L'obiettivo dell'enorme studio dietro a suddetto modello è lo sviluppo di un approccio più efficace al cambio riducendone i rischi e assicurando praticamente un buon risultato.

Si tratta di una metodologia del cambio, attuabile attraverso la tecnologia, che affronta cambi operativi e organizzativi così come i comportamenti che influenzano i risultati del programma e che risultano critici per il suo successo. In concreto, BCG ha sviluppato un delta di cambio formato da quattro componenti fortemente indipendenti, che nel loro insieme ottimizzano la struttura del programma di gestione del cambio e la sua implementazione.

Certeza dell'esecuzione:

Approccio utilizzato nella gestione degli elementi coinvolti in un programma di cambiamento di larga scala, che porta alla trasparenza sul loro stato attuale e ai progressi rispetto agli obiettivi, aiutando i leaders ad intraprendere azioni tempestive e decisive nella correzione delle problematiche aziendali.

Data la complessità dei programmi di cambiamento su larga scala, la loro supervisione e implementazione risulta una vera e propria sfida per i leaders senior. Questa sfida può essere superata tramite la certezza dell'esecuzione - una serie di attività volte a fornire ai leaders senior una chiara comprensione degli scopi di ciascuna iniziativa, delle intuizioni operative e delle relazioni periodiche sui progressi così da poter identificare in anticipo le varie problematiche e poterle risolvere rapidamente.

In generale, le attività sono le seguenti:

- Valutare in anticipo la progettazione delle iniziative e il modo in cui i gruppi sono costituiti.
- Massimizzare la comprensione delle tappe fondamentali e degli impatti previsti.
- Fornire indicatori lungimiranti che sollecitano correzioni tempestive.
- Per evitare di sovraccaricare gli alti dirigenti, si riportano solo le informazioni più critiche dando loro una panoramica dei progressi e fornendogli gli strumenti per agire in modo rapido e decisivo.

Sono disponibili vari strumenti per facilitare la certezza dell'esecuzione:

1. **DICE** utile per valutare le prospettive e i rischi inerenti a qualsiasi sforzo di cambiamento: utilizza un precedente empirico per valutare ogni iniziativa del gruppo, piano di lavoro complessivo e altri fattori di successo.
2. **Rigor Testing** è un processo utile per misurare la solidità e la coerenza di un'iniziativa proposta testando la chiarezza e la specificità dei suoi piani.

3. **RPM** che garantisce un efficiente monitoraggio e segnalazione dei progressi di un programma e aiuta a guidare le decisioni dei dirigenti senior. In altre parole, rafforza il loro potere organizzativo con dei suggerimenti operativi.

Oltretutto, dei rapporti regolari sui progressi consentono agli alti dirigenti di affermare ed incoraggiare quando si hanno degli esiti positivi o di apportare delle correzioni. Una componente cruciale del RPM è la tabella di marcia dell'iniziativa, che caratterizza ogni iniziativa elencandone gli elementi essenziali: da 5 a 20 pietre miliari, i principali rischi, le interconnessioni e gli indicatori di rilevamento precoce.

Suddetta tabella di marcia risulta utile nel mantenere il gruppo focalizzato e motivato, e chiarisce la responsabilità di ogni membro del gruppo in modo tale che tutti i partecipanti siano coscienti delle conseguenze delle loro azioni tempestivamente.

In generale, la certezza dell'esecuzione garantisce che il programma di cambiamento sia impostato per avere successo fin dall'inizio, applicando la prima e più fondamentale regola di Smart Simplicity - capire cosa le persone effettivamente fanno - per monitorare i progressi e identificare i cambiamenti nel comportamento utili a riportare i cambiamenti sulla retta via (nel caso fosse necessario).

Sponsorizzazione, Governance, e il Program Management Office (PMO):

La supervisione formale del programma di cambiamento, chiamata governance, è in genere responsabilità di due entità: lo sponsor o l'insieme di sponsor e il PMO.

Nel caso di un cambiamento a livello aziendale, è probabile che lo sponsor sia l'amministratore delegato, mentre per un programma di cambiamento progettato per un'unità aziendale o una divisione, lo sponsor sarà probabilmente il capo di tale unità o divisione. La sua responsabilità ultima è il raggiungimento e il sostegno della trasformazione per cui è stato progettato il programma.

È spesso supportato da un comitato direttivo, come un gruppo di dirigenti seniors convocati per questo scopo o il gruppo dirigente senior dell'organizzazione o della unità di business.

È lo stesso sponsor a dare potere al PMO e ai leaders dell'iniziativa, controllando che il PMO sia completamente allineato con la sua visione in modo che il gruppo di governance nel suo complesso parli con una sola voce e sia chiaramente visto come unificato.

Per quanto riguarda il PMO, il suo compito riguarda la supervisione operativa del programma, infatti quest'ultimo si assicura che ogni iniziativa sia adeguatamente costituita, dotata di risorse e organizzata per il successo. In qualità di amministratore del valore, il PMO:

- Promuove la cooperazione all'interno dell'organizzazione per supportare il programma di cambiamento.
- Aiuta ad allineare tutte le iniziative, ne monitora i progressi e mantiene informati gli sponsors e i dirigenti senior in modo che possano agire tempestivamente quando necessario.

Nel caso sorgano problemi, si assicura che avvengano le conversazioni appropriate e che i leaders comprendano le proprie responsabilità e abbiano gli strumenti necessari per attuarle.

Oltretutto, il leader del PMO potrebbe anche essere coinvolto nella progettazione del programma generale e nella scelta della miscela di iniziative maggiormente in grado di raggiungere gli obiettivi del programma.

Leaders attivi:

Un gruppo di leadership esteso con strumenti per sponsorizzare e gestire gli sforzi per il cambiamento in maniera efficace. Suddetto team è normalmente composto dal CEO, da chi rapporta direttamente al CEO, da chi rapporta a quest'ultimi e dai managers appartenenti al livello 4 e 5 (nelle grandi organizzazioni, può essere formato dai top 150 senior managers). Il suo supporto è cruciale per il completamento del programma e data la sua vicinanza ai dipendenti, si trova nella posizione migliore per coinvolgerli verso il raggiungimento degli obiettivi. Oltretutto, i dipendenti di solito reagiscono meglio ai propri supervisori rispetto che a dei leaders senior che ritengono più distanti.

Pertanto, per riuscire ad ottenere i benefici di suddetto team, un suo coinvolgimento già dalle fasi iniziali risulta vitale per il successo del programma.

Organizzazione coinvolta:

I dipendenti appartenenti a ogni livello comprendono il cambiamento e sono pronti, volenterosi e capaci di gestirlo. Un programma di cambio fa molto affidamento sul consenso dei dipendenti e il punto di inizio per la creazione e il mantenimento del loro coinvolgimento è una ponderata ed efficace comunicazione. Quest'atto di comunicazione deve inoltre essere ripetuto e consolidato. Per quanto un programma di cambio sia eccellente, molto probabilmente sprofonderà se i partecipanti sono mal informati o poco convinti sulla sua rettitudine. Inoltre, si deve considerare che comunicare significa anche ascoltare e non solo parlare. Dunque, la comunicazione dovrà essere bidirezionale tramite dei feedbacks.

Il delta di cambio risulta essere un modello efficace se utilizzato sviluppando il programma di cambio in maniera rigorosa, controllando e tenendo in conto i feedbacks per assicurarsi che vengano rispettate le tempistiche e il budget.

Con questo modello le ambizioni chiave di qualsiasi programma di cambiamento vengo soddisfatte, cioè:

- Ottenere miglioramenti sostenibili delle prestazioni (senza interruzioni indebite).
- Consentire a quante più persone possibile di sperimentare il cambiamento nel modo più positivo possibile.
- Costruire la capacità per un cambiamento ancora più audace.

Inoltre, il suo valore deriva dal fatto che si occupa della gestione di un programma di cambio piuttosto che di un progetto individuale assicurandosi che ogni dipendente non sia solamente allineato con gli obiettivi e le norme del programma, ma che abbia anche dei motivi per dedicarsi ad essi, così da prendere decisioni corrette ed agire con efficienza.



Fig.3.4.1: Rappresentazione Delta del cambio di BCG

4. Riprogettazione del processo di Acquisto

Nel seguente capitolo si introduce brevemente l'azienda presso la quale si è svolta la tesi (MANGO) e il progetto di gestione del cambio IT denominato Trasformazione Hangar. Dopodiché, ci si sofferma su come MANGO abbia raggiunto la consapevolezza della necessità di suddetto cambio e si ripercorrono i passi eseguiti nella Riprogettazione del processo di acquisto: dal processo attuale (AS-IS) al suo imminente cambiamento (TO-BE).

4.1 Descrizione dell'azienda

MANGO è un'azienda multinazionale che si dedica alla progettazione, produzione e commercializzazione di abbigliamento ed accessori seguendo le ultime tendenze della moda.

Le sue origini risalgono agli anni '80 quando Isak Andic, il suo fondatore, insieme al fratello Nahman incominciarono a vendere vestiti importati dalla Turchia a Barcellona.

Fin dalla sua creazione, è stata considerata una marca di moda pioniera nel settore online dato che creò la sua prima pagina web corporativa nel 1995 e che nel 2000 iniziò a mettere a disposizione della propria clientela anche la possibilità di comprare direttamente online.

Con il passare degli anni si è espansa ulteriormente ottenendo un'influenza globale con 2.150 negozi in 113 paesi.

Attualmente, MANGO possiede quattro linee di abbigliamento: Donna, Uomo, Bambino e Violeta (per taglie importanti). La loro commercializzazione avviene tramite tre canali differenti:

- Negozi di proprietà dell'impresa
- Negozi in franchising:
 - o Deposito: dove la mercanzia non venduta, viene restituita a MANGO
 - o Firms: dove la mercanzia non venduta rimane al negozio
- MANGO Online

4.2 Progetto Trasformazione Hangar

Da due anni a questa parte in MANGO ha avuto inizio un progetto, denominato Trasformazione Hangar, il cui obiettivo riguarda la digitalizzazione dell'organizzazione eseguendo una re-ingegnerizzazione dei processi aziendali e focalizzandosi in primis sul processo di acquisto, che ha inizio con la creazione dei prodotti e termina con la loro importazione tramite i fornitori. Il fine ultimo di suddetta trasformazione è una rivoluzione del sistema informatico aziendale attraverso l'implementazione dell'ERP SAP.

Per poterlo conseguire l'azienda ha deciso di utilizzare la metodologia PROSCI menzionata nel capitolo 3 posizionandosi nel livello 2 di maturità. Infatti, nonostante il progetto di Trasformazione Hangar sia molto avanzato in termini di strategia e tecniche utilizzate, la gestione del cambio è comunque ristretta a questo progetto e alcuni altri. Non è dunque presente un approccio globale per la gestione dei molteplici progetti aziendali.

Questo livello di maturità così basso è una diretta conseguenza della resistenza a livello culturale e di individui che l'azienda deve affrontare. Gli impiegati sono restii al cambio, non si sentono abbastanza motivati dalle novità apportate da SAP e anzi ritengono che il software possa ostacolare ulteriormente il loro lavoro aggravandolo.

4.3 Consapevolezza della necessità di un cambio IT

Una premessa importante riguarda il fatto che l'ERP utilizzato finora è stato realizzato su misura nell'arco degli ultimi 25 anni utilizzando il linguaggio di programmazione chiamato COBOL. Con la rapida crescita organica dell'azienda, anche l'ERP è cresciuto, espandendosi senza troppa pianificazione. Al giorno d'oggi continuare ad utilizzare COBOL risulta insostenibile per il mantenimento dell'azienda, la sua futura espansione e digitalizzazione del business online.

Da quattro anni a questa parte, si è deciso di cambiare l'ERP scritto in COBOL con un altro globalmente riconosciuto e approvato dal mondo aziendale, cioè SAP. I motivi che hanno portato alla scelta di questo software sono stati i seguenti:

- Riconoscimento del software a livello globale;
- Obbligo a standardizzare molti processi;
- Robustezza del software a livello di supply chain.

Pertanto, qualche anno fa, MANGO ha implementato SAP nella parte finanziaria e ultimamente ha deciso di estenderne l'utilizzo a tutta la supply chain aziendale. Questa decisione cambiamento comporta dunque una revisione dei processi aziendali con l'obiettivo di renderli più efficienti ed agili. Suddetta revisione viene facilitata tramite l'utilizzo di una metodologia chiamata Riprogettazione dei processi che verrà descritta nelle seguenti pagine.

4.4 Riprogettazione dei processi (*Process Reengineering*)

La Riprogettazione dei processi è un concetto emerso nei primi anni 90 che sostanzialmente può essere definito come un “*Ripensamento e riprogettazione radicale dei processi per raggiungere un miglioramento sostanziale nella performance.*” È un intervento di ristrutturazione organizzativa, volto a ridefinire i processi aziendali, per favorire l’introduzione di nuove tecnologie o la sostituzione di vecchie e pertanto risulta utile a MANGO per l’implementazione di SAP.

Nella sua applicazione è preferibile seguire un approccio strutturato come illustrato nella seguente figura (Fig.4.4.1). Anzitutto, è necessario comprendere su quale processo in concreto focalizzarsi per poi scoprirne le varie fasi descrivendo il processo così com’è (AS-IS). Successivamente, si esegue un’analisi del processo mappato, focalizzandosi sulle debolezze riscontrate e il loro impatto per poter realizzare una riprogettazione del processo ed arrivare alla mappatura del processo ideale (TO-BE). Dopo la sua implementazione, si controlla nuovamente il processo applicando eventuali correzioni fino ad ottenere delle prestazioni soddisfacenti.

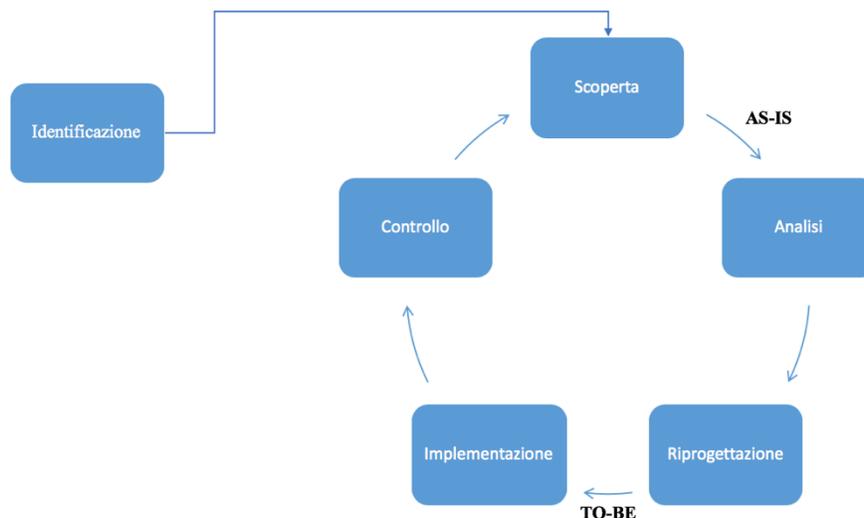


Fig.4.4.1: rappresentazione flusso della Riprogettazione dei processi.

4.5.1 Identificazione del processo di acquisto:

Come già accennato, nel caso del progetto di Trasformazione Hangar, l’azienda ha deciso di soffermarsi sul processo di acquisto dato che cronologicamente risulta essere il primo processo aziendale. Suddetto processo ha inizio con la creazione di prototipi (che possibilmente formeranno parte della nuova collezione), la loro selezione, la scelta dei fornitori e l’invio del prodotto finito da parte di quest’ultimi.

4.5.2 Scoperta del processo:

Nella fase di scoperta del processo risulta necessario effettuare dei workshops mirati alla comprensione del processo. MANGO ha dunque riunito esperti delle varie aree del processo così come il dipartimento di Trasformazione Hangar (per lo più formato da dipendenti IT ed esperti in gestione del cambio) per eseguire suddetti workshops. Ha dunque analizzato ogni fase del processo di acquisto annotando le osservazioni degli esperti per creare una bozza del processo da re-inviare agli esperti per ottenere dei feedback ed eseguire le dovute correzioni.

4.5.3 Mappatura processo AS-IS

Il risultato dei workshops effettuati dall'azienda si riscontra nella mappa di flusso presente nell'Appendice.

La prima attività nel processo di acquisto riguarda la **Decisione di acquisto**: quali fabbriche produrranno i vari modelli, quali sono gli attributi di ogni modello (lunghezza, larghezza, se ha delle maniche o no e come sono, etc.) e quante unità verranno comprate da diversi canali di commercializzazione di MANGO. Successivamente, si svolgono 3 attività in contemporanea: **Aggiudicazione del fornitore**, **CSBD** e **Composizione**.

Nell fase di **Aggiudicazione del fornitore** si prendono delle decisioni finali circa:

- Fornitori che produrranno i modelli;
- Prezzi d'acquisto;
- Paese di origine dei modelli;
- Porto di spedizione;
- Nomenclatura Incoterm, utilizzata nel campo dell'import e export, che definisce in modo univoco ogni diritto e dovere competente ai soggetti coinvolti in un'operazione di trasferimento di beni da una nazione ad un'altra;
- Data di trasporto/pagamento/arrivo dei modelli;
- Magazzino di destinazione.

Con l'attività chiamata **CSBD** si decide qual è la curva di taglie da acquistare, cioè per ogni modello quante taglie è necessario acquistare. Inoltre, si decide anche la quantità di prodotti con marchio Mango/MNG da acquistare. La tematica del marchio Mango/MNG è fondamentale dato che quando l'azienda importa prodotti in alcuni paesi come la Colombia deve prestare attenzione a cambiare il nome del marchio in MNG per una questione di licenze per evitare di incorrere in multe salate.

Con la fase di **Composizione** il fornitore invia le informazioni riguardanti la composizione e percentuale di tipo di tessuto dei modelli (cotone, lino...). La composizione è fondamentale per una questione di import/ export dato che in alcuni paesi sono proibiti certi tipi di materiali.

L'insieme di queste tre attività comporta la creazione di un **Ordine** che viene inviato al fornitore. Qui la mappa di flusso si divide in due parti differenti a seconda degli attori coinvolti:

Con MANGO si passa all'attività di **Invio istruzioni al fornitore circa l'imballaggio dei modelli** e di **Calcolo del costo standard** per iniziare ad avere un'idea dei costi finanziari della produzione.

Si ha dunque la creazione di **Colli standard**, basata sul calcolo di un algoritmo chiamato Barcelogic che identifica il numero di colli, le loro dimensioni e le quantità di prodotti per ogni collo.

Dal punto di vista del fornitore, una volta ricevuto l'ordine, si decide quale fabbrica realizzerà un determinato modello creando dunque una **Relazione fabbrica/modello** e in contemporanea MANGO **Pianifica l'audit di rischio RSC**, cioè il rischio legato alla responsabilità sociale corporativa (ad esempio si controlla che nelle fabbriche dove si realizzeranno i prodotti non lavorino dei bambini).

Successivamente, il fornitore realizza una pianificazione inversa della produzione tenendo conto della data di consegna, denominato **Critical Path** che necessita della **Conferma da parte di MANGO**.

Una volta approvata la pianificazione inversa, il fornitore esegue la **Previsione della produzione** che si divide in 2 tragitti differenti:

- 1) Confronto della realtà con il tragitto critico per vedere se vi sono stati dei cambi rispetto alla **Produzione reale** dei prodotti per poi effettuare una **Ispezione di qualità**. Il tutto eseguito da MANGO.
- 2) **Acquisto delle etichette dei prodotti**, controllo **GB** (test sulla composizione dei prodotti necessario per poter vendere in Cina) e **Acquisto dei componenti** (esterni al prodotto e usati per imballarlo, come il cartone per le camicie).

Successivamente, l'ordine viene **Incassato** in colli individuali che seguono una regola chiamata **UBIS** (nomenclatura di MANGO per indicare SKU = modello-colore-taglia) con una tolleranza del 2% rispetto all'ordine iniziale.

Si incassano anche i **Colli senza tolleranza (CD)**, denominati nel seguente modo poiché non devono sottostare ad una tolleranza trattandosi di colli standard.

Nella fase **Booking x Vendor**, MANGO organizza il trasporto della merce dal fornitore ai magazzini. Avviene poi l'**Invio** dei prodotti e il **Caricamento della documentazione a SDP** (un portale di gestione della documentazione a cui accede il fornitore).

Successivamente, MANGO autorizza il **Booking x Vendor** e la mercanzia viene **Inviata**. Si ha poi la **Validazione finanziaria** da parte di MANGO per effettuare il pagamento e la conseguente **Entrata in Magazzino** della merce.

Infine, si **Contabilizzano le fatture** e si effettua il **Pagamento finale**.

Vi sono anche delle azioni trasversali come **Documenti tecnici di export/import** e il **Peso/Misure** dei prodotti (sempre utile per una questione di export/import).

4.5.4 Mappatura processo TO-BE:

A seguito di riunioni con esperti delle varie fasi del processo di Acquisto aziendale, è stato dunque elaborato il TO-BE che figura nell'Appendice Fig.2:

Il nuovo processo inizierà con la fase di **Design**, cioè di ideazione delle bozze dei vestiti per via interna o tramite un fornitore. Le bozze saranno create con un codice Modello in Centric.

Successivamente il modello passerà attraverso vari filtri tramite delle riunioni. La riunione **Centrado** dove si deciderà quali modelli possono essere presentati e a cui verrà dunque posto il **Flag Style "Presented"**.

Successivamente vi sarà un'altra riunione chiamata **Buying Meeting** dove si decide quali dei modelli presentati verranno effettivamente comprati. Dopo suddetta riunione verrà inviato un **Flag Style "Buy"** a Centric e verranno dunque aggiunti nel sistema Java chiamato **COM** (strumento con composizione dei prodotti) dati circa la composizione del modello utili per la sua creazione.

Vi sarà dunque una **Selezione di acquisto dei modelli**, che sarà selezionata a seconda del Budget. Il **Purchase Planning** aiuterà a tenere sotto controllo il **Budget** mensile effettuando una pianificazione degli acquisti.

In parallelo si inizieranno le trattative circa i costi con i fornitori (**Costing and vendor negotiation**) e la selezione dei fornitori (**Vendor Allocation**) e si decideranno le quantità da comprare di ogni modello con i vari feedback descritti in seguito.

Per poterli realizzare, si terrà anche conto dei clusters di negozi di MANGO (ve ne sono di diversi tipi a seconda della grandezza dei negozi e della fatturazione) nel **Location clustering** e degli ordini iniziali dei clienti (**Initial Assortment**). Informazioni vitali per stimare le quantità che saranno acquistate da Proprias e Deposito con il **Buying Feedback** dove i PMs di GDP (distribuzione) indicheranno quante unità di un determinato modello saranno necessarie per il proprio mercato. Si esegue questa analisi per tutti i mercati e la si somma per avere una quantità definita per quei tipi di business.

Dopo mesi, si arriva al giorno della distribuzione con una riunione chiamata **Expiry Meeting** dove si decidono quali modelli devono uscire dal magazzino ed essere distribuiti e si ha quindi un aggiornamento del Feedback precedente (**Feedback Update**). Si seguono gli stessi step per Firms e Online nel **Wholesale and Online Feedback**.

Una volta ottenuta la quantità di unità da comprare per ogni modello, si effettuerà una riunione di acquisto detta **Buy Decision** con la quale si crea una pianificazione di consegna (**Delivery Schedule**).

Si crea dunque un documento in SAP che specifica la relazione tra quantità e fornitori (Info Record). I fornitori dovranno poi specificare come distribuiranno la merce in termini di tempo e in quali magazzini (**Plant & Segment**). Dei vari modelli si selezionano le quantità da distribuire delle varie taglie (**Select Size Curve**) e successivamente si Approva l'Ordine (**Approve PO**) e si Crea l'Ordine vero e proprio in SAP. La creazione dell'ordine comporta la creazione di un documento (**PO document**) che dovrà essere accettato dal fornitore per poter iniziare a lavorare.

Sarà poi deciso il numero di colli standard **PrePack** e inviato un ordine di colli al fornitore (**PO Cartons**). Import assegnerà il trasportista (**Forwarder Assignment**) e questo permetterà creare un **Booking** (il Booking per vendor del processo AS-IS)

In **Inbound Delivery**, il fornitore dà la merce al trasportista insieme a un documento chiamato **Packing List**. Allo stesso tempo il fornitore rilascia una fattura (**Invoice**) che viene verificata da SAP (**Invoice Verification**) e si esegue (**Invoice Posting**) sia in SAP 4 che in SAP Focus (SAP 3). Si riceve infine la merce (**Goods Receipt**).

4.5.5 Implementazione del processo

Al giorno d'oggi, il progetto di Trasformazione Hangar è ancora in fase di sviluppo, quindi l'implementazione del micro-processo volto alla standardizzazione dei colli aziendali chiamato Pre-Packs che verrà analizzata nei capitoli seguenti non è altro che una predizione. Utilizzando una tecnica di Machine Learning sarà dunque possibile "implementare" il micro-processo in anticipo, prevedendo i risultati della nuova configurazione proposta dall'azienda ed eseguendone un'analisi preliminare.

5. Situazione attuale, problema e soluzione

Nel seguente capitolo si descrive brevemente la distribuzione attuale dei colli aziendali facendo riferimento solo a una categoria di prodotti appartenenti alla famiglia* Camicie e soffermandosi sulla descrizione degli attuali colli “standard” di contenuto e formato differente a seconda del cliente finale. In termini aziendali, con famiglia ci si riferisce a famiglia di acquisto (ad esempio, della linea Donna esistono diverse famiglie di acquisto, come: giacche, pantaloni e camicie).

Si presentano dunque i problemi legati allo “standard” attuale: pallettizzazione per colpa del formato differente dei colli e possibilità di mancata distribuzione al cliente finale per via dei colli estremamente personalizzati. La soluzione aziendale per ovviare a tali problemi è una standardizzazione sia del contenuto che del formato dei colli, chiamata Pre-Pack.

5.1 Descrizione distribuzione prodotti attuale:

Attualmente, MANGO gestisce la distribuzione dei suoi prodotti in due maniere differenti, creando due tipi di colli:

- **Individuali:** dove il prodotto all’interno del collo, cioè la camicia, viene impacchettata solamente in una specifica taglia e determinata quantità a seconda del cliente finale.

- **Standardizzato (CD):** dove la camicia all'interno del collo viene impacchettata con un numero variabile di taglie e quantità per taglia, a seconda dell'ordine effettuato dal cliente a cui è destinato il collo. Dunque, ogni collo contiene una combinazione differente di taglie/quantità e perciò delle dimensioni differenti.

MANGO cerca di standardizzare tali colli chiamati CD utilizzando un algoritmo informatico chiamato Barcelogic per comprendere quali combinazioni sono adeguate a coprire il maggior numero di clienti. Dunque, cerca di distribuire al maggior numero di clienti lo stesso tipo di CD.

Al giorno d'oggi vi sono 732 combinazioni possibili che cambiano a seconda della famiglia e anche all'interno di una stessa famiglia (come si mostrerà nel paragrafo successivo 5.2) per ognuna delle linee commercializzate da MANGO.

La quantità di combinazioni di CD differenti dipende anche dalla varietà di prodotti appartenenti ad ogni famiglia. Ad esempio, per la Donna si arriva ad avere 179 combinazioni differenti di colli dato che è la parte di business con il più elevato numero di prodotti, mentre per la linea dei Bambini vi sono solamente 2 combinazioni.

Nella seguente tabella Fig.5.2.1, vi è un esempio del tipo di colli e del numero delle loro possibili combinazioni a seconda delle varie linee:

Genero	Taglie collo	Combinazioni differenti
Bambini	04-05-06-07-08-09-11-13	2
Uomo	20-21-22-23	7
	20-21-22-23-24	15
	36-38-40-42-44-46	6
	36-38-40-42-44-46-48	2
	38-40-42-44-46	5
	38-40-42-44-46-48	10
Donna	19-20-21-22	179
	19-20-21-22-23	90
	20-21-22	164
	20-21-22-23	7
	21-22	6
	32-34-36-38-40-42	81
	32-34-36-38-40-42-44	51
	34-36-38	1
	34-36-38-40	19
	34-36-38-40-42	51
	34-36-38-40-42-44	19
	36-38-40	4
	36-38-40-42-44	2
	37-38-39-40	6
	99	5
Totale		732

Fig.5.2.1: esempio combinazioni colli CD attuali calcolati dall'algoritmo Barcelogic

5.2 Situazione attuale CD

In seguito, si descrive un esempio della situazione attuale riguardante i colli CD. Supponiamo il caso in cui ci sia un cliente A con una domanda differente per due prodotti appartenenti alla stessa famiglia: la Camicia 1 e la Camicia 2.

Esaminando la Camicia 1, notiamo che ha effettuato il seguente ordine iniziale di acquisto (PI):

Camicia 1	
Taglie	PI
20	7
21	5
22	2

Secondo l'algoritmo Barcelogic, suddetto modello può essere incassato in tre tipi diversi di collo con combinazioni differenti di taglie. Nel caso del Cliente A, l'ordine viene incassato perfettamente nel secondo tipo di collo (I33-21B).

Taglie	20	21	22	Nome collo
Unità	8	4	2	I33-21D
	7	5	2	I33-21B
	15	10	5	I33-77B

Se prendiamo ora un altro modello Camicia 2, sempre da distribuire allo stesso cliente A, noteremo che essendo il PI differente rispetto al precedente modello, sono stati creati due colli distinti rispetto ai tre precedenti:

Camicia 2	
Taglie	PI
20	9
21	6
22	3

In questo caso gli saranno distribuiti due colli del primo tipo (A33-11D) contenenti 16 unità e che verranno chiamati Collo 1 e Collo 2.

Taglie	20	21	22	Nome collo
Unità	4	3	1	A33-11D
	7	5	2	I33-21B
	12	8	4	I33-12B

La situazione sarebbe dunque la seguente:

	Taglie		
	20	21	22
Collo 1	4	3	1
Collo 2	4	3	1
Totale	8	6	2
Mancanti	1	0	1

In una situazione ideale, le due unità mancanti vengono distribuite in colli individuali. A volte però l'azienda non ha a disposizione delle unità nei colli individuali poiché ha già distribuito tutti questi tipi di colli. Ammettiamo che sia questo il caso e che MANGO non riesca a sopperire al bisogno di due unità rispettivamente nelle taglie 20 e 22.

Per poter risolvere il problema si vede dunque costretta a manipolare altri colli CD (fermi in magazzino per vari motivi, come l'eliminazione di un ordine da parte di altri clienti), aprendoli e smistandone il contenuto in due colli individuali contenenti una taglia 20 e una taglia 21 inviate al cliente A.

5.3 Problema standard attuale CD

Il problema attuale riguarda una situazione specifica che si manifesta attualmente nell'azienda quando i clienti cancellano i propri ordini. Normalmente, l'azienda riesce a destinare i colli individuali di suddetti clienti ad altri senza troppa difficoltà (manipolandone un attimo il contenuto).

Per quanto riguarda i colli standard la loro manipolazione risulta più complessa dato che in ogni collo sono presenti combinazioni differenti di taglie e i nuovi clienti hanno delle esigenze rispetto ai vecchi clienti che hanno cancellato l'ordine.

Oltretutto, di norma è più comune avere dei colli standard da manipolare che dei colli individuali, dato che quest'ultimi vengono normalmente distribuiti con più facilità.

Ovviamente, questo comporta un costo non indifferente per l'azienda che si ritrova a pagare il fornitore affinché crei colli standard e poi a pagare i suoi stessi dipendenti affinché disfino il lavoro effettuato a monte. La conseguenza di questa azione è dunque uno spreco di risorse e denaro.

Oltretutto, da un punto di vista puramente logistico, i colli standard attuali hanno dimensioni differenti che possono variare molto. Queste dimensioni causano problemi al momento della pallettizzazione dato che risulta quasi impossibile ai lavoratori creare un pallet omogeneo e che non si disfi. Da questo punto di vista, si hanno dunque dei ritardi nella pallettizzazione non indifferenti, i quali aumentano quando la merce deve essere distribuita via aerea (di norma, i pallets aerei devono essere adeguati al tipo di aereo che effettua il trasporto e quindi possono avere varie forme che differiscono molto dai pallet tradizionali).

L'attuale processo risulta lungo e tedioso anche dal punto di vista del dipartimento responsabile della distribuzione che deve controllare ogni modello e il relativo CD assegnatogli 40 giorni prima della sua spedizione da parte dei fornitori. In aggiunta, nonostante lo standard sia fornito dal modello Barcelogic, non vi sono possibilità di integrare queste combinazioni in SAP.

5.4 Soluzione standard Pre-Packs

Per ovviare a questo problema, l'azienda ha pensato di standardizzare ulteriormente i colli standard creando una combinazione univoca del contenuto dei colli per le diverse famiglie e un formato univoco dei colli stessi.

Il nuovo collo, chiamato Pre-pack, non sarà più una cassa di dimensioni variabili ma una borsa di plastica con dentro sempre la stessa combinazione di prodotto (a seconda della famiglia). Questa borsa verrà poi inserita in un collo di dimensioni standard 40x40x60. La quantità di borse all'interno del collo dipenderà dalle necessità del cliente finale.

Ogni famiglia avrà la propria combinazione codificata in SAP con la possibilità di poterla cambiare nel caso si ritenga necessario ma che di norma rimarrà fissa. Inoltre, sarà posto un nuovo limite di acquisto dei colli standards sull'acquisto totale per ogni famiglia (ad esempio, nella famiglia delle camicie il 33% dell'acquisto sarà impacchettato come Pre-pack).

Questa standardizzazione dei colli comporta semplificazioni:

- A livello SAP dato che non vi sarà più un algoritmo dinamico che calcola i colli standard ogni stagione, ma un'analisi fatta su misura che viene semplicemente salvata su SAP;
- A livello logistico, poiché saranno diminuiti i tempi di pallettizzazione;
- A livello distributivo, poiché verranno manipolati un numero di minore di colli.

6. Machine Learning

I recenti progressi nella gestione dei dati digitali sono strettamente legati a una grande difficoltà nell'ottenere della conoscenza utile dall'informazione data. Infatti, nonostante le aziende siano in grado di gestire grandi quantità di dati, al giorno d'oggi risulta difficile estrapolare una conoscenza da quest'ultimi dato che la connessione delle informazioni può risultare complessa.

Per poter ovviare a questo problema si tende dunque a fare uso di tecniche di intelligenza artificiale che permettono di ottenere un'interpretazione dei dati tramite una simulazione. Tra le varie tecniche appartenenti a suddetta disciplina vi è il Machine Learning.

6.1 Contesto

Il Machine Learning è un ramo dell'intelligenza artificiale che utilizza varie tecniche per far sì che un computer apprenda a risolvere problemi di inferenza, realizzare predizioni, prendere decisioni o a costruire modelli descrittivi a partire dai dati.

Tipicamente, i dati venivano trasformati in conoscenza tramite dei processi manuali realizzati da esperti del settore analizzato. Queste trasformazioni manuali erano però estremamente lente, costose e altamente soggettive. Una evoluzione di questo processo è il Knowledge Discovery Database creato da Fayyad et al, un procedimento di estrazione dell'informazione utile dai dati.

Nella figura 6.1.1 si mostra il ciclo di vita del KDD dettagliandone le varie fasi. In primo luogo, è necessario acquisire i dati grezzi da cui si vuole estrarre la conoscenza, selezionando solo quelli che soddisfano i criteri desiderati. Successivamente, si effettua un pre-processamento dei dati eliminando possibili rumori o variabili indesiderate e, se si desidera, discretizzandoli, normalizzandoli etc. Dopodiché, i dati vengono immagazzinati in un file ARFF* (ad esempio), il quale viene successivamente utilizzato da un algoritmo di Machine Learning per ottenere dei modelli (patterns) e dunque la conoscenza.

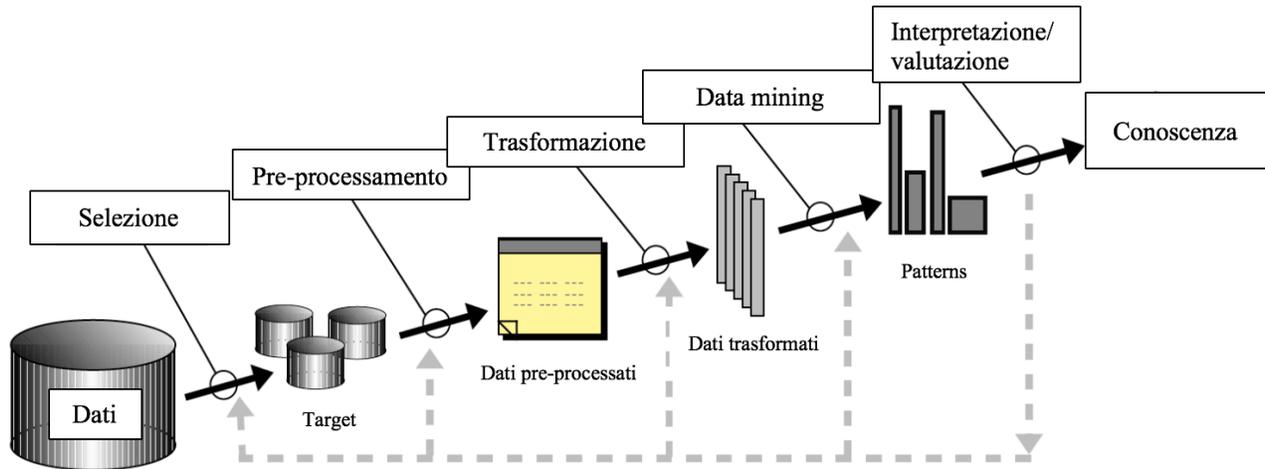


Fig. 6.1.1: Ciclo di vita del Knowledge Discovery Database secondo Fayyad et al. [1996].

Da un punto di vista matematico il processo di Machine Learning si traduce nell'individuazione di una serie di approssimazioni per stimare una funzione f che vincola variabili indipendenti a variabili dipendenti [James et al., 2013].

6.2 Notazione e funzione f

Come menzionato anteriormente, i problemi da risolvere utilizzando il machine learning sono rappresentati da un insieme di variabili indipendenti X composto da: variabili, attributi o predittori X_1, X_2, \dots, X_p quindi $X = (X_1, X_2, \dots, X_p)$. Le variabili dipendenti sono caratterizzate dal simbolo Y . Vi è inoltre un errore aleatorio denotato con il simbolo ε , che risulta essere indipendente da X e con media zero.

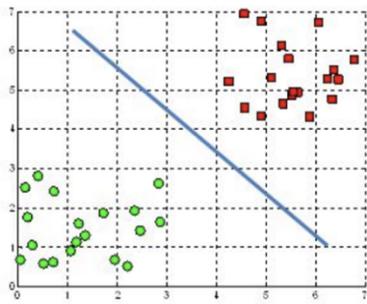
Inoltre, in seguito, simbolo $\hat{\cdot}$ indicherà una approssimazione verso l'obiettivo presupposto, ad esempio \hat{f} è la approssimazione di f e \hat{Y} la approssimazione di Y .

È inoltre necessario introdurre il concetto di iperpiano che di norma si utilizza nei modelli basati sulle reti neurali e nelle macchine a vettori di supporto. Gli iperpiani sono confini decisionali che aiutano a classificare i dati, infatti i dati che si ritrovano in un lato o l'altro dell'iperpiano possono essere attribuiti a classi differenti.

Inoltre, la dimensione dell'iperpiano dipende dal numero di caratteristiche. In uno spazio p dimensionale, l'iperpiano è uno spazio affine di dimensioni $p-1$. Ad esempio, in uno spazio bi-dimensionale l'iperspazio è una retta che divide il piano in due metà. In uno spazio tri-dimensionale è un piano che divide lo spazio in due metà (Fig.6.2.1).

*ARFF detto anche Attribute Relationship File Format è un formato per un file testo usato per memorizzare dati in un database

Un iperpiano in \mathbb{R}^2 è una linea



Un iperpiano in \mathbb{R}^3 è un piano

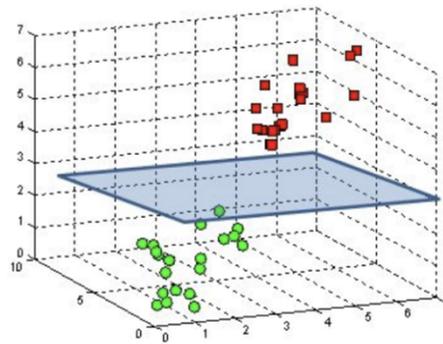


Fig.6.2.1: rappresentazione grafica degli iperpiani in due e tre dimensioni

6.3 Funzione f

Come menzionato precedentemente, si assume che esista una relazione tra la variabile indipendente X e la variabile dipendente Y . Suddetta relazione si esprime nella seguente maniera:

$$Y = f(X) + \varepsilon$$

In questo contesto f è una funzione sconosciuta e rappresenta l'informazione sistematica che X fornisce circa la Y . I due motivi principali per stimare f sono la inferenza e la predizione. ε invece rappresenta l'errore relativo al *fit* della funzione f .

6.4 Inferenza

Stimare f permette di studiare la relazione esistente tra le variabili indipendenti e la risposta o , detto in un altro modo, la forma in cui Y viene influenzata quando X_1, X_2, \dots, X_P cambia. Questo cambiamento viene denominato Inferenza.

Volendo l'obiettivo finale può anche non essere la realizzazione di predizioni circa Y perché può anche risultare interessante conoscere che predittori sono relazionati con la risposta, qual è la relazione tra quest'ultima e ogni predittore (se è possibile descrivere il vincolo esistente tra la risposta e ogni predittore mediante un'equazione lineare o se al contrario si tratta di una relazione più complessa).

6.5 Predizione

In molti problemi, trovare le variabili indipendenti X è un'attività praticamente immediata, Y al contrario non si riesce a ottenere facilmente.

Pertanto, risulta necessario costruire un modello f capace di generalizzare i dati e la relazione esistente tra di essi, utilizzando casi già esistenti per poter predire la variabile dipendente Y .

Detto in termini più generali, l'obiettivo principale del machine learning è che una macchina riesca a generalizzare dalla propria esperienza, eseguendo dei ragionamenti induttivi. La macchina deve pertanto riuscire a completare compiti nuovi, mai affrontati prima, dopo essersi esercitata su un insieme di dati di apprendimento.

Normalmente si assume che gli esempi di addestramento derivino da una distribuzione di probabilità (generalmente sconosciuta) considerata rappresentativa dello spazio delle occorrenze del fenomeno da apprendere. La macchina costruisce dunque un modello probabilistico generale dello spazio delle occorrenze così da poter produrre previsioni sufficientemente accurate quando le vengano presentate delle nuove casistiche.

6.6 Stima di \hat{f}

La stima del modello \hat{f} è di per sé piuttosto complessa, soprattutto dato che si desidera generalizzare in maniera automatizzata.

Facendo un attimo un riferimento alla teoria, questa analisi computazionale degli algoritmi di machine learning fa parte di una branca dell'informatica teorica, chiamata teoria dell'apprendimento. Secondo questa teoria, gli esempi di addestramento sono insiemi finiti di dati e non vi è modo di conoscere l'evoluzione futura di un modello.

Inoltre, la teoria dell'apprendimento non fornisce alcuna garanzia circa le prestazioni degli algoritmi e il bias-varianza tradeoff è uno dei modi utilizzati per quantificare l'errore di generalizzazione.

Nel seguente elaborato verrà creato un modello $\hat{f}(X)$ di $f(X)$ che, come precedentemente accennato, prevede un errore ε . La creazione del modello normalmente avviene tramite una regressione lineare o altre tecniche di modellazione. Pertanto, l'errore previsto al quadrato di X sarà:

$$\text{Err}(X) = E[(Y - \hat{f}(X))^2]$$

L'errore $\text{Err}(X)$ può essere ulteriormente suddiviso come:

$$\text{Err}(X) = (E[\hat{f}(X)] - f(X))^2 + E[(\hat{f}(X) - E[\hat{f}(X)])^2] + \sigma_\varepsilon^2$$

$$\text{Err}(X) = \text{Bias}^2 + \text{Varianza} + \text{Errore irriducibile}$$

Vi è dunque un compromesso (tradeoff) tra la capacità del modello di ridurre al minimo i bias e la varianza. Entrambi sono degli errori comuni quando si effettua una stima \hat{f} e se compresi correttamente permettono la costruzione di modelli accurati, evitando errori di *overfitting* e *underfitting*.

Il **bias** non è altro che la differenza tra la predizione media del modello e il valore corretto che si sta cercando di predire. Dei modelli con alto bias prestano pochissima attenzione ai dati di allenamento e semplificano eccessivamente il modello. Pertanto, comportano sempre un grande errore sui dati di allenamento (training) e di verifica (test).

La **varianza** è la variabilità della previsione del modello per un determinato insieme di dati o un valore, che rappresenta come sono distribuiti i dati. Un modello con un'alta varianza presta molta attenzione ai dati di addestramento e non generalizza sui dati nuovi. Di conseguenza, tali modelli si comportano molto bene sui dati di allenamento, ma presentano elevati tassi di errore sui dati di verifica.

Errore irriducibile: è una misura della quantità di rumore nei dati usati e non può essere ridotto neanche creando dei buoni modelli.

Nel seguente diagramma Fig.6.6.1, il centro del bersaglio rappresenta un modello che predice perfettamente i valori corretti. Quanto più ci si sposta dal centro tanto più peggiorano le predizioni. Le croci indicano le varie ripetizioni del processo di predizione effettuate con il modello.

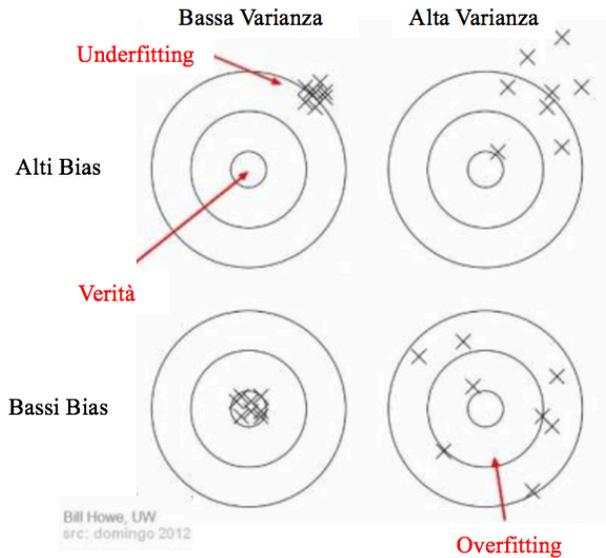


Fig.6.6.1: Rappresentazione casuistiche predizioni (underfitting, overfitting e verità)

Come si può notare dal grafico Fig. 6.6.2, se un modello è troppo semplice e consta di pochi parametri, allora potrebbe avere bias elevato e varianza bassa. D'altro canto, se il modello ha un grande numero di parametri avrà una varianza elevata e un bias basso. Si deve cercare di trovare un equilibrio senza effettuare un *overfitting* o *underfitting* dei dati, cioè il suddetto *tradeoff*.

Nell'apprendimento supervisionato, un *underfitting* avviene quando un modello non è in grado di catturare lo schema alla radice dei dati. Di solito, tali modelli hanno alto bias e bassa varianza. Tipicamente, questo fenomeno avviene quando si hanno pochi dati per creare un modello accurato o quando si cerca di creare un modello lineare da dei dati non lineari.

L'*overfitting* avviene quando il modello cattura dei rumori insieme allo schema sottostante i dati e ciò accade quando si addestra il modello su un dataset rumoroso. Questi modelli tendono ad avere un bias basso e un'alta varianza. Gli alberi decisionali sono prони all'*overfitting*.

Nella seguente figura Fig.6.6.2 vengono rappresentati graficamente un caso di *overfitting*, *underfitting* e di *tradeoff*.

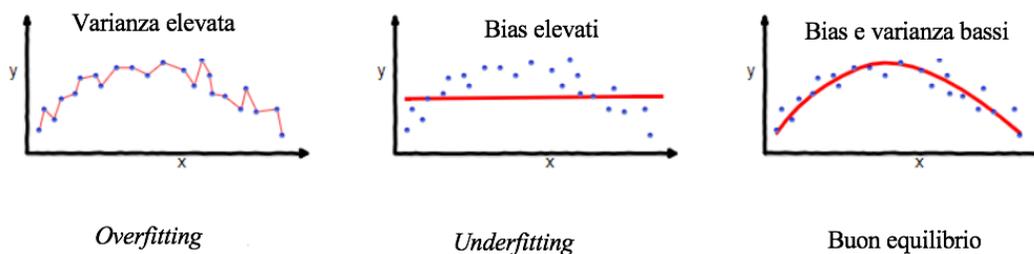


Fig.6.6.2: rappresentazione grafica *overfitting*, *underfitting* ed equilibrio

In generale, affinché la generalizzazione offra le migliori prestazioni possibili, la complessità dell'ipotesi induttiva deve essere pari alla complessità della funzione sottostante i dati. Quando ciò non avviene, per poter creare un buon modello, si deve trovare un buon equilibrio tra il bias e la varianza in modo tale da minimizzare l'errore totale $Err(X)$. Un equilibrio ottimale sarebbe tale da non eseguire mai un *overfit* o *underfit* del modello.

Normalmente, per poter generalizzare correttamente in maniera automatizzata si frammenta il database tramite una convalida incrociata in due parti: una parte di allenamento (train) e una parte di prova (test). La convalida incrociata è una tecnica statistica usata nel machine learning per eliminare il problema di *overfitting* nell'insieme di addestramento. Quando si esegue una convalida incrociata k-volte, il campione

originale viene suddiviso in k sottocampioni della stessa dimensione. Di questi k sottocampioni, uno è conservato come dato di convalida per testare il modello e i restanti $k-1$ sottocampioni sono usati per l'addestramento. Questo processo è dunque ripetuto k volte e ogni k sottocampione viene usato esattamente una volta come dato di convalida.

Infine, i k risultati derivanti dalle k ripetizioni del processo vengono combinati effettuando una media (o in altri modi) per produrre una singola stima.

6.7 Paradigmi

I differenti algoritmi di machine learning si raggruppano in tre grandi categorie chiamate paradigmi, a seconda della natura del segnale usato per apprendere o del feedback disponibile per l'apprendimento:

- **apprendimento supervisionato** (*supervised learning*), in cui vengono forniti degli esempi al modello nella forma di possibili input con i rispettivi output desiderati. L'obiettivo è l'estrazione di una regola generale che associ l'input all'output corretto. A seconda delle variabili indipendenti X , l'apprendimento supervisionato può essere:
 - **di classificazione**, dove gli output sono suddivisi in due o più classi e il sistema di apprendimento deve creare un modello che assegni gli input non ancora visti a una o più di queste classi (un esempio di classificazione è il filtro antispam, dove gli input possono essere considerati le e-mail che arrivano all'indirizzo di posta elettronica e le classi possono essere considerate le categorie "spam" e "non spam");
 - **di regressione**, dove il modello utilizzato e l'output sono continui. Un esempio riguarda la predizione del valore del tasso di cambio di una valuta nel prossimo futuro, prendendo in considerazione i suoi valori passati.
- **apprendimento non supervisionato** (*unsupervised learning*), dove lo scopo del modello è trovare una struttura negli input forniti, senza che gli input vengano etichettati in alcun modo. Alcune tecniche utilizzate sono:
 - **clustering**, cioè il raggruppamento degli input in regioni dove la somiglianza reciproca è elevata;
 - **regole di associazione**, utilizzata per scoprire ciò che accade comunemente in un determinato insieme di dati;
 - **riduzione delle dimensioni**, consiste nella riduzione dello spazio di ricerca del database mantenendo solo gli attributi che apportano il maggior numero di informazioni al dataset.
- **apprendimento per rinforzo** (*reinforcement learning*), un ibrido dei paradigmi precedenti dove il modello interagisce con un ambiente dinamico nel quale cerca di raggiungere un obiettivo senza l'intervento di un supervisore che lo guidi. Dunque, il modello apprende provando e sbagliandosi. Un esempio può essere quando si cerca di imparare a giocare un gioco giocando contro un avversario.

Oltretutto, tra l'apprendimento supervisionato e quello non supervisionato può essere collocato anche l'**apprendimento semi-supervisionato**, dove l'insegnante fornisce un dataset incompleto per l'allenamento, dove l'insieme di dati per l'allenamento contiene alcuni dati senza il rispettivo output desiderato. Un caso speciale di questo principio è la **trasduzione**, dove l'intero insieme delle istanze del problema è noto durante l'apprendimento, eccetto la parte degli output desiderati che è mancante.

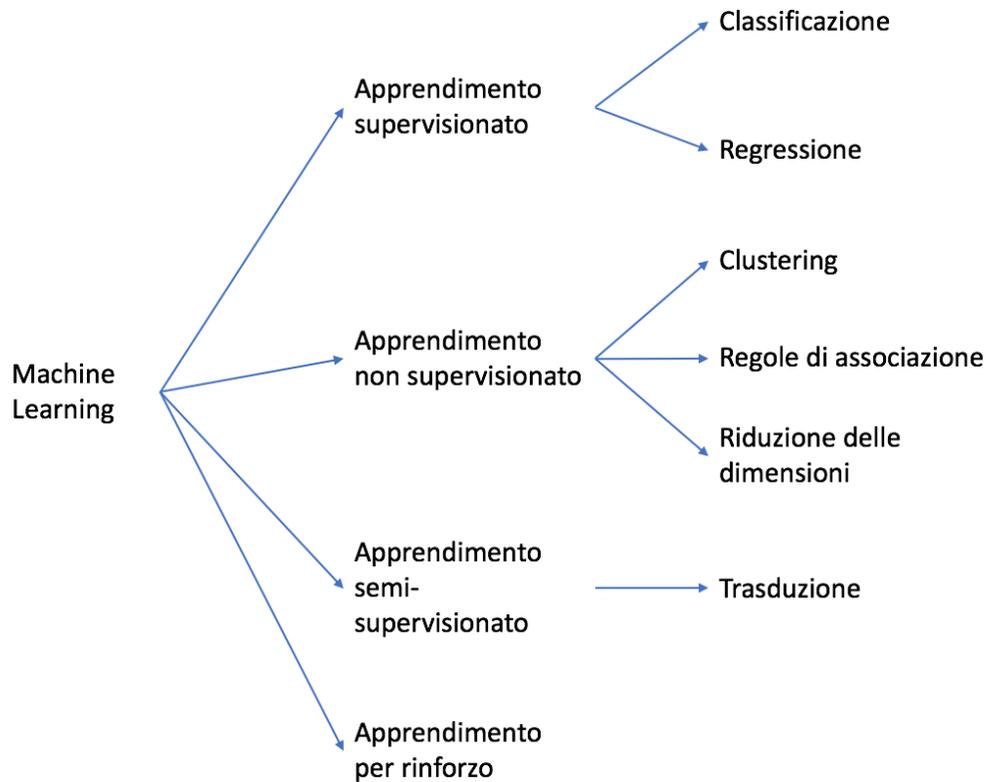


Fig.6.7.1: Rappresentazione grafica dei paradigmi di Machine Learning

L'obiettivo finale dell'elaborato riguarda la modellizzazione del rendimento aziendale una volta implementato il nuovo standard tenendo conto dei dati storici per effettuare l'addestramento e la verifica. Pertanto, dato che al modello verranno forniti degli esempi nella forma di possibili input con i rispettivi output desiderati, ci si soffermerà sulla categoria di Machine Learning riguardante l'apprendimento supervisionato.

7. Alberi decisionali e classificatori avanzati

Nel seguente capitolo verrà esposto il metodo di machine learning denominato Albero di decisione (*Decision tree*) appartenente alla categoria dell'apprendimento supervisionato utile per poter valutare le prestazioni del nuovo standard aziendale. Ci si soffermerà anche sui metodi avanzati di classificazione *Ensemble*, che consistono nella combinazione di molteplici modelli per poter generare un unico modello molto più preciso. Questi metodi sono costituiti principalmente da due grandi famiglie: *Random Forest* e *Boosting*.

7.1 Alberi decisionali

Gli alberi decisionali sono uno dei metodi più utilizzati nell'ambito del machine learning perché consentono di ottenere buone performance senza sacrificare l'interpretabilità del modello. Infatti, un fattore chiave che contraddistingue questo metodo è la chiarezza della rappresentazione delle informazioni: durante la fase di addestramento, l'algoritmo consente di rappresentare le regole estratte dai dati in maniera gerarchica, sfruttando i nodi dell'albero. In questo modo, la conoscenza appresa dall'albero può essere compresa senza difficoltà anche da non-esperti del settore. Le regole menzionate sono individuate tramite l'estrapolazione di relazioni statistiche che analizzano la dipendenza tra la classe di appartenenza e le variabili dipendenti che descrivono il fenomeno che si vuole modellare. Infine, l'insieme gerarchico di queste regole determina un insieme di percorsi che consente di identificare la classe di

appartenenza dell'esempio analizzato, semplicemente percorrendo l'albero dal nodo radice fino al raggiungimento di una foglia.

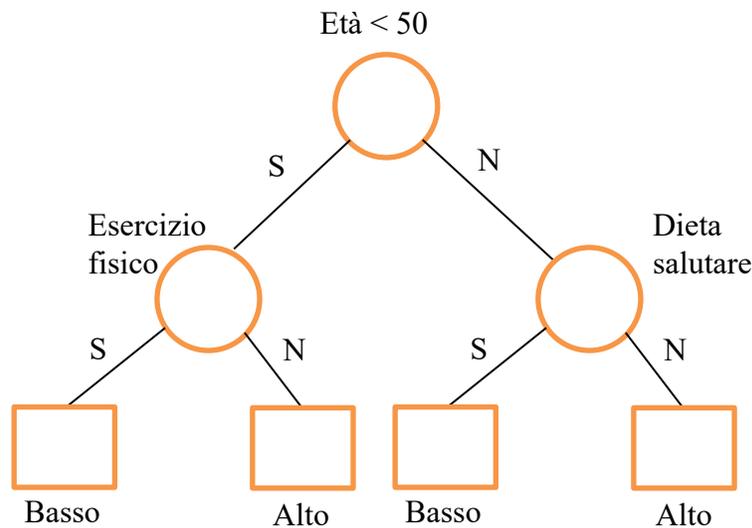


Fig. 7.1.1: Esempio albero decisionale

Utilizzando come riferimento la figura 7.1.1 è possibile introdurre la notazione relativa agli alberi decisionali. Tale albero consente di identificare se una persona può avere un problema di salute nei successivi sei mesi.

Ogni nodo può essere un padre di altri due figli, oppure di una foglia dell'albero. Il primo nodo è denominato radice, e rappresenta la variabile con il più alto potere discriminativo; nell'esempio la condizione testata è relativa all'età dell'individuo. Se un nodo non è una foglia, allora esso rappresenta una condizione booleana, che consente di segmentare i dati di ingresso in base a quanto appreso durante la fase di addestramento. Qualora invece il nodo fosse una foglia, esso rappresenta l'output del modello (nel nostro caso rischio alto o basso di avere un problema di salute nei successivi sei mesi).

L'albero viene costruito con un processo ricorsivo tale per cui, ad ogni passo, da un nodo interno (padre) dipartono due nodi figli. Tale metodo viene anche definito segmentazione binaria, in quanto l'idea di base è partizionare un insieme di unità statistiche in gruppi sempre meno numerosi e sempre più omogenei.

Gli alberi decisionali consentono di apprendere un modello per risolvere problemi di classificazione o regressione, seguendo un approccio di tipo supervisionato. Questo significa che l'insieme dei dati con cui viene condotto l'addestramento del modello deve contenere un set di variabili indipendenti denotate con X e una variabile obiettivo Y ben definita, che può essere di due tipi:

- un'etichetta di classe, se l'obiettivo è predire l'appartenenza di un esempio a una data classe;
- una variabile dipendente continua, nel caso di una regressione.

Tipicamente, è necessario sottoporre i dati a una fase di preparazione che può essere più o meno onerosa, a seconda del modello prescelto (es. nel caso delle reti neurali occorre normalizzare i dati in ingresso). Gli alberi decisionali richiedono poco intervento in tal senso: alcuni metodi, come il Random Forest, necessitano l'imputazione dei valori nulli (per esempio sostituendo il valore medio), mentre altri, come l'*XGBoost* possiedono sofisticati meccanismi che consentono una gestione automatica dei valori nulli.

La procedura di creazione degli alberi decisionali consta di varie fasi:

- Scissione ricorsiva (*recursive partitioning*), il processo di partizione dell'insieme di dati in sottoinsiemi creando un albero decisionale con l'obiettivo di individuare il taglio binario migliore rispetto ad un certo criterio statistico, ID3, CART...

L'idea di base della metodologia ID3 è determinare, per un insieme di esempi forniti, l'attributo più importante, ovvero quello con il maggior potere discriminativo per quell'insieme. Tipicamente, l>ID3 è supportato da tecniche matematiche e probabilistiche, quali l'entropia.

In meccanica statistica, l'entropia rappresenta la quantità di “*disordine*” di un sistema. Ad esempio, un sistema in cui delle molecole di gas sono riscaldate a una temperatura elevata possiede un grado più elevato di entropia rispetto a un gas vicino allo zero assoluto.

In teoria dell'informazione l'entropia rappresenta la quantità di informazione contenuta in un messaggio. Per esempio, si immagina il caso in cui una sorgente inoltri a un destinatario un messaggio per certificare il corretto funzionamento dei sistemi.

Nel caso in cui un malfunzionamento avesse una probabilità di verificarsi pari al 50%, allora la sorgente avrebbe bisogno di un unico bit per comunicare il proprio messaggio. Per calcolare il numero di bit necessari è sufficiente utilizzare la formula: Nel nostro caso, il numero di stati possibili è pari a due (il sistema funziona o è rotto). Pertanto, il numero di bit necessario è pari a uno.

Immaginando, invece, che la sorgente possa inviare uno stato più dettagliato (es. trasmettitore ok/ko, sensore ok/ko), allora gli stati possibili sarebbero quattro. Pertanto, il sistema necessiterebbe di due bit per trasmettere il messaggio, nel caso in cui ciascuno degli esiti fosse equiprobabile.

Ritornando al caso in cui la sorgente può inviare un messaggio binario che attesti il corretto funzionamento o un malfunzionamento. Tuttavia, trattandosi di un apparato estremamente affidabile, la probabilità che si verifichi un malfunzionamento è pari solo al 10%.

L'entropia quindi sarebbe pari a 90% in quanto in media è molto più probabile che l'apparecchio funzioni senza problemi. Ciò significa che, in media, servirebbero meno bit per trasmettere il messaggio, il 90% riceveremmo comunque un OK.

Il criterio utilizzato per definire il la migliore partizione che ottimizza la metrica di classificazione o regressione è il cosiddetto guadagno informativo: definito come variazione di dell'entropia prima e dopo una scissione. Una variabile molto discriminativa consente di ottenere un elevato guadagno informativo. Per esempio, supponendo di voler classificare le persone in base al sesso, e di potere osservare unicamente caratteristiche quali la lunghezza dei capelli e il colore degli occhi, si può osservare come la lunghezza dei capelli consenta di ottenere due partizioni più pure del colore degli occhi, in quanto è più probabile che le donne portino i capelli più lunghi.

Il processo di selezione degli attributi, calcolo dell'entropia e guadagno informativo viene ripetuto ricorsivamente a ogni livello dell'albero.

- Potatura (*pruning*), il processo tramite il quale si ha la riduzione della dimensione dell'albero mediante l'individuazione dei rami meno rilevanti che, di conseguenza, vengono trasformati direttamente in foglie. Tale metodo viene utilizzato per migliorare le capacità di generalizzazione del modello e prevenire l'*overfitting*. Tipicamente la scelta del ramo da potare viene effettuata conducendo analisi statistiche volte a comprendere l'impatto che tale operazione avrà sulle capacità predittive del modello.
- Selezione dell'albero (*tree selection*), il processo di ricerca dell'albero più piccolo che meglio si adatta ai dati. Tipicamente, il risultato è l'albero che porta ad avere il più piccolo errore di convalida incrociata.

7.2 Tecniche avanzate di classificazione

L'ultima tendenza è cercare di scoprire nuove tecniche che permettano di ottenere dei classificatori più precisi. Un metodo che consente di ottenere classificatori con prestazioni più elevate è il cosiddetto *Ensemble*, che consiste nel combinare le predizioni di più di un modello (ciascuno dei quali viene denominato *weak learner*), al fine di ottenere predizioni più robuste e corrette.

Le due metodologie di *ensembling* più popolari sono il *Bagging* e il *Boosting*.

La figura successiva mostra come un problema venga risolto tramite la metodologia *Ensemble*. Come si denota dalla figura, ogni classificatore ha dei piccoli errori ma la combinazione dei tre classificatori ha come risultato un modello di predizione più preciso dei tre modelli individuali.

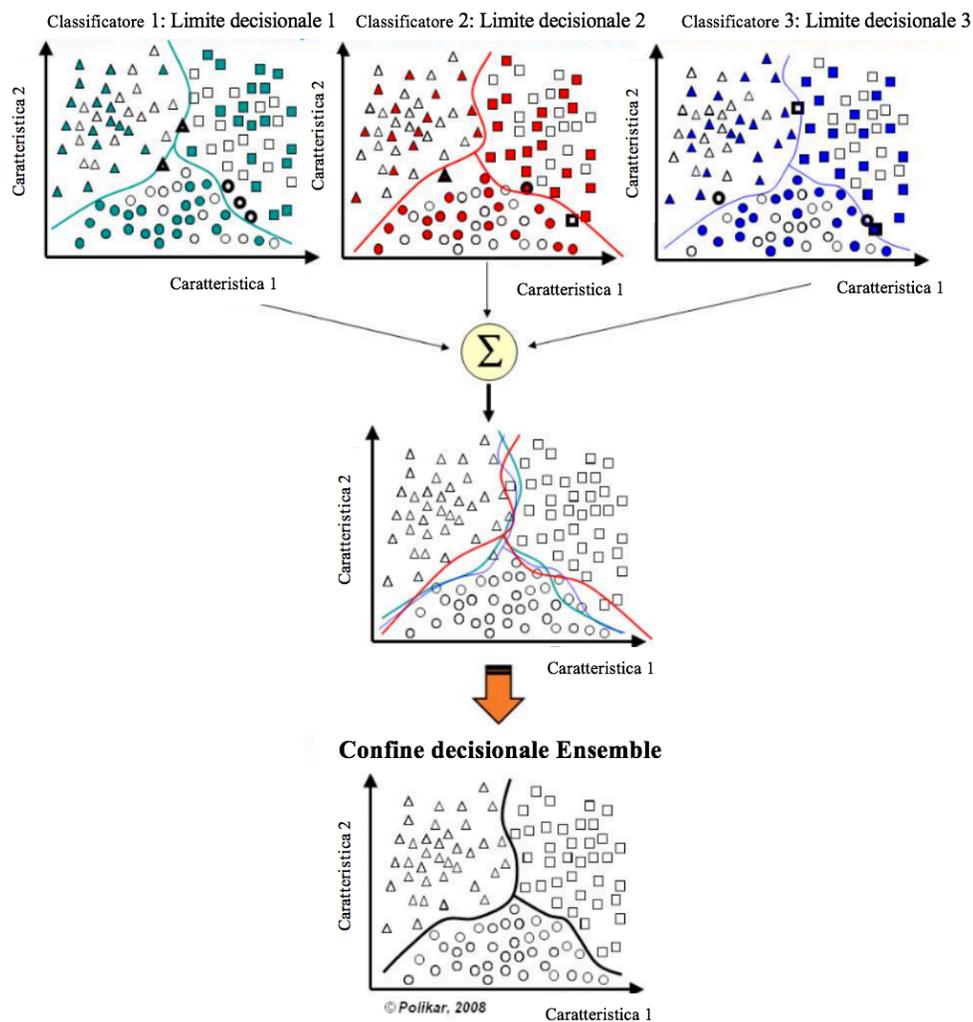
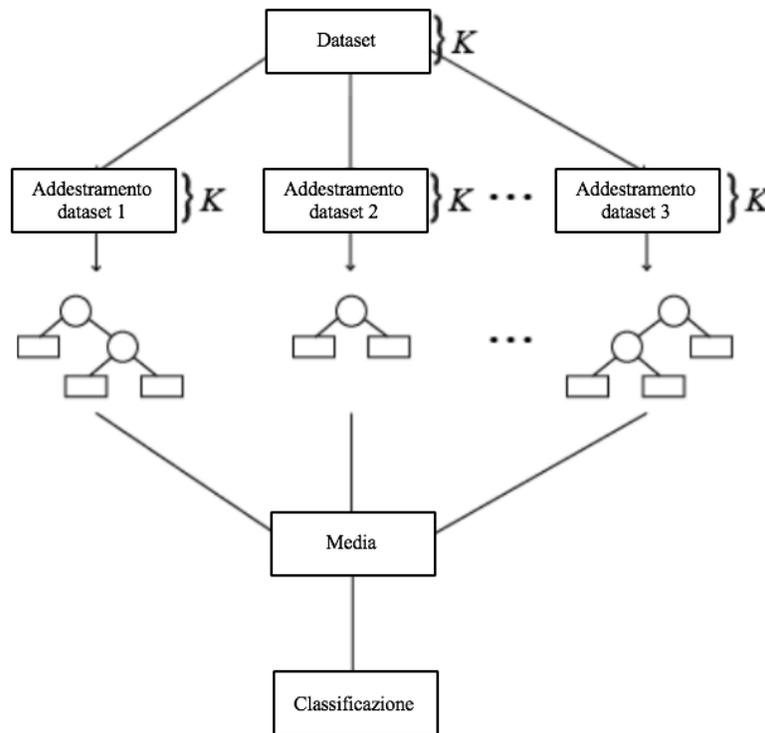


Figura 7.2.1: Metodo *Ensemble* dove l'insieme dei dati contiene due attributi differenti e il sistema utilizza tre sistemi di classificatori per modellare l'informazione.

7.2.1 Bagging: Random Forest

In origine questa tecnica *Ensemble* fu progettata per gli alberi decisionali. Permette di ottenere una approssimazione molto accurata alla distribuzione reale dei dati ed è utilizzata di frequente poiché fu progettata con l'obiettivo di minimizzare l'*overfitting*.

Nella Figura 7.2.1.1 viene illustrato il funzionamento di suddetta tecnica. Dato un insieme di dati di K esempi, si generano N insiemi di dati dell'originale con rimpiazzo (ciò significa che possono esserci degli elementi ripetuti all'interno di uno stesso insieme di dati). Ad ognuno di questi N insiemi, si applica un algoritmo di classificazione o regressione. Nell'esempio fornito si tratta di alberi decisionali combinati tramite una media per ottenere il classificatore finale.

Figura 7.2.1.1: Metodo *Bagging*

L'algoritmo più famoso che utilizza il *Bagging* è il *Random Forest*. Questo algoritmo coinvolge un insieme di alberi decisionali che vengono combinati per ottenere un risultato più preciso. Si tratta di alberi decisionali casuali costruiti tenendo in considerazione due concetti chiave:

- Campionamento casuale dei dati di addestramento;
- Insiemi casuali di caratteristiche usati nella scelta della partizione.

Per quanto riguarda il punto 1), durante la fase di addestramento ogni albero in un *Random Forest* apprende focalizzandosi unicamente su di un campione casuale dei dati originali. I campioni utilizzati sono estratti con rimpiazzo, tecnica denominata *Bootstrapping*, e quindi alcuni di essi possono essere usati anche molteplici volte in un singolo albero. Teoricamente, addestrando ogni albero su dei campioni differenti si ottiene un'alta varianza rispetto ad un addestramento eseguito solo su un insieme specifico dei dati di addestramento però, in generale, l'intera foresta (insieme di alberi) avrà una varianza minore senza incorrere in un aumento di bias.

Per quanto riguarda il punto 2), nel *Random Forest* solo un sottoinsieme di tutte le caratteristiche è preso in considerazione per effettuare la partizione dei nodi in ogni albero decisionale. Tipicamente, si tratta della radice quadrata del numero di caratteristiche. Pertanto, nel caso vi siano 16 caratteristiche, a ogni nodo in ogni albero decisionale, si considerano solo 4 caratteristiche casuali per effettuare la partizione. Ovviamente, gli alberi possono anche essere addestrati considerando tutte le caratteristiche a ogni nodo come d'usanza nella regressione.

Riassumendo, il *Random Forest* combina centinaia o migliaia di alberi decisionali, addestra ognuno di essi su un insieme leggermente differente di osservazioni ed effettua le partizioni considerando un numero limitato di caratteristiche. Le predizioni finali del *Random Forest* derivano dalla media delle predizioni di ogni albero decisionale; il che significa che tutti gli alberi hanno la stessa influenza nel determinare la decisione finale.

7.2.2 Boosting

A differenza del *Bagging* dove ogni classificatore è indipendente e la soluzione finale è dettata dal consenso, nel Boosting si cerca di generare un miglioramento continuo. Questa tecnica fu introdotta

soprattutto per ridurre il bias, così come la varianza e il suo obiettivo finale è la trasformazione di classificatori “deboli” (*weak learners*) in classificatori forti (*strong learners*).

Il *Boosting* è noto anche come *Ensemble* sequenziale, dato che i classificatori deboli sono prodotti sequenzialmente durante la fase di addestramento (e non in parallelo come nel caso del Random Forest, in cui tutti i classificatori sono di fatto indipendenti). Le prestazioni del modello vengono dunque migliorate assegnando un peso maggiore ai campioni incorrettamente classificati ad ogni iterazione di *Boosting*.

Pertanto, il principio alla base del funzionamento dell’algoritmo di *Boosting* è la generazione di molteplici classificatori deboli e la combinazione delle loro predizioni per formare una regola forte. Ciò avviene generando regole deboli su distribuzioni differenti dell’insieme di dati ad ogni iterazione della fase di addestramento dell’algoritmo. Infine, i classificatori deboli sono combinati per formare un classificatore forte che predice un risultato più accurato, a partire da un insieme di regole più forti. Nella figura Fig. 7.2.2.1 si illustra il funzionamento dell’algoritmo:

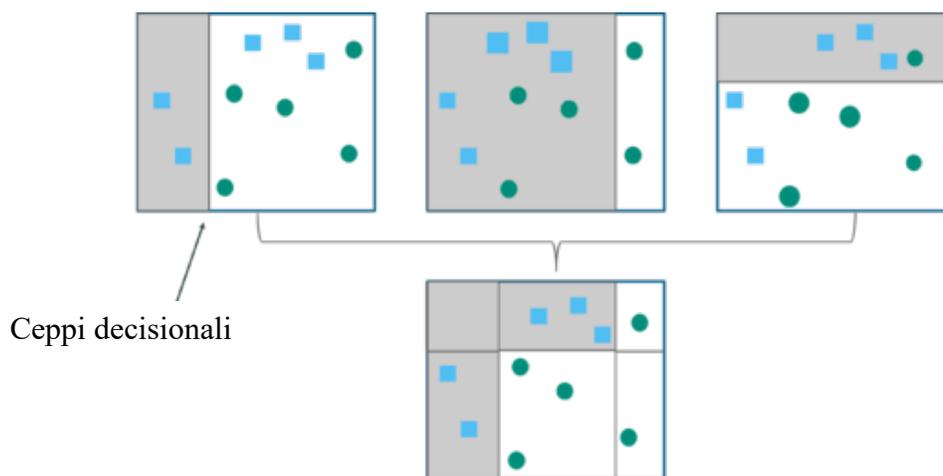


Fig. 7.2.2.1: funzionamento algoritmo di *Boosting*

Si seguono i seguenti passi:

Passo 1: L’algoritmo base legge i dati e assegna pesi uguali ad ogni campione osservato

Passo 2: Le predizioni errate effettuate dal classificatore base sono identificate e nell’iterazione successiva viene assegnato loro un peso maggiore rispetto agli esempi classificati correttamente.

Passo 3: si ripete iterativamente il Passo 2 fino a che l’algoritmo la metrica utilizzata per effettuare l’addestramento non converge, così da classificare più correttamente il dato.

L’obiettivo principale del *Boosting* è focalizzarsi maggiormente sulle predizioni classificate male. Perciò, i classificatori deboli costruiti nelle iterazioni successive si concentrano di più sugli esempi che i classificatori precedenti non sono stati in grado di classificare correttamente.

La prima tecnica che utilizzò il *Boosting* fu l’*AdaBoost*, il cui obiettivo finale riguardava la creazione di un classificatore forte $H(x)$ partendo da una combinazione lineare di classificatori semplici $h_t(x)$, come definito nelle seguenti espressioni:

$$f(x) = \sum_{t=1}^T \alpha_t h_t(x)$$

$$H(x) = \text{sign}(f(x))$$

Nella precedente formula, il parametro T indica il numero di iterazioni eseguite dall'*AdaBoost*; tale parametro viene indicato in fase di addestramento ed è una scelta dello sviluppatore. Tale tecnica è agnostica rispetto alla tipologia di classificatore, e pertanto rende possibile la combinazione di modelli differenti (es. alberi decisionali o reti neurali). Tuttavia, l'*AdaBoost* è molto suscettibile al rumore, e pertanto è facilmente soggetta a *overfitting*.

Una evoluzione dell'*AdaBoost* è il *Gradient Boosting*. Tale approccio è basato sul calcolo dei cosiddetti residui, ovvero la differenza tra il valore reale y e il valore approssimato \hat{y} . Questa differenza viene denominata *Loss-function* $L(y, F(x))$. Nel caso di un problema di regressione, una delle funzioni di costo più utilizzate è *MSE* (*Mean Square Error*):

$$L(y, F(x)) = \frac{1}{2} \sum_{k=1}^{ins} (y_k - \hat{y}_k)^2$$

Dove *ins* indica il numero di istanze.

Successivamente, si minimizzano i residui usando un gradiente, come mostrato nella seguente formula:

$$r_{im} = \frac{\partial L(y_i, F(x_i))}{\partial F(x_i)}$$

Dove l'istanza $i = 1, \dots, n$ e l'albero $m = 1, \dots, M$, e F rappresenta i parametri del modello (es. pesi di una rete neurale, o scelta delle variabili di split e dei valori in un albero decisionale) che possono essere variati al fine di minimizzare la funzione di costo.

L'idea fondamentale dell'algoritmo è che i residui tendano a zero, cioè che non ci sia errore.

Come si può notare dalla seguente figura Fig. 7.2.2.2, l'ultima tecnologia sviluppata finora dopo il *Gradient Boosting* è l'*XGBoost*:

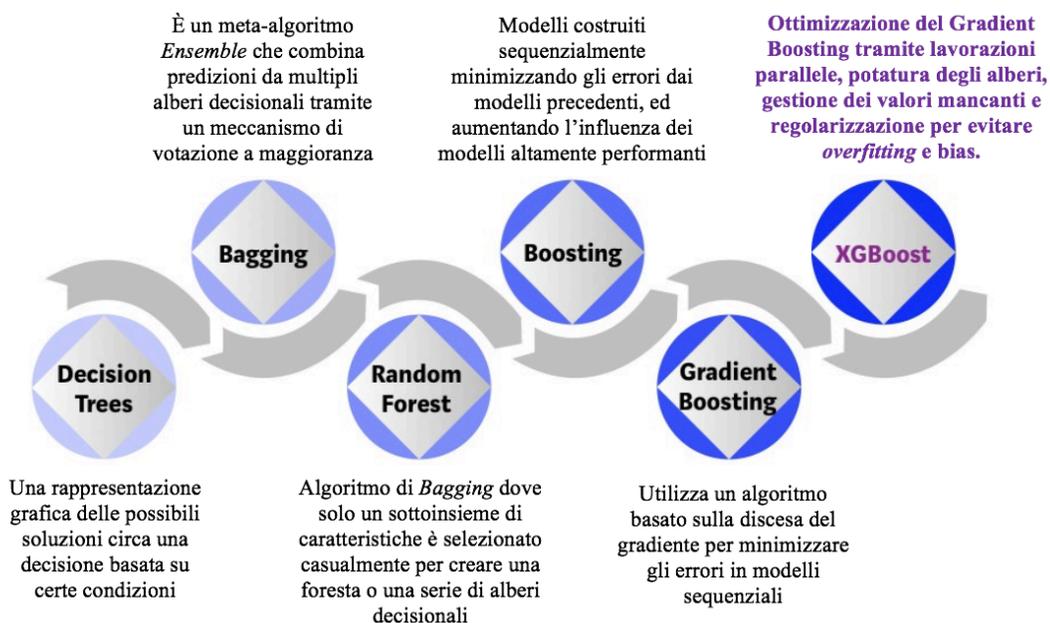


Fig. 7.2.2.2: evoluzione dagli alberi decisionali al *XGBoost*

L'*XGBoost* è un algoritmo *Ensemble* di machine learning basato sugli alberi decisionali che utilizza il framework del *Gradient Boosting*.

Fu sviluppato come un progetto di ricerca all'Università di Washington e presentato in una conferenza nel 2016 da Tianqi Chen e Carlos Guestrin. Esso consente di ottenere migliori risultati utilizzando meno risorse computazionali e impiegando meno tempo di calcolo.



Fig. 7.2.2.3: caratteristiche *XGBoost*

Ottimizzazioni del sistema

1. **Parallelizzazione:** *XGBoost* affronta il processo di costruzione sequenziale di alberi usando un'implementazione parallela. Ciò è possibile grazie alla natura intercambiabile dei cicli utilizzati per la costruzione dei *weak learners*: il ciclo esterno che enumera i nodi foglia di un albero e il secondo ciclo interno che calcola le caratteristiche. Questa nidificazione di cicli limita la parallelizzazione perché senza completare il ciclo interno (più esigente dal punto di vista computazionale dei due), il ciclo esterno non può essere attivato. Pertanto, per migliorare il tempo di esecuzione, l'ordine dei cicli viene scambiato mediante l'inizializzazione tramite una scansione globale di tutte le istanze e l'ordinamento usando fili paralleli. Questo scambio migliora le prestazioni algoritmiche compensando ogni costo di parallelizzazione.
2. **Potatura:** il criterio di potatura in GBM si basa sul criterio di perdita negativa quando si effettua lo split. *XGBoost* utilizza il parametro 'max_depth' e inizia a potare gli alberi al rovescio. Questo approccio *depth-first* migliora le prestazioni computazionali significativamente.
3. **Hardware:** l'algoritmo fa buon uso delle risorse hardware tramite la consapevolezza della cache, cioè allocando dei buffers interni in ogni filo per immagazzinare le statistiche sul gradiente. Ulteriori miglioramenti come il calcolo "out-of-core" ottimizzano lo spazio disponibile su disco gestendo grandi frame di dati che non entrano nella memoria.

Potenziamenti algoritmici

1. **Regolarizzazione:** penalizza i modelli più complessi attraverso l'utilizzo di tecniche di regolarizzazione LASSO (L1) e Ridge (L2) per evitare un eccesso di *overfitting* e per selezionare le caratteristiche importanti. Normalmente, metodi tradizionali come la convalida incrociata risultano appropriati, però quando si inizia a trattare una grande quantità di dati si preferisce ricorrere a queste tecniche.

2. **Consapevolezza della scarsità:** *XGBoost* ammette naturalmente caratteristiche scarse come input apprendendo automaticamente il migliore valore mancante a seconda delle perdite nell'addestramento. Dunque, gestisce i vari tipi di scarsità nei dati in maniera efficiente.
3. **Weighted Quantile Sketch:** *XGBoost* utilizza questo algoritmo per trovare in maniera efficace il migliore punto di split tra insiemi pesati di dati.
4. **Convalida incrociata:** l'algoritmo ha un metodo di convalida incrociata incorporato in ogni iterazione, dunque non risulta necessario programmarlo e specificare il numero esatto di iterazioni *boosting* richieste in un'unica esecuzione.

8. Creazione del modello con *XGBoost* e analisi della predizione

Nel capitolo precedente si sottolinea come il *Gradient Boosting* sia una delle tecniche più precise attualmente esistenti in letteratura. Questa tecnica è tipicamente sfruttata in maniera ottimale utilizzando come base degli alberi decisionali. Nel seguente capitolo, si farà uso del *Gradient Boosting* come framework per l'applicazione del metodo *Ensemble XGBoost* (famoso per le sue elevate prestazioni nelle competizioni Kaggle).

I motivi per cui si è scelto di implementare l'algoritmo *XGBoost* sono legati al fatto che permette di gestire efficacemente i dati mancanti, diminuire i tempi computazionali tramite la parallelizzazione e regolarizzare i dati evitando l'*overfitting*.

Per poterlo applicare, i dati dovranno prima essere processati con il formato idoneo. Il primo passo sarà dunque la trasformazione del dataset seguendo i passi dettati dalla disciplina *Knowledge Discovery in Databases (KDD)* precedentemente menzionata con l'obiettivo di facilitare all'algoritmo l'estrazione della conoscenza.

8.1 Definizione *task* da risolvere

Come già sottolineato in precedenza, con il seguente modello *XGBoost* si vuole comprendere se con la nuova configurazione dei colli si ottiene un miglioramento dei colli manipolati o se risulta necessario

all'azienda eseguire diversi scenari con un contenuto differente dei colli fino ad arrivare ad una minimizzazione del numero di colli manipolati.

Al fine di misurare il miglioramento si dovrà dunque effettuare un confronto tra la predizione del modello e la situazione corrente (cioè i risultati della collezione Autunno-Inverno 2018), analizzando il miglioramento in termini di 'percentuale di colli manipolati', 'costo manipolazione dei colli' e 'FTE'. Teoricamente la nuova configurazione dovrebbe comportare un numero di Pre-Packs manipolati pari a zero (obiettivo aziendale).

È doveroso precisare che ci si limiterà all'analisi di una sola una famiglia di prodotti, cioè le Camicie della famiglia Donna poiché la nuova combinazione è stata creata proprio a partire da questi stessi dati.

8.2 Raccolta dati

Per effettuare la raccolta dei dati necessari, si è utilizzato come base un Excel precedentemente creato dai colleghi di MANGO, attingendo a diversi report aziendali storici scaricati da SAP.

Suddetti report contenevano informazioni circa:

- quante unità di ogni prodotto sono state comprate dal business online e offline
- quante unità sono effettivamente entrate in magazzino
- quali prodotti sono stati distribuiti nei colli standard e quante unità sono state destinate a questi colli
- quanti colli standard sono stati manipolati (aperti) e quanti colli sono stati correttamente distribuiti

8.3 Pre-processamento

Il secondo passo è il pre-processamento dei dati grezzi (*raw*) collezionati dal mondo reale per creare un insieme di dati 'pulito'.

Dunque, si sono utilizzati i reports scaricati da SAP per creare un Excel uguale a quello precedentemente creato dai colleghi. Per poterlo ricreare è stato necessario usare delle tabelle pivot, VLOOKUPs e formule Excel. Si sono creati in totale tre Excel con questo formato, ognuno di essi con dati appartenenti a periodi storici differenti (cioè collezioni di moda differenti).

Durante questa fase di creazione, si sono riscontrate delle difficoltà dovute a un calcolo erroneo delle date storiche da analizzare. Inizialmente si credeva fosse corretto prendere una data qualunque dell'ultimo mese di ogni collezione. Quindi si erano presi dati corrispondenti all'ultimo giorno del mese finale di ogni collezione.

Invece, dopo aver consultato un collega, si è compresa la necessità di porre una data precisa corrispondente alla fine di ogni collezione evitando così di ottenere dei dati rumorosi. Questa data era il 24 di ogni mese finale di una collezione.

Oltretutto, si sono riscontrati altri dati rumorosi dovuti a errori nelle formule Excel usate per riempire i dati mancanti. Questi errori si sono manifestati dopo aver creato il modello e aver predetto il test. Infatti, la predizione risultava del tutto erronea, a differenza delle prime predizioni usate per creare il modello stesso. Dunque, dopo aver consultato il dipartimento, si è notato che l'errore derivava dalle formule Excel.

Alcuni valori del dataset erano inoltre assenti e per esempio non vi erano unità pendenti di entrata. Questi valori non comportavano però un dataset rumoroso e non sono stati eliminati.

Al contrario, sono stati riscontrati dei valori negativi nei reports aziendali che sono stati eliminati.

Dopo aver raccolto e pre-processato i dati, si è creato il dataset finale formato da 30 attributi, come mostrato nella seguente Tabella Fig.8.2.1:

Attributo	Valori [Rango]
BL	Numerico [10,65]
MC	Stringa
Genero	Stringa [MANGO Uomo, MANGO Violeta, Donna, MANGO Bebè Maschio, MANGO Bebè Femmina, MANGO Neonato, MANGO Bimbo, MANGO Bimba]
Genero aggruppato	Stringa [Donna, Uomo, Bambino, Violeta]
Prodotto	Stringa [Indumento, Accessorio]
N° di MC	Numerico [1]
N° di MC con CD	Numerico [0,1]
Acquisto incluso MC senza CD	Numerico [0, ∞]
Acquisto MC con CD	Numerico [0, ∞]
Tipo di Reparto	Stringa [Piegato, Appeso]
Acquisto Reale Tot	Numerico [0, ∞]
Acquisto Reale no MOL	Numerico [0, ∞]
Acquisto Reale MOL	Numerico [0, ∞]
Unità media di CD per collo	Numerico [0, ∞]
Colli comprati CD	Numerico [0, ∞]
Colli distribuiti	Numerico [0, ∞]
Colli aperti	Numerico [0, ∞]
Unità comprate CD	Numerico [0, ∞]
Unità distribuite	Numerico [0, ∞]
Unità aperte	Numerico [0, ∞]
Scommessa Firms	Numerico [0, ∞]
Ordine Firms	Numerico [0, ∞]
Unità consegnate in magazzino	Numerico [0, ∞]
Unità entrate tot	Numerico [0, ∞]
Unità entrate no MOL	Numerico [0, ∞]
Unità entrate MOL	Numerico [0, ∞]
Unità pendenti entrata tot	Numerico [0, ∞]
Unità pendenti entrata no MOL	Numerico [0, ∞]
Unità pendenti entrata MOL	Numerico [0, ∞]
% Unità entrate/ Acquisto Reale	Percentuale [0,100]

Fig.8.3.1: tabella dove figurano le colonne del dataset e i corrispondenti valori.

8.4 Spiegazione algoritmo

Anzitutto, è necessario importare diverse librerie per facilitare la creazione del modello tramite l'algoritmo *XGBoost*:

- **Numpy**: libreria open source per Python con funzioni matematiche di alto livello e che offre supporto a grandi matrici e array multidimensionali per operare con efficacia sulle strutture dei dati
- **Pandas**: libreria scritta per Python utilizzata per manipolare e analizzare i dati. È necessaria la formattazione del dataset nel formato CSV.
- **XGBoost**: libreria open source che fornisce un framework di *Gradient Boosting*.
- **Sklearn**: libreria open source che fornisce vari algoritmi di apprendimento supervisionato e non supervisionato.

Il modello è stato creato seguendo codesti passi:

1: Assegnazione Seed. Un *seed* in Machine Learning inizializza il generatore di numeri pseudocasuali. Con numeri pseudocasuali ci si riferisce ai numeri generati da un algoritmo deterministico, che produce una sequenza con approssimativamente le stesse proprietà statistiche di una sequenza di numeri generata da un processo casuale.

Dunque, il modulo casuale utilizza il valore *seed* come base per generare un numero casuale. Questa inizializzazione permette di replicare uno stesso esperimento, ottenendo dunque sempre gli stessi risultati anche se il processo consta di funzioni casuali.

In una situazione reale di verifica dell'algoritmo, come può essere la presentazione dello stesso alla commissione di laurea, grazie al *seed* risulta fattibile riprodurre gli stessi risultati mostrati nell'elaborato anche se si esegue l'esperimento in un periodo di tempo successivo.

2: Caricamento del dataset di addestramento. Si caricano i vari datasets di addestramento in formato CSV concatenandoli in un unico dataset, facendo attenzione a renderlo casuale con una funzione shuffle grazie alla quale l'ordine delle righe del dataset stesso risulta casuale.

3: Processamento delle caratteristiche categoriche. Si identificano le stringhe del dataset alfanumeriche o contenenti solo parole (cioè: MC, Genere, Genere aggruppato, Prodotto, Tipo di Reparto) e si processano per trasformarle temporaneamente in numeri. La trasformazione è necessaria dato che non si possono porre delle variabili categoriche in un'equazione di regressione lineare nel loro formato grezzo nella maggior parte delle librerie. In output, suddette variabili si trasformano di nuovo in categoriche.

4: Creazione delle variabili X e Y. Si creano le variabili indipendenti e dipendenti spiegate in precedenza. In questo caso X corrisponde alla matrice del dataset e Y corrisponde ad un vettore di variabili continue.

5: Creazione e addestramento del modello XGBoost. Si utilizza la funzione GridSearch appartenente alla libreria Sklearn per trovare i migliori valori dei diversi parametri necessari al pre-addestramento del modello. I parametri sono i seguenti:

Parametri	Valori
N° di threads	[4]
Obiettivo	Regressione lineare
Tasso di apprendimento (eta)	[0.03, 0.05, 0.20]
Profondità massima	[3, 4, 5, 6]
Peso minimo figlio	[4]
Sottoinsieme	[0.7, 1.0, 0.5]
Sottoinsieme di colonne per albero	[0.5, 0.7]
N° di estimatori	[200]

Fig.8.4.1: parametri usati nel GridSearch

- **N° di threads:** si riferisce al minimo numero di istanze utilizzate per generare un nodo foglia dell'albero decisionale ed è usato per l'esecuzione in parallelo. Se questo numero è basso, l'albero cresce e ogni nodo foglia dell'albero effettua la regressione su pochi valori. Questo può non essere un fatto negativo ma può introdurre *overfitting*. Invece, con un valore elevato del parametro, l'albero tenderà ad essere molto piccolo, generando un potenziale *underfitting*. Nel caso del modello creato, si è impostato il valore 4 per questo parametro.
- **Obiettivo:** definisce la funzione di perdita che deve essere minimizzata. In questo caso, si tratta di una regressione lineare essendo l'output numerico.
- **Tasso di apprendimento:** è il parametro che determina l'importanza dei contributi dati dai nuovi alberi rispetto alla soluzione già incontrata. Se il valore tende a zero, darà poca importanza ai

nuovi risultanti e questo potrebbe causare un *underfitting*. Invece, se il valore è molto elevato, si darà molta importanza ai nuovi risultati portando dunque ad un *overfitting*. Questo parametro determina la discesa del gradiente (*steepest descent*), cioè quanto saranno grandi i passi effettuati dal gradiente per raggiungere la funzione obiettivo. Più i passi sono piccoli, più preciso sarà il calcolo sebbene comporterà un maggiore tempo computazionale.

Si è dunque preferito inserire come possibili valori dei numeri piccoli per poter ottenere una maggiore precisione.

- **Profondità massima:** questo parametro determina la profondità degli alberi decisionali. Se il valore è basso, si ottengono degli alberi piccoli e vi è la possibilità di un *underfitting*. Al contrario, con valori grandi si generano *strong learners* invece di *weak learners*, ogni albero risulta enorme e sicuramente si ha un *overfitting*. I valori del parametro variano da 3 a 10 e in letteratura si tende a porre un 6. Nel caso del modello, si è posto un intervallo di valori tra il 3 e il 6, il valore ottimale sarà poi trovato con GridSearch.
- **Peso minimo figlio:** nella regressione lineare, corrisponde al minimo numero di istanze necessarie in ogni nodo figlio. Nell'algoritmo si è posto come valore 4.
- **Sottocampione:** l'*XGBoost* campiona casualmente una certa quantità dei dati di addestramento prima di creare gli alberi. Questa quantità è un rapporto che viene posto come parametro. Se per esempio si ha un sottocampione pari a 0.5, allora *XGBoost* prende un campione casuale pari a metà dei dati di addestramento. Questo sottocampionamento avviene in ogni iterazione.
- **Campione di colonne per albero:** è il rapporto di sottocampionamento delle colonne quando si costruisce un albero. Avviene ogni volta che si costruisce un albero.
- **N° di estimatori:** numero di alberi creati dal *XGBoost*. Tipicamente, non è un numero molto grande perché è stato dimostrato che nella maggior parte dei modelli un numero elevato di alberi non migliora le prestazioni del modello.

6: 10 volte convalida incrociata: è una tecnica usata per valutare i modelli predittivi con una partizione del campione originale in un insieme di addestramento per addestrare il modello e un insieme di test per valutarlo. In una k-volte convalida incrociata, il campione originale è suddiviso in k sottocampioni della stessa dimensione. Dei k sottocampioni, uno singolo è conservato come dato di convalida per testare il modello, e i rimanenti k-1 sottocampioni sono usati come dati di addestramento. Il processo di convalida incrociata è dunque ripetuto k volte e ogni k sottocampione viene usato esattamente una volta come dato di convalida. I k risultati derivanti dalle k ripetizioni del processo vengono combinati effettuando una media (o in altri modi) per produrre una singola stima.

Nel modello k equivale a 10, quindi si sono effettuate 10 ripetizioni del processo di convalida incrociata.

7: Creazione del dataset di test: si carica il dataset di test proprio come fatto in precedenza per l'addestramento, cioè concatenando e usando la funzione shuffle. Si processano le caratteristiche categoriche e si occultano le colonne che aiuterebbero il modello nella predizione agendo come spoilers (Colli aperti, Unità distribuite, Unità aperte). Si pone come colonna da predire Colli distribuiti e si creano le variabili X e Y di test.

8: Caricamento del modello allenato: si alimenta il modello con il test appena creato e si ottiene come risultato la predizione \hat{Y} .

9: Calcolo delle prestazioni del modello: è possibile utilizzare delle metriche per misurare con quanta accuratezza il modello è in grado di predire \hat{Y} .

- **Mean Squared Error (MSE):** è una delle funzioni di perdita più comuni. Le funzioni di perdita sono usate per calcolare l'accuratezza della predizione. Queste funzioni hanno due input: la predizione effettuata dal modello e il valore reale che si vuole predire. L'output della funzione, denominato perdita, è la misura dell'accuratezza del modello a stimare

la realtà. Un valore elevato della perdita, indica che il modello ha avuto una prestazione scadente e, viceversa, un valore basso indica una prestazione buona del modello.

Per calcolare MSE, si esegue la differenza tra la predizione del modello e il valore reale, elevata al quadrato e si esegue la media rispetto al numero di campioni usati (N). L'MSE è definito dalla seguente espressione:

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2$$

Un vantaggio di questo indicatore è che risulta molto efficace nell'assicurarsi che il modello addestrato non abbia predizioni *outliers* con grandi errori, dato che dà un peso maggiore a questi errori grazie al fatto che eleva al quadrato quella parte dell'errore.

D'altro canto, se il modello esegue una singola predizione molto erronea, la parte della funzione elevata al quadrato ne amplifica l'errore. In realtà, nella maggior parte dei casi non si tengono molto in considerazione gli outliers dato che si vuole ottenere un modello che ha delle prestazioni buone in generale. Un buon valore di MSE è un valore vicino allo zero.

Nel caso del modello creato si è ottenuto un MSE pari a 0,000617335. Questo valore indica che la differenza tra la predizione del modello e il valore reale è molto bassa.

- **R²**: è una misura statistica di quanto i dati siano vicini alla linea di regressione. I suoi valori variano dal 0% al 100%. In generale, più si ottiene un valore elevato di R², migliori sono le prestazioni del modello. Nel caso del modello creato, si è ottenuto un valore di R² piuttosto buono, pari a 94,41%.

10: Rappresentazioni della importanza delle caratteristiche: dopo aver costruito gli alberi decisionali è possibile richiedere l'importanza dei vari attributi nella ricerca della predizione ottimale. Tipicamente, più un attributo viene utilizzato per prendere decisioni chiave al momento di una partizione, maggiore è la sua importanza relativa.

La libreria di *XGBoost* ha una funzione incorporata che grafica direttamente l'importanza degli attributi utilizzata per controllare quali fossero gli attributi più importanti secondo il modello. Di seguito un elenco secondo l'ordine di importanza estratto dal grafico di output Fig. 8.4.2:

Classifica	Attributi
1	Colli comprati CD
2	N° di MC con CD
3	Unità comprate CD
4	Acquisto MC con CD
5	Unità media di CD per collo
6	Tipo di Reparto
7	Unità consegnate in magazzino
8	Acquisto Reale Tot
9	MC
10	Acquisto incluso MC senza CD
11	Unità entrate MOL
12	BL
13	Acquisto Reale no MOL
14	Genero aggruppato
15	Acquisto Reale MOL
16	Scommessa Firmes
17	% Unità entrate/ Acquisto Reale
18	Unità pendenti entrata tot
19	Unità entrate tot
20	Ordine Firmes
21	Unità pendenti entrata no MOL
22	Genero
23	Unità entrate no MOL
24	Unità pendenti entrata MOL
25	N° di MC
26	Prodotto

Fig. 8.4.2: elenco attributi seconda la loro importanza

Come si può notare, gli attributi con la maggiore importanza sono il numero di colli standard CD comprati, i prodotti di cui si è creato il collo standard e le unità comprate di CD.

8.5 Calcolo colli standard: Pre-Packs

Per poter effettuare il test finale con il modello e predire il numero di colli Pre-Packs che si andrebbero a manipolare con la nuova configurazione, in primo luogo è stato necessario calcolare quanti Pre-Packs si creerebbero con la nuova configurazione.

Per far ciò, è stato necessario recuperare gli ordini dei clienti circa i prodotti Camice, applicare delle specifiche regole per effettuare una scrematura del database e poi utilizzare Python per effettuare il calcolo. Nelle seguenti pagine vengono dettagliati i passi seguiti.

Preparazione database calcolo Pre-Packs

Per poter calcolare i Pre-Packs, si è effettuata una raccolta dei dati dal software SAP creando un report dei prodotti appartenenti alla famiglia Camicie (Donna) contenente gli ordini iniziali di ogni cliente di MANGO, suddivisi a seconda delle diverse taglie. Si è dunque ordinato tale report creando una tabella pivot in Excel, ottenendo il risultato riportato nella seguente tabella (Fig.8.5.1):

		Taglie			
Cliente	Modello-Colore	19	20	21	22
C	43005787-01		3	2	1
C	43013725-01	1	2	2	2
C	43013725-02	1	2	2	2
C	43013725-37	1	2	2	1
C	43013725-99	1	2	4	2
C	43013726-01	1	2	2	2
C	43013726-02	1	2	2	1

Fig.8.5.1: esempio di dati grezzi che mostrano gli ordini iniziali effettuati da uno stesso cliente per prodotti differenti.

Come si può notare, nella prima riga si ha un ordine iniziale inesistente della taglia 19 nel prodotto 43005787-01. In realtà, suddetta casistica si riscontra in clienti differenti e comporta un problema nella creazione dei colli dato che teoricamente per suddetto cliente non si soddisferebbe la combinazione base del Pre-Packs (1:2:2:1). Perciò, si andrebbero così a creare troppi colli individuali.

Per ovviare a questo problema, è stato necessario eseguire un pre-processamento del database seguendo due linee guida:

1. Controllare se esistono dei clienti con ordine iniziale presente solo per una o due taglie.
2. Controllare in quali prodotti non è presente un ordine iniziale su una o più taglie per tutti i clienti di MANGO e cambiare la nuova configurazione a seconda delle necessità.

Con la prima regola sono stati individuati quei clienti con prodotti ordinati solo in una o due taglie. Dunque, quelle unità incompatibili nel calcolo dei Pre-Packs sono state scartate e poste direttamente in colli individuali. Nell'esempio seguente si possono notare due prodotti differenti per lo stesso cliente con una distribuzione di taglie ordinate differenti (Fig.8.5.2).

Cliente	Modello-Colore	19	20	21	22
D	43085723-99	200	425	363	167
D	43085817-99		222	155	

Fig.8.5.2: esempio cliente con ordini differenti circa la distribuzione delle taglie

Gli ordini iniziali del prodotto 43085723-99 sono stati usati per il calcolo del collo standard mentre il prodotto 43085817-99 ordinato solamente in due taglie è stato eliminato dal database. Le unità che contiene verranno inserite in dei colli individuali.

Una volta effettuata questa scrematura iniziale a livello micro, è stata applicata la seconda regola che consiste in un cambio della nuova configurazione nel caso non ci sia un ordine in una taglia per un determinato prodotto a livello globale. Il tutto per evitare di creare troppi colli individuali. Dunque, fornendo un esempio con la seguente tabella (Fig.8.5.3):

Modello-Colore	19	20	21	22
41000896-02	145	268	231	108
41000896-06		203	168	95

Fig.8.5.3: Tabella generale con sommatoria dei differenti clienti per ogni prodotto ordinato.

Il prodotto 41000896-02 contiene ordini di tutte le taglie e quindi per il calcolo del collo è stata utilizzata la combinazione standard 1:2:2:1 (per le corrispondenti taglie: 19, 20, 21, 22).

Invece, per il prodotto 41000896-06 non si ha ordine iniziale della taglia 19 per nessuno dei clienti di MANGO. Perciò, la combinazione cambia divenendo 2:2:1 (per le corrispondenti taglie: 20, 21, 22).

La seguente tabella (Fig.8.5.4) mostra il risultato di suddetto pre-processamento, Come si può notare vi sono casi dove per uno stesso cliente viene eliminato il Pre-Packs o casi dove il Pre-Packs consta di unità differenti (6 o 5).

Cliente	Modello-Colore	Taglie				Commenti	Unità Pre-Packs
		19	20	21	22		
100000	43085817-99		222	155		Eliminare	0
100000	43087757-02	190	255	261	151		6
100000	43090845-70	53	101	98	54		6
100000	43099063-02		835	628	324		5
10002	41000896-02	3	5	4	2		6
10002	41029088-02		6	4	2		5

Fig.8.5.4: Risultato finale seguendo le linee guida di MANGO dove si evidenziano gli ordini iniziali nelle varie tagli, i commenti circa l'eliminazione di una riga e le unità previste nei Pre-Packs.

Dunque, per poter effettuare il calcolo vero e proprio è stato necessario l'utilizzo di due differenti database. Il primo database estrapolato dal database usato per l'esempio in Fig.8.5.4 e denominato PI nella tabella Fig.8.5.5. L'ultima colonna è stata momentaneamente occultata durante il calcolo non essendo necessaria, ma è stata mantenuta perché utile nella creazione del Test finale dato in pasto al modello.

Cliente	Modello-Colore	19	20	21	22	Unità Pre-Packs
100000	43087757-02	190	255	261	151	6
100000	43090845-70	53	101	98	54	6
100000	43099063-02		835	628	324	5
10002	41000896-02	3	5	4	2	6
10002	41029088-02		6	4	2	5

Fig.8.5.5: Database PI

Il secondo database denominato CO (Combinazione) di cui un esempio nella Fig.8.5.6, è stato creato ad hoc perché contiene gli stessi attributi del PI senza la colonna Unità Pre-Packs. Al posto delle unità ordinate reali è stato posta la combinazione standard 1:2:2:1. Si sono inoltre tenuti in considerazione i casi in cui in PI non vi era nessun ordine iniziale, riflettendo la stessa situazione in CO e ottenendo il seguente risultato:

Cliente	MC Base	19	20	21	22
100000	43087757-02	1	2	2	1
100000	43090845-70	1	2	2	1
100000	43099063-02		2	2	1
10002	41000896-02	1	2	2	1
10002	41029088-02		2	2	1

Fig.8.5.6: Database CO (Combinazione)

Notazioni

Da un punto di vista formale il database PI può essere definito come una funzione:

$$PI : \{1, \dots, i\} \times \{1, \dots, j\} \rightarrow Z^+_0$$

Dove i e j sono numeri interi positivi appartenenti all'insieme dei numeri reali (incluso lo zero). Si indicherà con $[PI]_{ij}$ l'elemento posizionato nella riga i -esima e colonna j -esima.

Allo stesso modo, il database Combinazione può essere definito come una funzione:

$$CO : \{1, \dots, i\} \times \{1, \dots, j\} \rightarrow Z^+$$

Dove i e j sono numeri interi positivi appartenenti all'insieme dei numeri interi (incluso lo zero). Si indicherà con $[CO]_{i,j}$ l'elemento posizionato nella riga i -esima e colonna j -esima.

Calcolo teorico

Successivamente, si effettua una divisione tra le due matrici occultando temporaneamente la colonna Unità Pre-Packs del database PI, superflua ai fini del calcolo ma necessaria nelle fasi successive. Dunque, si ottiene un'altra matrice risultato R1 definita nella seguente maniera:

$$R1 : \{1, \dots, i\} \times \{1, \dots, j\} \rightarrow Q^+$$

Dove i e j sono numeri decimali positivi appartenenti all'insieme dei numeri razionali escluso lo zero. Si indicherà con $[R1]_{i,j}$ l'elemento posizionato nella riga i -esima e colonna j -esima. Essendo però un numero reale, si effettuerà un arrotondamento per difetto tramite la funzione floor, con la seguente espressione:

$$[R1]_{i,j} = \left\lfloor \frac{[PI]_{i,j}}{[CO]_{i,j}} \right\rfloor$$

Successivamente, per ogni riga i si estrapolerà il minimo, ottenendo una matrice R2 di dimensione ridotte rispetto alle precedenti:

$$R2 : \{1, \dots, a\} \times \{1, \dots, b\} \rightarrow Z^+$$

Risultato

Il risultato intermedio del calcolo precedente senza la selezione del minimo sarà dunque il seguente (con l'aggiunta della colonna Unità Pre-Packs):

Cliente	Modello- Colore	19	20	21	22	Unità Pre- Packs
100000	43087757-02	190	127	130	151	6
100000	43090845-70	53	50	49	54	6
100000	43099063-02		417	314	324	5
10002	41000896-02	3	2	2	2	6
10002	41029088-02		3	2	2	5

Fig.8.5.7: Risultato intermedio del calcolo

Dunque, Python estrapola direttamente il minimo di ogni riga, ottenendo il seguente risultato finale:

Cliente	Modello- Colore	Numero Pre-Packs	Unità Pre- Packs
100000	43087757-02	127	6
100000	43090845-70	49	6
100000	43099063-02	314	5
10002	41000896-02	2	6
10002	41029088-02	2	5

Fig.8.5.8: Risultato finale del calcolo

Suddetto risultato viene trasferito in un Excel per poter eseguire una pivot table e ottenere il numero di Pre-Packs creati per ogni prodotto, così come le unità medie presenti nei Pre-Packs e le unità totali.

Modello-Colore	N° Pre-Packs	Media unità nei Pre-Packs	Unità tot nei Pre-Packs
41000765-02	2561	5,952038369	15243
41000765-35	2854	5,956586826	17000
41000765-85	2774	5,950900164	16507

Fig.8.5.9: Risultato finale aggregato per ogni prodotto

Successivamente, è stata creata la seguente tabella tenendo conto del limite del 33% menzionato in precedenza, secondo il quale solo il 33% dell'Acquisto reale può essere destinato ai colli standard.

Applicando suddetto limite, si sono notate delle discrepanze tra i Pre-Packs creati da Python e i Pre-Packs che MANGO realmente desidera creare.

Si è quindi dedotto che nel caso in cui Python dica di creare più Pre-Packs del limite consentito, si calcolano quanti Pre-Packs MANGO desidera che siano creati con il limite del 33% e si considerano quest'ultimi come Pre-Packs finali.

Nel caso in cui Python dica di creare un numero minore di Pre-Packs rispetto al limite del 33%, si tengono in considerazione i Pre-Packs dettati da Python, dato che seguendo le due regole citate prima non si potrebbero creare più Pre-Packs di quelli calcolati da Python. Il risultato ottenuto è dunque il seguente:

Modello-Colore	Colli Pre-Packs Python	Unità nei Pre-Packs Python	Unità destinate a colli standard (limite 33%)	Pre-Packs con limite 33%	Pre-Packs reali	Unità Pre-Packs reali
41000765-02	2561	15243	8709	1463	1463	8707
41000765-35	2854	17000	11625	1951	1951	11621
41000765-85	2774	16507	9946	1671	1671	9943
41000765-95	2570	15304	9303	1562	1562	9301
41000802-99	1414	7070	5114	1022	1022	5110
41000896-02	103	618	5827	971	103	618
41000896-06	81	486	4830	805	81	486

Dunque, una volta calcolati il numero di Pre-Packs reali così come le unità per ogni prodotto, si è creato il test finale da introdurre nell'algoritmo per ottenere la predizione.

8.6 Analisi: Predizione vs. Realtà

Nelle seguenti tabelle vengono posti rispettivamente i risultati ottenuti con la predizione e i risultati reali per poter effettuare un confronto tra le due situazioni. La Fig. 8.6.1 è un esempio del risultato finale della predizione mentre la Fig. 8.6.2 rappresenta la situazione reale.

Modello- Colore	Unità media Pre- Packs	N° Pre- Packs	Pre-Packs distribuiti	Pre-Packs aperti	Unità in Pre-Packs	Unità Pre- Packs distribuite	Unità Pre-Packs aperte
43099063-02	5	325	325	0	1625	1625	0
43095034-19	5	552	552	0	2760	2760	0
43093723-79	6	1830	1830	0	10980	10980	0
43093723-37	6	1996	1714	282	11976	10284	1692
43093723-15	6	1969	1698	271	11814	10188	1626

Fig. 8.6.1: Risultato predizione

Modello- Colore	Unità media CD	N° CD	CD distribuiti	CD aperti	Unità in CD	Unità CD distribuite	Unità CD aperte
43099063-02	8	486	486	0	4128	4128	0
43095034-19	16	205	194	11	3273	3068	205
43093723-79	13	652	652	0	8830	8830	0
43093723-37	10	1230	1220	10	12358	12228	130
43093723-15	10	1268	1192	76	12780	11792	988

Fig. 8.6.2: Situazione reale

Si sono dunque calcolati i KPI per poter valutare una possibile migioria del processo:

Percentuale di colli manipolati

Prendendo in considerazione questi dataset di esempio, si è analizzato l'output della predizione a un livello micro, notando che:

- Per il primo prodotto si ha una percentuale di colli standard aperti pari a 0 in entrambi i casi (nonostante i colli creati come Pre-Packs e CD differiscano in quantità). Quindi la nuova combinazione risulterebbe efficace.
- Per il secondo prodotto la percentuale di colli standard Pre-Packs aperti è uguale a 0% mentre i CD aperti nella situazione reale corrispondono ad un 5%. In questo caso la nuova combinazione risulta essere migliore della precedente. Da notare che il numero di colli creati come Pre-Packs sono 552 invece dei 205 CD, quindi 347 colli in più e nonostante ciò, si predice che vengano distribuiti tutti.
- Per il terzo prodotto si ha una percentuale di colli standard aperti pari a 0 in entrambi i casi, nonostante vengano creati 1178 Pre-Packs in più rispetto ai 652 CD.
- Per il quarto prodotto la situazione cambia dato che il 14% dei Pre-Packs vengono aperti rispetto al 1% di CD che sono stati aperti nella realtà. In questo caso la nuova combinazione non migliorerebbe il processo di distribuzione.
- Per il quinto prodotto il 14% dei Pre-Packs vengono aperti rispetto al 6% di CD. Dunque, la nuova combinazione risulterebbe meno efficace del presente.

Nel seguente grafico viene illustrato il confronto a livello micro tra predizione e realtà appena descritto:

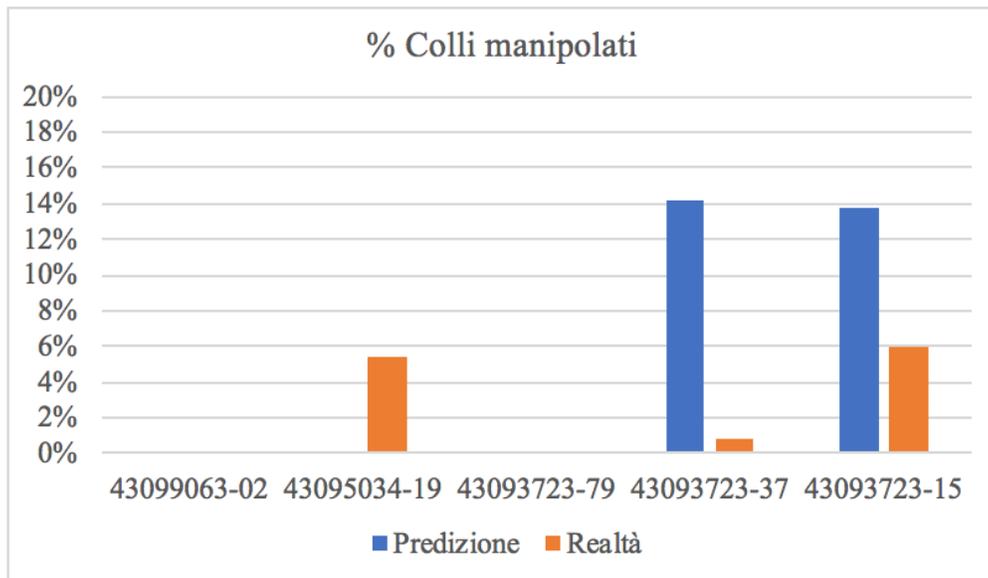


Fig. 8.6.3: confronto a livello micro della predizione e della realtà

Si è analizzato l'impatto reale della nuova combinazione rispetto alla combinazione del passato a livello macro. Il seguente grafico Fig.8.6.4 mostra qual è la percentuale di colli manipolati sui colli totali creati nei due scenari: Pre-Packs con il limite menzionato precedentemente del 33% e situazione reale.

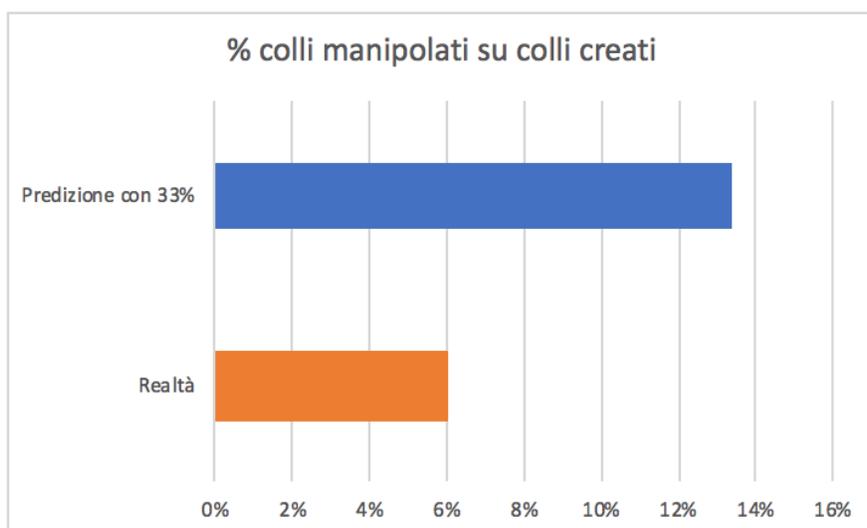


Fig. 8.6.4: Confronto colli manipolati Pre-Packs (con limite del 33%) e CD

Come si può notare, la nuova combinazione comporta un 13,4% di Pre-Packs manipolati che è in realtà superiore rispetto al 6% dei CD manipolati finora.

Oltretutto, la nuova combinazione comporta un acquisto più elevato di colli. Nello specifico si realizzano 272214 invece dei 193871 colli, cioè un 40,4% di colli standard in più come mostrato dal grafico Fig.8.6.5.

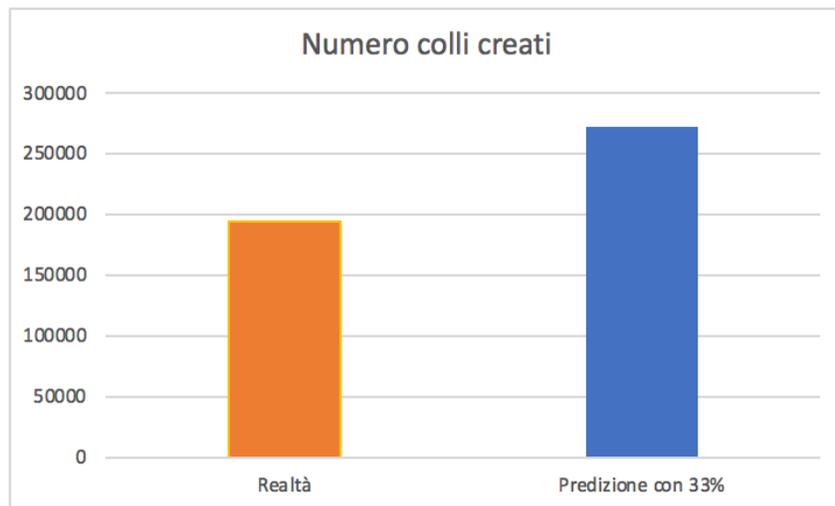


Fig. 8.6.5: Confronto numero colli creati tra realtà e predizione

Si hanno dunque dei costi maggiori di creazione dei colli a monte dato che devo essere creati un numero maggiore di colli.

FTE

È un indicatore che esprime il numero di risorse utilizzate a tempo pieno per svolgere una determinata attività. Il *Full Time Equivalent* (FTE) si calcola dividendo il tempo associato allo svolgimento di una certa attività rispetto al tempo disponibile.

L'attività di manipolazione dei colli standard consta delle seguenti fasi:

- **Picking** (automatizzato): il collo viene estratto dalla sua ubicazione nel magazzino e portato tramite un nastro trasportatore di fronte all'operatore. In media si impiegano 30 secondi;
- **Apertura** (manuale): l'operatore apre il collo. In media si impiegano 15 secondi;
- **Impacchettamento** del prodotto (manuale): l'operatore prende il prodotto dal collo standard e lo deposita in un altro collo individuale. Il tempo di questa fase dipende dal numero di righe d'ordine che l'operatore deve soddisfare. In media si impiegano 35 secondi per riga d'ordine;
- **Spostamento** del nuovo collo individuale sul nastro trasportatore (manuale): una volta soddisfatte le righe d'ordine per un determinato collo individuale, l'operatore lo deposita su un nastro trasportatore. In media si impiegano 10 secondi;
- **Chiusura** del collo (automatizzato): il collo viene chiuso ed etichettato automaticamente. In media si impiegano 5 secondi.

Il contenuto medio di un collo standard con la combinazione attuale corrisponde a 9 unità di prodotto, ciò significa che a seconda della fase vengono impiegate le seguenti tempistiche per la manipolazione di 1 collo:

Fase	Tempo impiegato in media [s]
Picking – auto	30
Apertura – manuale	15
Impacchettamento – manuale	315
Spostamento – manuale	10
Chiusura - auto	5
Totale	375

Considerando una media di 21 giorni lavorativi al mese e il fatto che nel settore della moda una collezione corrisponde a 6 mesi, nella collezione Autunno-Inverno 2018 sono stati manipolati 11.370 colli standard

con la combinazione attuale. Questo significa che in un mese sono stati manipolati 1895 colli e ogni giorno sono stati manipolati 90 colli.

Considerando che 1 FTE corrisponde a 8 ore lavorative, e che nella situazione attuale vengono manipolati 90 colli standard al giorno, si ottengono i seguenti FTE per ognuna delle fasi precedentemente menzionate dividendo il tempo impiegato da ogni fase per 480 minuti (cioè 8 ore):

Fase	Tempo impiegato in media [min]	FTE [min]
Picking – auto	46	0,096
Apertura – manuale	23	0,048
Impacchettamento – manuale	474	0,988
Spostamento – manuale	16	0,033
Chiusura - auto	8	0,017
Totale	564	1,175

Perciò per poter soddisfare la domanda di colli standard manipolati giornaliera, servono 1,175 FTE e pertanto 9,4 ore. Considerando che un operatore di MANGO destina approssimativamente solo 1 ora/gg del suo tempo alla manipolazione dei colli, per poter sopperire alla domanda giornaliera servono 10 operatori.

Si applica dunque la stessa logica alla nuova soluzione di colli Pre-Packs, il cui contenuto medio è 6 unità di prodotto. Ciò significa che a seconda della fase vengono impiegate le seguenti tempistiche per la manipolazione di 1 collo:

Fase	Tempo impiegato in media [s]
Picking – auto	30
Apertura – manuale	15
Impacchettamento – manuale	210
Spostamento – manuale	10
Chiusura - auto	5
Totale	270

Secondo la predizione del modello, nella collezione Autunno-Inverno 2018 si manipolano 36498 colli Pre-Packs. Mantenendo le ipotesi citate in precedenza, questo significa che vengono manipolati 290 colli al giorno. Si ottengono dunque i seguenti FTE per ognuna delle fasi:

Fase	Tempo impiegato in media [min]	FTE [min]
Picking – auto	145	0,302
Apertura – manuale	73	0,152
Impacchettamento – manuale	1014	2,113
Spostamento – manuale	49	0,102
Chiusura - auto	25	0,052
Totale	1304	2,717

Perciò per poter soddisfare la domanda di colli Pre-Packs manipolati giornaliera, servono 2,717 FTE e pertanto 21,7 ore. Dunque, per poter sopperire alla domanda giornaliera servono 22 operatori.

Considerando che con la soluzione attuale vengono utilizzati 10 operatori e che con la nuova soluzione se ne dovrebbero usare 22, la nuova soluzione comporta 12 lavoratori in più con un aumento percentuale di FTE pari a +131%.

Costo manipolazione dei colli

Per poter valutare l'impatto economico, si è introdotto un altro indicatore relativo al costo di manipolazione dei colli. Per una questione di riservatezza, non si riportano i valori in euro ma bensì in unità monetarie. Ovviamente si deve considerare che il costo della fase di impacchettamento varia a seconda delle unità smistate.

Nella combinazione attuale, i costi delle varie fasi di manipolazione con un collo standard contenente 9 unità in media sono i seguenti:

Fase	Costo in unità monetaria
Picking – auto	0,06
Apertura – manuale	0,03
Impacchettamento – manuale	0,9
Spostamento – manuale	0,02
Chiusura - auto	0,01
Costo totale	1,02

Ciò significa che per ogni collo standard manipolato si devono pagare 1,02 unità monetarie. Considerando che il numero di colli manipolati ogni giorno equivalgono a 90, il costo di manipolazione giornaliero equivale a $1,02 \times 90 = 91,8$ unità monetarie.

Con la nuova soluzione certamente il costo di manipolazione di un collo è minore, essendo il contenuto pari a 6 unità:

Fase	Costo in unità monetaria
Picking – auto	0,06
Apertura – manuale	0,03
Impacchettamento – manuale	0,6
Spostamento – manuale	0,02
Chiusura - auto	0,01
Costo totale	0,72

Essendo però i colli Pre-Packs giornalieri manipolati 290, il costo totale è più elevato e pari a 208,8 con un incremento percentuale del 127% rispetto alla soluzione attuale.

9. Conclusione e sviluppi futuri

L'obiettivo generale dell'elaborato è stata dunque l'analisi di un micro-processo aziendale per comprendere se il cambiamento circa il contenuto e il formato dei colli aziendali comporta un effettivo miglioramento o se risulta necessario all'azienda eseguire diversi scenari con un contenuto differente dei colli fino ad arrivare ad una minimizzazione del numero di colli manipolati. Per poter giungere a una conclusione si è usato un algoritmo di machine learning e si sono analizzati i risultati tramite tre KPI differenti.

9.1 Conclusione

In seguito, vengono espone le conclusioni tratte dall'attività di elaborazione della tesi:

Importanza di un dataset corretto:

Fondamentale per la buona riuscita della creazione di un modello di machine learning come l'*XGBoost* è l'utilizzo di un dataset corretto. Durante lo sviluppo della tesi è stato infatti necessario manipolare il dataset varie volte, aumentando dunque la quantità di tempo impiegata nell'elaborazione dell'algoritmo.

Anzitutto, si è dovuto effettuare un lavoro di scrematura iniziale scegliendo il periodo di tempo corretto in cui scaricare i dati. Successivamente, si sono riscontrati dei dati rumorosi dovuti a formule erronee nell'Excel.

Infine, alcuni dati nel database erano negativi ed è stato necessario eliminarli, mentre altri dati che risultavano mancanti non sono stati eliminati dato che non influenzavano il risultato della predizione.

Gli errori riguardanti le formule e i valori negativi sono stati riscontrati solo dopo aver creato il modello constatando che le predizioni non erano corrette. Pertanto, considerando la quantità di tempo che è stata impiegata durante l'attività di tesi per sistemare il database, una conclusione che risulta importante trarre riguarda l'importanza di lavorare con un database adeguato.

Validazione del modello:

Altra conclusione fondamentale riguarda la necessità di fare affidamento a indicatori circa le prestazioni del modello. Gli indicatori rendono possibile effettuare un'analisi immediata dell'accuratezza del modello creato.

Essendo il problema trattato una regressione lineare, è stata necessaria effettuare una ricerca degli indicatori utili alla validazione del modello, individuandone due: MSE e R^2 . Questi indicatori sono risultati fondamentali per poter comprendere con maggiore facilità la precisione del modello senza dover guardare uno ad uno i risultati della predizione.

Analisi della nuova combinazione:

L'analisi effettuata utilizzando i vari KPI dimostra che la nuova combinazione non comporta un miglioramento del processo attuale. Infatti, facendo riferimento ai KPI analizzati:

- La percentuale di colli manipolati aumenta del 7,4%.
- FTE aumenta del 131% con un numero di lavoratori pari a 22 invece che 10.
- Il costo di manipolazione dei colli è maggiore del 127% rispetto alla soluzione attuale.

Una possibile causa del mancato miglioramento potrebbe essere attribuita al limite del 33% sulle unità riservate ai colli standard.

Si è dunque deciso di eliminare questo limite per vedere quanti Pre-Packs venissero suggeriti da Python. Essendo però il numero suggerito maggiore rispetto al numero con il limite, si è dedotto che probabilmente il modello avrebbe predetto un numero di casse manipolate maggiore. Come si può notare dalla Fig.9.1.1, i colli creati senza il limite sono appunto 377347:

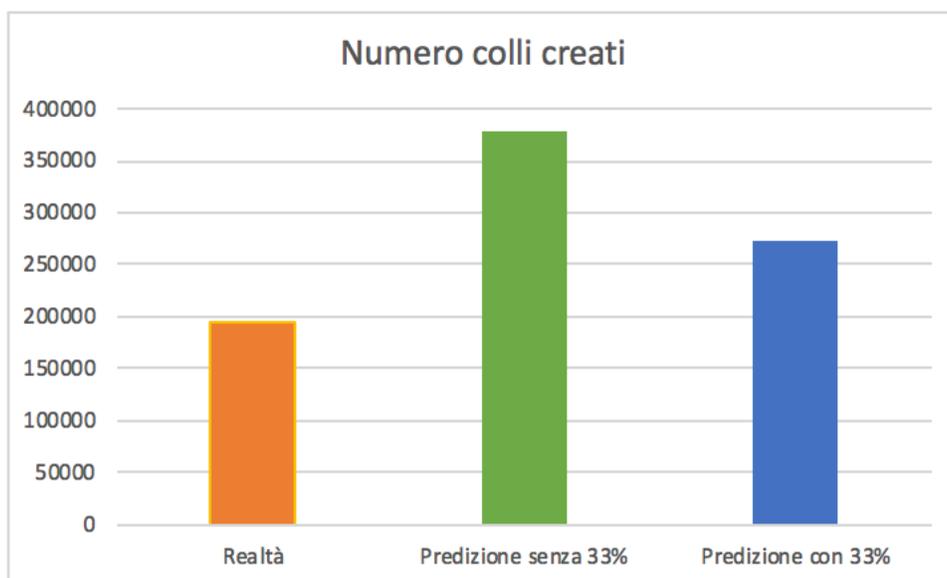


Fig.9.1.1: Confronto dei colli creati nella realtà e nella predizione con e senza il limite

Si è comunque analizzata la predizione con il KPI 'percentuale di colli manipolati' ottenendo i seguenti risultati:

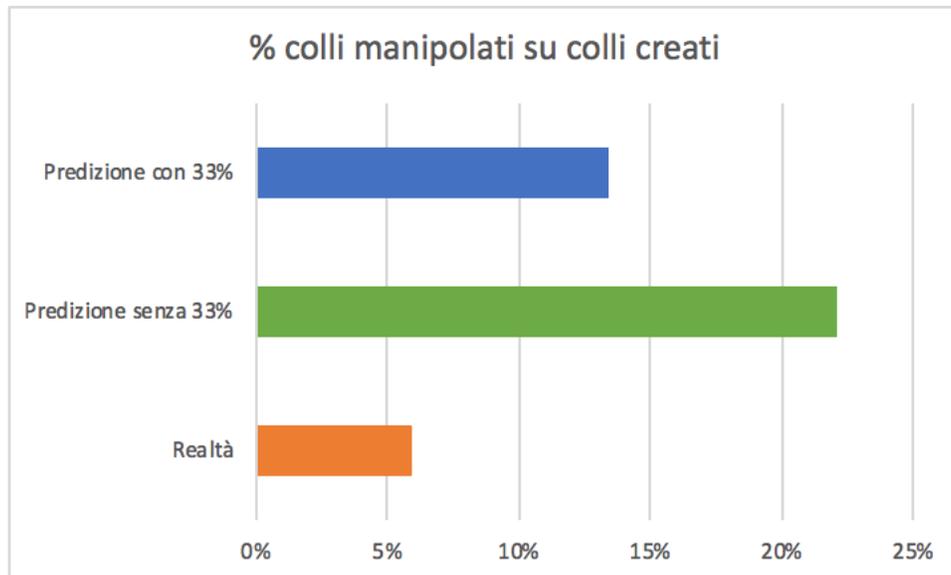


Fig.9.1.1: Confronti colli manipolati tra realtà, predizione con limite del 33% e senza il limite.

Come anticipato, nel caso MANGO eliminasse il limite del 33% non otterrebbe comunque un miglioramento.

9.2 Sviluppi futuri

Per quanto riguarda gli sviluppi futuri, sicuramente MANGO dovrebbe calcolare le ore lavorative risparmiate grazie a una pallettizzazione più efficace dovuta al formato della scatola 40x40x60 dentro al quale vengono posti più Pre-Packs. Nel caso ritenga che il costo risparmiato copra il nuovo costo di manipolazione, potrebbe dunque adottare la combinazione di cui si è parlato finora.

Altrimenti dovrebbe valutare la possibilità di effettuare esperimenti iterativi cambiando il contenuto dei colli, così da fornire al modello più scenari da analizzare. Ciò consentirebbe di migliorare il potere predittivo dello stesso, così da permettere un incremento dell'efficienza del processo. Oltretutto, tramite i diversi esperimenti l'azienda potrebbe trovare la configurazione ottimale del contenuto dei colli andando a ridurre al minimo la manipolazione.

MANGO potrebbe anche valutare la possibilità che la creazione di una combinazione per famiglia possa essere una facilitazione estrema dello standard e che sia dunque necessario creare una combinazione basata sui modelli e le taglie distribuite più frequentemente.

Infine, come spunto futuro potrebbe anche essere interessante utilizzare la tecnica di machine learning denominata *Random Forest* e confrontare i due modelli creati.

REFERENZE

1. <http://nuovadidattica.lascuolaconvoi.it/agire-educativo/16-la-competenza-riflessiva/agire-riflessivo/>
2. <https://blog.4ward.it/le-quattro-p-del-change-management>
3. <https://www.emeraldinsight.com/doi/pdfplus/10.1108/IJPPM-10-2012-0108>
4. <https://www.ipma.world/individuals/standard/>
5. <https://change.walkme.com/2019-change-management/>
6. <https://www.ipma.world/individuals/standard/>
7. <https://www.edv-buchversand.de/sap/chapter.php?cnt=getchapter&id=gp-104.pdf>
8. <http://insights.btoes.com/resources/what-is-process-architecture-modeling-and-mapping>
9. http://www.parla.cat/pres_catalaenlinia/AppPHP/login/index.php
10. <https://www.asug.com/news/change-management-is-the-only-constant-in-it>
11. <https://www.asug.com/news/preparing-for-sap-s-4hana-related-change-management>
12. <https://www.slideshare.net/TechedgeGroup/change-control-management-in-sap-solution-manager-72>
13. <https://www.computerworlduk.com/it-leadership/change-management-derails-northern-gas-networks-s-4hana-migration-3678703/>
14. <https://www.sap.com/products/management-of-change-moc.html>
15. <https://www.youtube.com/watch?v=Eh6YtvPV7MI>
16. [https://it.wikipedia.org/wiki/Change_Management_\(ITSM\)](https://it.wikipedia.org/wiki/Change_Management_(ITSM))
17. <https://www.economyup.it/innovazione/change-management-che-cos-e-e-perche-e-indispensabile-alle-aziende/>
18. https://www.linkedin.com/pulse/evolution-change-management-burhan-syed-pmp?trk=pulse_spock-articles
19. https://www.linkedin.com/pulse/evolution-change-management-burhan-syed-pmp?trk=pulse_spock-articles
20. https://en.wikipedia.org/wiki/Technology_acceptance_model
21. [https://books.google.es/books?id=wE3OCwAAQBAJ&pg=PA54&lpg=PA54&dq=Boston+Consulting+Group+\(BCG\)+Change+Delta&source=bl&ots=8_YiqOX3SB&sig=ACfU3U0XPI48bbDzBEArejHOo39P_9gIDg&hl=it&sa=X&ved=2ahUKEwiTx6yPn9nhAhXIA2MBHW4RBEw](https://books.google.es/books?id=wE3OCwAAQBAJ&pg=PA54&lpg=PA54&dq=Boston+Consulting+Group+(BCG)+Change+Delta&source=bl&ots=8_YiqOX3SB&sig=ACfU3U0XPI48bbDzBEArejHOo39P_9gIDg&hl=it&sa=X&ved=2ahUKEwiTx6yPn9nhAhXIA2MBHW4RBEw)

[Q6AEwDnoEAgQAQ#v=onepage&q=Boston%20Consulting%20Group%20\(BCG\)%20Change%20Delta&f=false](https://www.bcg.com/press-room/articles/2017/07/07/bcg-change-management-delta)

22. <https://it.wikipedia.org/wiki/Reingegnerizzazione>
23. <https://www.brightline.org/resources/getting-smart-about-change-management/>
24. <http://www.change-management.com/ecmlab/ECM-Lab-Preread-M-Model.pdf>
25. <https://www.sciencedirect.com/topics/computer-science/process-redesign>
26. https://www.bcg.com/search.aspx?q=Change%20Management&sort=_score_desc
27. <https://www.process.st/change-management-strategy/>
28. <https://towardsdatascience.com/workflow-of-a-machine-learning-project-ec1dba419b94>
29. <https://it.wikipedia.org/wiki/Matrice>
30. <https://lorenzogovoni.com/machine-learning-e-funzionamento/> (BUON LINK RIVEDERE)
31. https://it.wikipedia.org/wiki/Apprendimento_automatico
32. <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>
33. https://it.wikipedia.org/wiki/Convalida_incrociata
34. <https://towardsdatascience.com/understanding-the-bias-variance-tradeoff-165e6942b229>
35. <https://towardsdatascience.com/a-guide-to-decision-trees-for-machine-learning-and-data-science-fe2607241956>
36. https://en.wikipedia.org/wiki/Labeled_data
37. https://it.wikipedia.org/wiki/Albero_di_decisione
38. <https://medium.com/@chiragsehra42/decision-trees-explained-easily-28f23241248>
39. <https://towardsdatascience.com/decision-trees-d07e0f420175>
40. <http://www.federica.unina.it/economia/analisi-statistica-sociologica/alberi-classificazione/>
41. <https://towardsdatascience.com/ensemble-methods-in-machine-learning-what-are-they-and-why-use-them-68ec3f9fef5f>
42. <https://www.datasciencecentral.com/profiles/blogs/want-to-win-at-kaggle-pay-attention-to-your-ensembles>
43. <https://medium.com/mlreview/gradient-boosting-from-scratch-1e317ae4587d>
44. <https://www.edureka.co/blog/boosting-machine-learning/>
45. <https://hackernoon.com/boosting-algorithms-adaboost-gradient-boosting-and-xgboost-f74991cad38c>
46. <https://towardsdatascience.com/an-implementation-and-explanation-of-the-random-forest-in-python-77bf308a9b76>

47. <http://enhancedatascience.com/2017/06/28/machine-learning-explained-bagging/>
48. <https://www.datasciencecentral.com/profiles/blogs/want-to-win-at-kaggle-pay-attention-to-your-ensembles>
49. <https://towardsdatascience.com/https-medium-com-vishalmorde-xgboost-algorithm-long-she-may-rein-edd9f99be63d>
50. <https://towardsdatascience.com/l1-and-l2-regularization-methods-ce25e7fc831c>
51. <https://www.sciencedirect.com/topics/computer-science/process-redesign>
52. <https://machinelearningmastery.com/tune-number-size-decision-trees-xgboost-python/>
53. https://it.wikipedia.org/wiki/Numeri_pseudo-casuali
54. <https://www.edureka.co/community/25335/what-exactly-is-the-function-of-random-seed-in-python>
55. <https://www.talentica.com/blogs/handling-categorical-features-in-machine-learning/>
56. <https://it.wikipedia.org/wiki/NumPy>
57. <https://xgboost.readthedocs.io/en/latest/parameter.html>
58. <https://www.geeksforgeeks.org/multithreading-python-set-1/>
59. http://wiki.fast.ai/index.php/Gradient_Descent
60. <https://www.datasciencecentral.com/profiles/blogs/regression-analysis-how-do-i-interpret-r-squared-and-assess-the>
61. <https://towardsdatascience.com/understanding-the-3-most-common-loss-functions-for-machine-learning-regression-23e0ef3e14d3>
62. <https://www.datasciencecentral.com/profiles/blogs/regression-analysis-how-do-i-interpret-r-squared-and-assess-the>
63. https://en.wikipedia.org/wiki/Full-time_equivalent

APPENDICE

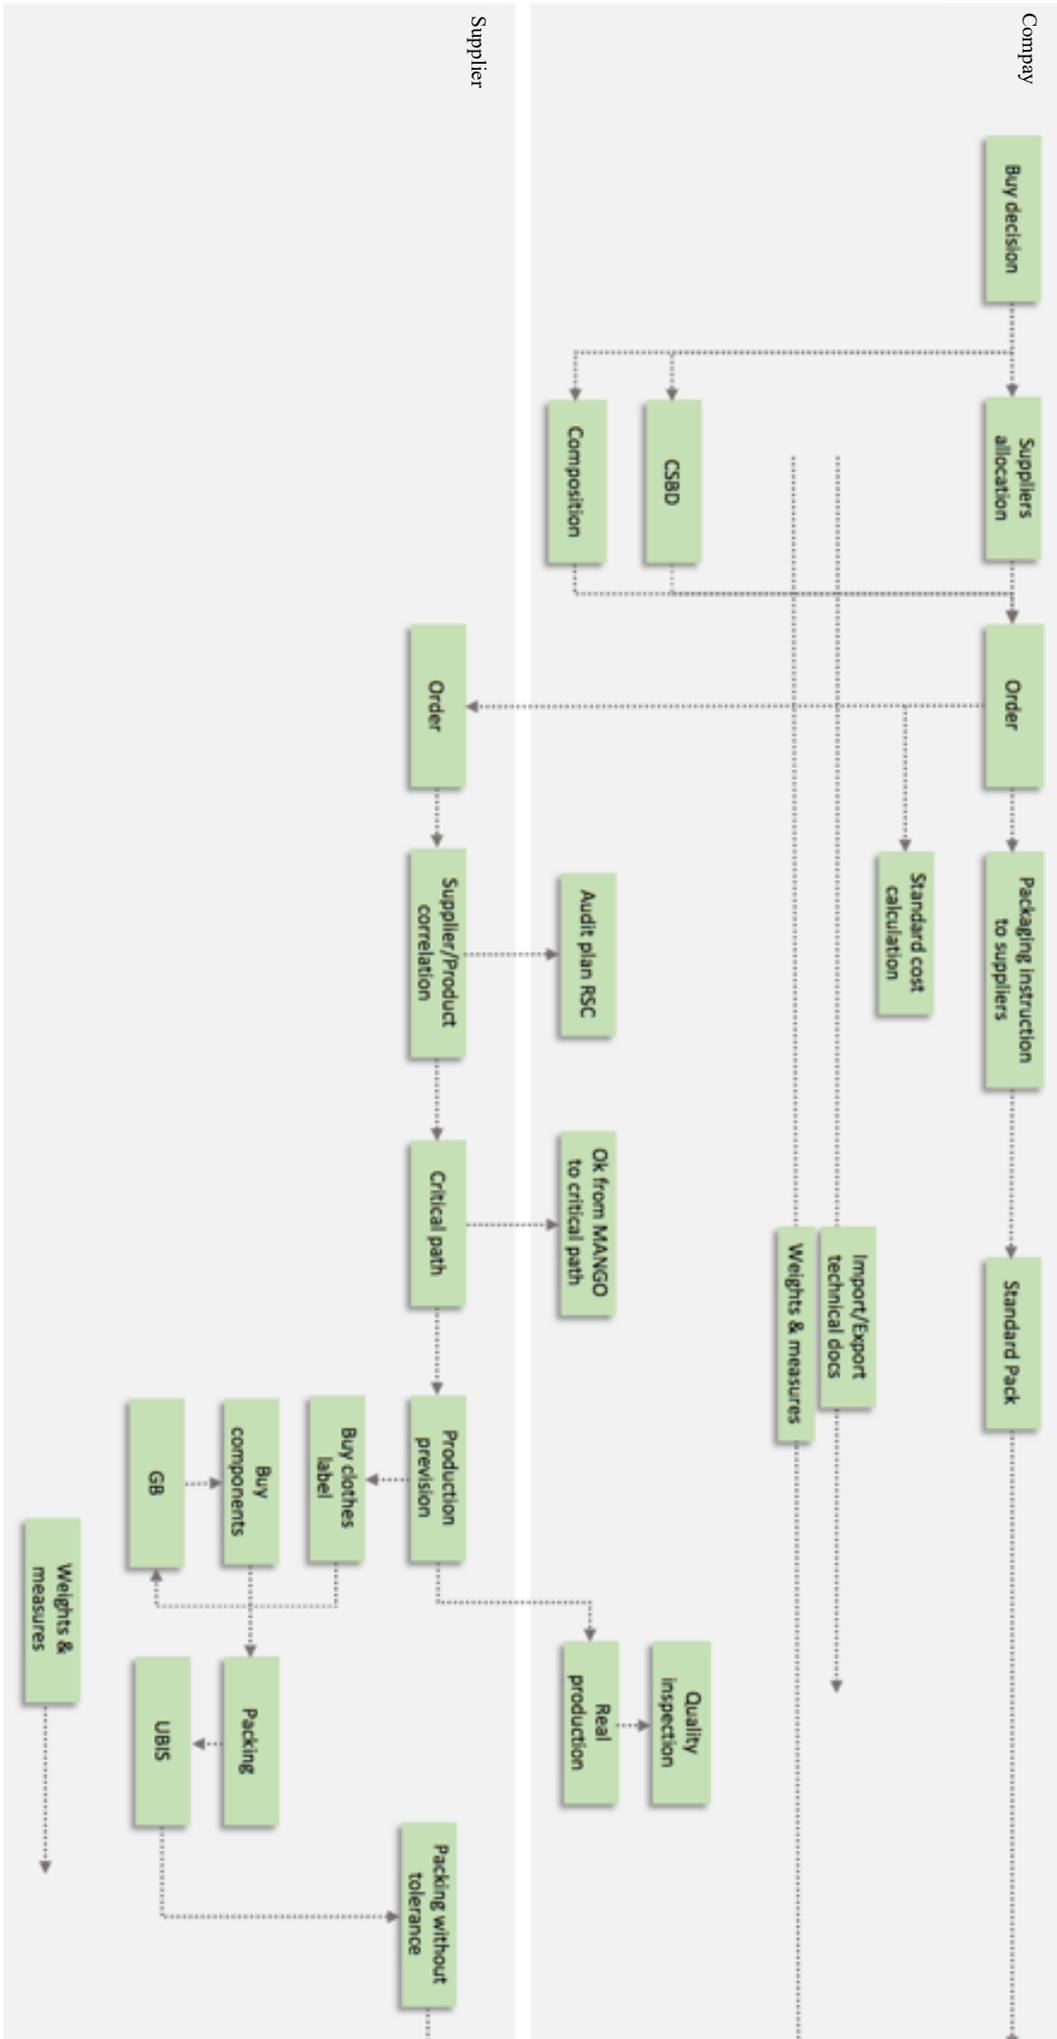
Capitolo 8, rappresentazione di due istanze appartenenti a uno dei tre dataset (di minimo 400 istanze) usati per addestrare e testare il modello:

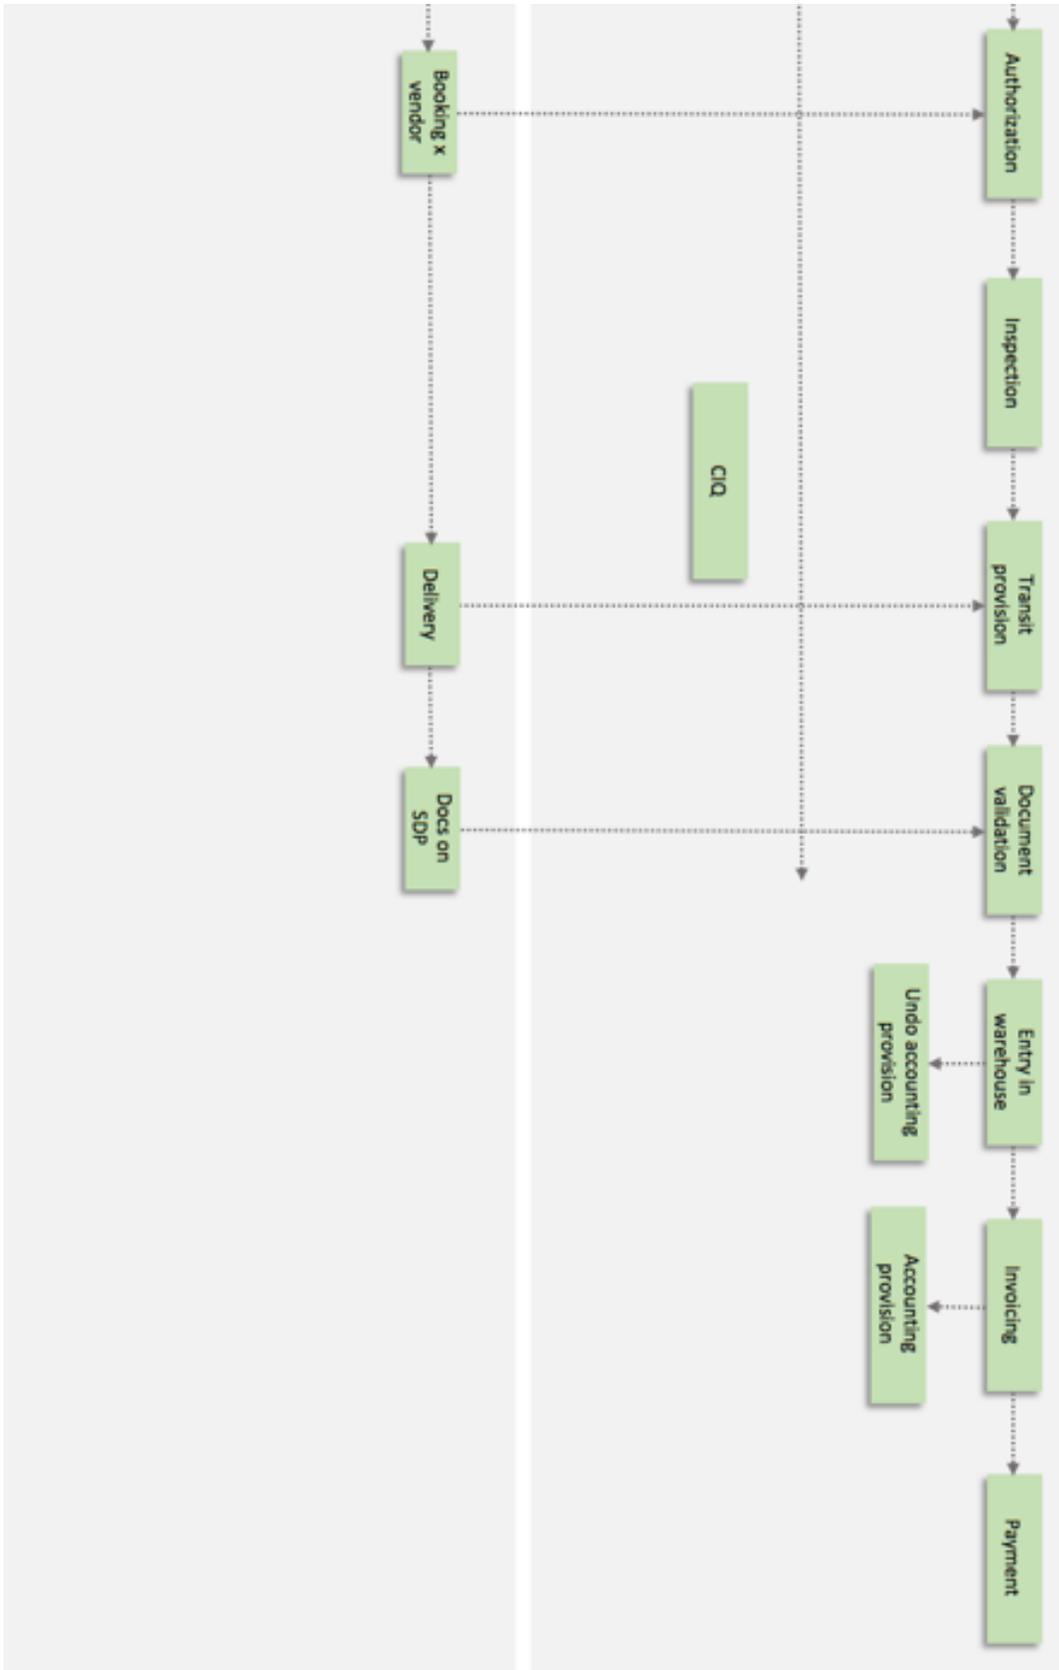
BL	MC	Genere	Genere aggruppato	Prodotto	N° di MC	N° di MC con CD	Acquisto incluso MC senza CD	Acquisto MC con CD	Tipo di Reparto	Acquisto Reale Tot
22	43187757-02	Donna	Donna	Indumento	1	1	13275	13275	Piegato	14809
25	43290845-70	Donna	Donna	Indumento	1	1	20177	20177	Piegato	21179

Acquisto Reale no MOL	Acquisto Reale MOL	Unità media di CD per collo	Colli comprati CD	Colli distribuiti	Colli aperti	Unità comprate CD	Unità distribuite	Unità aperte	Scommessa Firmes	Ordine Firmes
13275	1034	6,1	519	519	0	3179	3179	0	2790	2420
20177	802	7,6	891	885	6	6753	6707	46	2000	3774

Unità consegnate in magazzino	Unità entrate tot	Unità entrate no MOL	Unità entrate MOL	Unità pendenti entrata tot	Unità pendenti entrata no MOL	Unità pendenti entrata MOL	% Unità entrate/ Acquisto Reale
12523	12523	11020	1503	2286	2255	31	84,56%
21179	21179	20077	802	0	0	0	100,00%

Capitolo 4, mappa di flusso del processo AS-IS:





Capitolo 4, mappa di flusso del processo TO-BE

