

Quando contano
metriche hard e soft:
integrazione in un indice
composto e impatto del
Timing personalizzato
sulle intenzioni d'acquisto

Prof.

MICHELE COSTABILE

Prof.

ANDREA DE MAURO

RICCARDO DELUCCHI 787231

Indice

Introduzione	5
Capitolo 1	7
1.1 Il Ruolo del <i>Timing</i> delle Promozioni e l'Integrazione di Metriche <i>Hard</i> e <i>Soft</i>	7
1.1.1 Definizione del Customer Lifetime Value (CLV) e del Return Investment (ROI)	7
1.1.2 Limiti attuali nella misurazione del valore del cliente	8
1.1.3 L'integrazione delle metriche <i>hard</i> e <i>soft</i> e il ruolo del <i>Timing</i>	10
1.2. Fondamenti Teorici del CLV e ROI.....	12
1.2.1 Differenza tra metriche <i>hard</i> e <i>soft</i> nella misurazione del valore del cliente	12
1.2.2 Il contributo dell'AI e del <i>Machine Learning</i> nella misurazione del valore del cliente	13
1.2.3 Gap nella letteratura: Limiti dei modelli tradizionali e necessità di nuove metriche predittive	15
1.3. Personalizzazione e Intelligenza Artificiale per il Marketing.....	17
1.3.1 Il ruolo dell'AI nella predizione del comportamento del consumatore	17
1.3.2 Machine Learning e personalizzazione delle offerte	19
1.3.3 Il ruolo del <i>Timing</i> nella personalizzazione delle promozioni e nel miglioramento del CLV	20
1.4. Il <i>Timing</i> delle Promozioni e il Comportamento del Consumatore	22
1.4.1 L'effetto del momento di invio delle promozioni sulle decisioni di acquisto e sul ROI	22
1.4.2 Evidenze empiriche: il legame tra personalizzazione, <i>Timing</i> e valore del cliente	22
1.4.3 Applicazioni nel settore <i>Fast Food</i> e <i>Food Delivery</i>	24
1.5. Modelli Esistenti e Nuove Proposte	25
1.5.1 Modelli attuali per la predizione del CLV e del ROI	25
1.5.2 Il contributo del <i>Timing</i> personalizzato nella predizione del CLV e del ROI	26
Capitolo 2: Metodologia della ricerca	27
2.1 Definizione e rilevanza della domanda di ricerca	27
2.2 Modello teorico e ipotesi di ricerca.....	28
2.3 Approccio metodologico adottato	31

2.4 Tecniche di analisi dei dati	32
2.4.1 Pulizia e preparazione dei dati	32
2.4.2 Analisi descrittiva	32
2.4.3 Validazione delle scale	33
2.4.4 Calcolo delle metriche <i>hard</i> , <i>soft</i> e costruzione dell'indice integrato M	33
2.5 Limiti della Ricerca	35
Capitolo 3: Risultati e Implicazioni.....	37
3.1 Preparazione dei dati e caratteristiche del campione.....	37
3.2 Validazione degli strumenti di misurazione	38
3.2.1 Affidabilità interna	38
3.2.2 Analisi Fattoriale esplorativa (EFA)	38
3.3 Controllo delle manipolazioni	40
3.4 Analisi descrittive	41
3.5 Analisi dell'indice integrato M	42
3.6 Test dell'ipotesi (PROCESS Model 14).....	42
3.7 Discussione dei risultati	44
Appendicie	47
	51
Bibliografia	56

Introduzione

Negli ultimi anni, le dinamiche competitive e la crescente complessità del comportamento del consumatore hanno richiesto alle imprese una maggiore ed efficace precisione nella misurazione e assegnazione delle risorse. In particolare, il Customer Lifetime Value (CLV) e il Return on Investment (ROI) rappresentano due metriche fondamentali che, se correttamente integrate nelle strategie aziendali, massimizzano il valore generato dai clienti nel lungo termine (Ali & Shabn, 2024). Tuttavia, le modalità tradizionali di valutazione del CLV e del ROI tendono a concentrarsi prevalentemente su metriche "hard" come il tasso di conversione, i costi di acquisizione e la redditività immediata del cliente (Almestarihi et al., 2024; Petersen et al., 2009), trascurando elementi qualitativi o "soft", quali la soddisfazione del cliente, l'*Engagement* e la percezione del brand (Gupta & Zeithaml, 2006; Morgan et al., 2019).

Questa limitata visione del valore del cliente, come segnalato da diversi autori, rischia di produrre stime imprecise che non consentono una pianificazione ottimale per le strategie aziendali e un adeguato supporto per il management (Oblander et al., 2020; Wedel & Kannan, 2016). Allo stesso tempo, le rapide innovazioni tecnologiche dell'AI e del Machine Learning permettono di integrare queste due dimensioni grazie a modelli predittivi più avanzati, migliorando e ottimizzando la personalizzazione delle strategie di marketing (De Mauro et al., 2022; Firmansyah et al., 2024).

Nell'ambito specifico del settore Fast Food e Food Delivery, caratterizzato da decisioni di acquisto spesso impulsive e rapide, diventa cruciale comprendere come e quanto il *Timing* delle promozioni personalizzate possa influenzare il comportamento dei consumatori. Numerosi studi evidenziano che inviare offerte personalizzate al momento opportuno incrementa la probabilità di conversione e la percezione positiva del brand, generando un maggiore coinvolgimento e una più elevata soddisfazione del cliente (Ban & Keskin, 2021; Huang & Zhou, 2018; Venkatesan & Farris, 2012). Nonostante queste evidenze empiriche, l'effetto specifico del *Timing* delle promozioni sul CLV e sul ROI rimane scarsamente esplorato, soprattutto attraverso l'integrazione di metriche *hard*, *soft* e di *Timing* (Goldenberg et al., 2020; Arenoe & van der Rest, 2020).

In questa prospettiva, la presente ricerca si propone di dimostrare che l'integrazione del *Timing* nelle promozioni altamente personalizzate agisce come un ponte operativo fra

metriche *hard* e *soft*, migliorando sia la probabilità di acquisto sia la precisione delle previsioni del CLV e l'efficacia delle strategie di marketing (in termini di ROI), grazie all'effetto mediatore di un indice calcolato con la combinazione di queste metriche. Per raggiungere tale obiettivo, verrà adottato un approccio integrato che combina metriche operative tradizionali e dimensioni qualitative, mediante una raccolta dati quantitativa basata su un unico questionario e l'applicazione di avanzati strumenti analitici come la regressione lineare, analisi PCA e PROCESS Model 14 per l'analisi di mediazione moderata. Più specificamente, lo studio intende rispondere alla seguente Research Question (RQ):

“In che modo un indice integrato di metriche *hard* e *soft*, applicato alle promozioni personalizzate inviate in momento strategici, influisce sulle decisioni di acquisto e sulla predizione del CLV e del ROI, tenendo conto della Promotion Fatigue come fattore critico?”

Il contributo della ricerca è la proposta di un framework analitico innovativo che integra, in modo sinergico, metriche quantitative (*hard*) e qualitative (*soft*) con una componente temporale, ovvero il *Timing* delle promozioni e la *Fatigue* percepita (quindi la “stanchezza” delle promozioni). Questo approccio evidenzia come il tempismo nell'invio delle offerte non solo contribuisca ad accrescere i ricavi, ma plasmi anche il sentiment e l'*Engagement* dei clienti. In tal modo, il *Timing* agisce come un collegamento dinamico, integrando in modo sinergico le dimensioni economiche e quelle qualitative, fornendo una visione complessiva che incide sia sulle decisioni di acquisto immediate sia sul valore a lungo termine dei clienti, potendone prevedere il comportamento e traducendosi in un concreto miglioramento del ROI.

La struttura della tesi seguirà pertanto un percorso coerente e articolato in tre capitoli principali: la definizione del contesto teorico e concettuale relativo al ruolo del *Timing* e alle metriche *hard* e *soft*; la descrizione dettagliata della metodologia e degli strumenti analitici adottati; la presentazione dei risultati empirici e la discussione delle loro implicazioni manageriali, teoriche e operative. Concludendo, si delineeranno limiti e futuri sviluppi della ricerca, ponendo le basi per ulteriori approfondimenti sul tema.

Capitolo 1

1.1 Il Ruolo del *Timing* delle Promozioni e l'Integrazione di Metriche *Hard* e *Soft*

1.1.1 Definizione del Customer Lifetime Value (CLV) e del Return Investment (ROI)

Nel contesto del marketing strategico, la misurazione accurata e approfondita del valore del cliente rappresenta un aspetto cruciale per le aziende che mirano ad ottimizzare le proprie strategie di business e allocare in modo efficace le risorse disponibili. Tra le metriche più utilizzate per valutare la redditività del cliente vi è il *Customer Lifetime Value* (CLV), definito come il valore presente netto di tutti i profitti futuri che l'azienda si aspetta di generare da una relazione con un cliente specifico durante l'intero periodo della relazione stessa (Ali & Shabn, 2024). Più precisamente, il CLV esprime la capacità dell'impresa di comprendere e prevedere il valore a lungo termine generato dal cliente, considerando costi di acquisizione, gestione, *retention* e altri investimenti effettuati lungo tutto il ciclo di vita del cliente.

Simultaneamente, il *Return on Investment* (ROI) rappresenta una metrica ampiamente adottata per misurare la performance finanziaria delle iniziative di marketing. Il ROI è calcolato come il rapporto tra il profitto netto generato da una specifica attività di marketing e i costi associati all'implementazione di tale attività (Almestarihi et al., 2024). Questa metrica permette di valutare direttamente l'efficacia delle campagne promozionali e di marketing, contribuendo a ottimizzare il budget e a massimizzare il ritorno degli investimenti.

Sebbene entrambe le metriche abbiano l'obiettivo comune di quantificare il valore del cliente, il CLV e il ROI differiscono significativamente per orizzonte temporale e obiettivi specifici. Il *Customer Lifetime Value* si concentra sul valore relazionale a lungo termine, enfatizzando la necessità di mantenere relazioni durature e profittevoli con i clienti. Al contrario, il ROI tende ad avere un orizzonte più breve, focalizzandosi prevalentemente sull'efficacia economica immediata delle azioni di marketing e promozionali. Nonostante queste differenze, il CLV e il *Return on Investment* presentano una complementarità

strategica essenziale: l'integrazione di queste due metriche consente infatti di ottenere una visione completa del valore generato dai clienti, fornendo informazioni sia sul rendimento immediato delle azioni di marketing, sia sulla capacità di queste ultime di generare relazioni solide e profittevoli nel lungo periodo (Gupta & Zeithaml, 2006).

Nel settore *Fast Food* e *Food Delivery*, l'applicazione combinata di CLV e ROI assume particolare rilevanza a causa delle caratteristiche intrinseche di tali mercati, caratterizzati da decisioni di acquisto rapide e impulsive. In questi contesti, il *Timing* e la personalizzazione delle promozioni assumono un ruolo decisivo nel massimizzare il valore economico e relazionale del cliente. Le evidenze empiriche dimostrano infatti che promozioni mirate e personalizzate, se inviate nel momento ottimale, possono incrementare notevolmente sia la conversione immediata (ROI), sia la *Customer Satisfaction* e il *Customer Engagement*, alimentando la fedeltà e di conseguenza il CLV (Gupta & Zeithaml, 2006).

Un'ulteriore criticità riguarda la cosiddetta "*Promotion Fatigue*" cioè la percezione di sovraccarico promozionale che può generarsi quando i clienti ricevono offerte e coupon in maniera eccessivamente frequente o invasiva. Sebbene le promozioni personalizzate possano infatti incrementare vendite e soddisfazione, una loro somministrazione poco oculata rischia di indurre i consumatori a ignorare i messaggi o a sviluppare un atteggiamento negativo verso il *brand* (Huang et al., 2013). Nel settore *Fast Food* e *Food Delivery*, caratterizzato da interazioni rapide e numerose, la "*Promotion Fatigue*" si traduce in un calo dell'attenzione e in una riduzione dell'efficacia delle campagne. Da un punto di vista di valore del cliente, ciò implica che un eccesso di comunicazione promozionale può compromettere la relazione di lungo periodo, erodendo la fedeltà e, di conseguenza, il CLV. Al contrario, un uso strategico e moderato delle promozioni, calibrato sulle preferenze e sul comportamento d'acquisto effettivo, contribuisce a preservare l'*Engagement* e a ottimizzare i rendimenti economici sia nel breve (ROI) sia nel lungo periodo.

1.1.2 Limiti attuali nella misurazione del valore del cliente

La misurazione tradizionale del *Customer Lifetime Value* e del *Return on Investment*, nonostante la crescente consapevolezza dell'importanza di un approccio integrato, è spesso caratterizzata da un'eccessiva enfasi su metriche quantitative o "*hard*", come la

frequenza d'acquisto, i costi di acquisizione e il valore monetario medio per cliente (Ali & Shabn, 2024). Tale approccio, sebbene fornisca dati oggettivi e facilmente misurabili, presenta significativi limiti nell'offrire una comprensione completa e accurata del valore reale e potenziale del cliente.

Uno dei principali limiti dei modelli tradizionali risiede nell'incapacità di includere efficacemente le dimensioni qualitative o "*soft*" che influenzano significativamente il comportamento futuro dei clienti. Morgan et al. (2019) sottolinea come molte aziende, pur riconoscendo l'importanza teorica delle metriche qualitative come la soddisfazione del cliente, la percezione del brand e *l'Engagement*, spesso trascurano di integrarle sistematicamente nelle analisi finanziarie e strategiche. Questa esclusione porta a una visione parziale del comportamento del cliente, limitando la capacità delle aziende di prevedere correttamente il valore del cliente e, di conseguenza, di adottare decisioni strategiche ottimali. Nello studio di Almestarihi et al. (2024) si evidenziano che le metodologie tradizionali per la valutazione del ROI nelle campagne di marketing digitale spesso forniscono stime incomplete, non riuscendo a catturare efficacemente gli impatti indiretti delle promozioni sul valore percepito e sull'*Engagement* del cliente.

Un esempio concreto di questa limitazione si può osservare nel settore del *Fast Food* e *Food Delivery*, dove una valutazione basata esclusivamente su metriche "*hard*" potrebbe indicare un cliente come altamente profittevole a breve termine, ignorando però la scarsa soddisfazione percepita o la debole relazione emotiva con il brand, elementi che potrebbero comportare una rapida perdita di fidelizzazione nel lungo periodo. Tale approccio può indurre l'azienda a investire ulteriormente su strategie promozionali mirate unicamente all'acquisizione alla conversione immediata, trascurando iniziative orientate al miglioramento della relazione con il cliente, che invece potrebbero garantire un valore più elevato e sostenibile nel tempo.

Un ulteriore limite dei modelli tradizionali consiste nella mancata integrazione delle potenzialità offerte dai Big Data e dalle tecnologie di Intelligenza Artificiale (AI). Wedel & Kannan (2016) evidenziano come molte aziende ancora non sfruttino pienamente le potenzialità derivanti dall'integrazione di dati comportamentali con quelli finanziari. Tale lacuna impedisce alle imprese di generare previsioni più precise e tempestive, che potrebbero supportare decisioni di marketing più efficaci e orientate al lungo termine.

Infatti, l'assenza di modelli predittivi avanzati basati sull'AI limita la capacità delle piattaforme di *food delivery* di identificare rapidamente cambiamenti nel comportamento di acquisto, riducendo così l'efficacia delle promozioni personalizzate inviate ai clienti.

Oblander et al. (2020), in particolare, dimostrano che la combinazione di dati comportamentali e finanziari permette non solo di migliorare la predizione del CLV, ma anche di identificare segmenti di clienti potenzialmente ad alto valore che altrimenti resterebbero invisibili con un approccio esclusivamente quantitativo.

Per superare tali limitazioni, è fondamentale sviluppare modelli integrati che sfruttino pienamente l'integrazione di metriche *hard* e *soft*.

1.1.3 L'integrazione delle metriche *hard* e *soft* e il ruolo del *Timing*

Un approccio integrato nella misurazione del valore del cliente, che coniuga metriche quantitative (*hard*) con quelle qualitative (*soft*), consente di superare i limiti identificati precedentemente, offrendo una valutazione più precisa e completa del *Customer Lifetime Value* e del *Return on Investment*. L'integrazione di queste metriche permette infatti di ottenere una visione più approfondita del comportamento dei clienti, includendo non solo aspetti finanziari immediati, ma anche elementi relazionali ed emozionali.

In questo contesto, Folstad e Kvale (2018) evidenziano come l'applicazione dei modelli di *Customer journey*, arricchiti da metriche *soft*, consenta di cogliere in maniera più dettagliata e realistica il percorso del cliente dalla consapevolezza iniziale fino alla fidelizzazione, rendendo così più accurata la previsione del suo valore nel tempo.

L'introduzione della variabile temporale, ovvero il *Timing* delle promozioni, rappresenta un elemento chiave per amplificare ulteriormente il valore aggiunto dell'approccio integrato. Infatti, il *Timing* ottimale di una promozione può massimizzare contemporaneamente gli effetti quantitativi immediati (aumento delle conversioni) e quelli qualitativi di lungo periodo (incremento della soddisfazione e del coinvolgimento). In particolare, una promozione inviata ad un cliente di un servizio di *Food Delivery* in prossimità degli orari in cui tipicamente effettua gli ordini, può aumentare significativamente la probabilità di acquisto immediato (metrica *hard*), generando allo stesso tempo una percezione positiva del marchio come attento e personalizzato (metrica *soft*), mantenendolo fidelizzato e coinvolto con il *brand*.

Sun et al. (2023), hanno sviluppato un modello basato su tecniche avanzate di *machine learning* che integra dati quantitativi e qualitativi, sottolineando proprio come il *Timing* possa rappresentare un elemento cruciale per ottimizzare le previsioni del CLV. Attraverso l'analisi dettagliata dei comportamenti storici e delle interazioni del cliente con il *brand*, questo modello è in grado di prevedere il momento ottimale per inviare promozioni personalizzate, aumentando così il ritorno economico delle iniziative di marketing e rafforzando il rapporto relazionale con il cliente.

Nel settore del *Fast Food* e *Food Delivery*, dove le decisioni di acquisto sono spesso impulsive e fortemente influenzate dalla disponibilità immediata e dalla convenienza percepita, il *Timing* delle promozioni può fare la differenza tra una strategia promozionale generica e una efficace. Inviare offerte promozionali personalizzate poco prima dell'orario in cui un cliente è più propenso a mangiare o ordinare può aumentare significativamente il tasso di conversione (metrica *hard*). Allo stesso tempo, questa strategia migliora la percezione del *brand*, rafforzando la fidelizzazione e il coinvolgimento del cliente (metriche *soft*).

1.2. Fondamenti Teorici del CLV e ROI

1.2.1 Differenza tra metriche *hard* e *soft* nella misurazione del valore del cliente

Per una valutazione accurata e strategica del valore del cliente è fondamentale distinguere tra due tipologie principali di metriche: le metriche *hard* e le metriche *soft*. Tale distinzione è essenziale per sviluppare modelli integrati di analisi del *Customer Lifetime Value* e del *Return on Investment*, specialmente nel settore dinamico osservato del *Fast Food* e *Food Delivery*.

Le metriche *hard*, o metriche quantitative e operative, comprendono indicatori direttamente misurabili, tangibili e finanziariamente quantificabili. Queste metriche possono essere il valore monetario medio delle transazioni, i costi di acquisizione cliente (CAC), il *retention rate*, il tasso di conversione, il tasso di abbandono e la durata media del rapporto cliente-azienda (Petersen et al., 2009). Nel settore analizzato, una metrica *hard* comune è il valore medio degli ordini giornalieri o settimanali per cliente, utile per valutare rapidamente l'efficacia immediata delle promozioni e delle strategie operative.

Al contrario, le metriche *soft* si concentrano sugli aspetti qualitativi e relazionali della relazione con il cliente. Questi indicatori includono, ad esempio, il grado di soddisfazione, il livello di coinvolgimento emotivo ed esperienziale (*Engagement*), la percezione del *brand* e la fedeltà del cliente (Gupta & Zeithaml, 2006). Nel contesto pratico del *Food Delivery*, alcune metriche *soft* rilevanti sono il livello di soddisfazione derivante dalla puntualità della consegna, dalla qualità del cibo o dall'esperienza complessiva dell'utente con il servizio di *delivery*.

Le metriche *hard* e *soft*, pur essendo complementari, presentano differenze sostanziali nell'utilizzo pratico e nelle implicazioni strategiche. Le metriche *hard* offrono vantaggi in termini di oggettività e facilità di misurazione, permettendo una valutazione rapida e diretta delle prestazioni operative e finanziarie.

Le metriche *soft*, al contrario, pur essendo più difficili da quantificare direttamente in termini finanziari, offrono una profondità di analisi maggiore, catturando aspetti cruciali per la fidelizzazione e la costruzione di relazioni durature. Infatti, la *Satisfaction* e

l'Engagement possono predire una maggiore frequenza d'acquisto e una riduzione del *churn* (tasso di abbandono), generando valore finanziario significativo nel tempo (Gupta & Zeithaml, 2006).

La complementarità tra queste due tipologie di metriche emerge chiaramente nella possibilità di integrare queste dimensioni in modelli predittivi avanzati, capaci di migliorare significativamente l'accuratezza delle previsioni sul valore del cliente. Folstad e Kvale (2018), dimostrano come la combinazione di metriche qualitative nel *Customer journey* possa offrire previsioni più precise e dettagliate, identificando le fasi critiche in cui i clienti sviluppano un legame più forte con il marchio o manifestano segnali di potenziale insoddisfazione.

Oblander et al. (2020) sottolineano come l'integrazione sistematica tra dati comportamentali (*soft*) e finanziari (*hard*) consenta non solo una previsione più accurata del CLV, ma anche strategie promozionali più mirate e personalizzate, generando un vantaggio competitivo significativo.

1.2.2 Il contributo dell'AI e del *Machine Learning* nella misurazione del valore del cliente

L'intelligenza artificiale (AI) e il *Machine Learning* (ML) hanno trasformato radicalmente le metodologie utilizzate per misurare e predire il *Customer Lifetime Value* e il *Return on Investment*. Queste tecnologie avanzate consentono una gestione efficiente e accurata di grandi quantità di dati, facilitando l'integrazione di metriche quantitative (*hard*) e qualitative (*soft*) per ottenere previsioni più precise e strategie promozionali altamente personalizzate.

De Mauro et al. (2022) sottolinea come l'applicazione del *Machine Learning* nel marketing abbia permesso di sfruttare dati granulari per sviluppare modelli predittivi che migliorano sensibilmente la personalizzazione delle campagne promozionali. Nel settore *Fast Food e Food Delivery* algoritmi basati sull'AI possono analizzare rapidamente abitudini di consumo, orari, preferenze personali e comportamenti passati per anticipare e soddisfare le esigenze individuali, incrementando così la soddisfazione e la fidelizzazione dei clienti.

Lo studio di Firmansyah et al. (2024) mostra che l'utilizzo dell'AI permette di integrare efficacemente metriche *soft* come la soddisfazione del cliente e *l'Engagement* emotivo in modelli predittivi tradizionalmente basati esclusivamente su dati finanziari e transazionali. Questa integrazione porta a una predizione più completa e accurata del CLV, consentendo alle aziende di identificare precocemente segnali di insoddisfazione o potenziali abbandoni e adottare tempestivamente misure correttive.

Un esempio concreto è fornito da Sun et al. (2023), che propongono un modello CRM (*consumer relationship management*) basato sul *Machine Learning* capace di combinare dati transazionali (frequenza e valore degli acquisti) con dati comportamentali (recensioni, interazioni sui social media e *Engagement* con il marchio). Tale approccio offre alle aziende del *Fast Food* e *Food Delivery* informazioni dettagliate sulle preferenze e abitudini di consumo, permettendo di ottimizzare le promozioni personalizzandole con il *Timing* e il tipo di offerta per massimizzare conversione e fedeltà.

Ulteriori ricerche confermano empiricamente che modelli predittivi avanzati, basati sull'intelligenza artificiale e sull'integrazione tra metriche *hard* e *soft*, migliorano significativamente l'accuratezza delle previsioni sul valore del cliente, come quello di Akter et al. (2025). In particolare, attraverso algoritmi avanzati, le piattaforme di Food Delivery possono prevedere non solo quali clienti hanno maggiore probabilità di effettuare acquisti futuri, ma anche quali azioni promozionali avranno il maggior impatto positivo sulla loro fedeltà e valore economico.

Infine, Lukita et al. (2023) mettono a confronto diversi algoritmi di *Machine Learning* per predire il tasso di abbandono, evidenziando come modelli avanzati, quali *l'Extreme Gradient Boosting (XGBoost)*, superino significativamente i metodi tradizionali nella predizione della perdita di clienti e nella gestione proattiva delle relazioni. Nel settore *Fast Food* identificare rapidamente i clienti a rischio di *churn* consente interventi mirati, come offerte speciali personalizzate o programmi fedeltà, che possono non solo prevenire la perdita del cliente, ma anche aumentare la sua soddisfazione e valore a lungo termine.

Questi modelli avanzati costituiscono un importante passo verso l'introduzione del *Timing* come nuova variabile predittiva e da ponte tra le due tipologie di metriche.

1.2.3 Gap nella letteratura: Limiti dei modelli tradizionali e necessità di nuove metriche predittive

Come abbiamo già visto i modelli tradizionali di predizione del CLV e del ROI sono spesso caratterizzati da una visione statica del valore del cliente, limitata prevalentemente all'utilizzo isolato di metriche *hard* e *soft*. Questi modelli presentano una lacuna, dovuta alla mancata inclusione della variabile temporale, che rende difficile cogliere le dinamiche evolutive del comportamento del consumatore. Wedel e Kannan (2016) evidenziano come l'assenza di un'integrazione efficace dei *Big*

Data e della dimensione temporale riduca notevolmente la precisione predittiva, impedendo alle aziende di prevedere con accuratezza quando un cliente sarà più propenso ad effettuare un acquisto.

Morgan et al. (2019) e Oblander et al. (2020) sottolineano ulteriormente che la mancanza di un collegamento sistematico tra metriche quantitative (*hard*) e qualitative (*soft*) compromette la capacità dei modelli tradizionali di catturare la complessità delle decisioni di acquisto dinamiche. Questa disconnessione limita la possibilità di prevedere il comportamento futuro dei clienti, poiché trascura elementi fondamentali come il momento esatto in cui una promozione o un'offerta personalizzata può risultare più efficace per il singolo.

Per colmare questo *gap*, è essenziale considerare il *Timing* delle promozioni non semplicemente come una leva operativa, ma come una nuova e strategica variabile predittiva. Il *Timing* permette infatti di intercettare con precisione il momento più adatto per coinvolgere il consumatore, trasformando radicalmente il modo in cui si valuta e si predice il CLV e il ROI.

Sun et al. (2023) e Tong et al. (2022) hanno dimostrato che modelli avanzati di CRM basati su *Machine Learning*, che integrano la variabile temporale, consentono di migliorare sensibilmente la personalizzazione delle promozioni, incrementando sia il tasso di conversione che il livello di *Engagement*.

Inoltre, Ellickson et al. (2022) confermano che l'efficacia delle promozioni digitali mirate dipende fortemente dal momento esatto della loro distribuzione. Promozioni inviate in

momenti strategici mostrano risultati significativamente superiori rispetto a quelle inviate in momenti non ottimali, confermando così il valore predittivo del *Timing*.

L'integrazione della variabile temporale nei modelli avanzati di *AI* e *ML* rappresenta una risposta concreta alle limitazioni dei modelli tradizionali. Akter et al. (2025), Lukita et al. (2023) e Firmansyah et al. (2024) dimostrano empiricamente che gli algoritmi di *AI* capaci di integrare dati transazionali, comportamentali e temporali riescono a prevedere con grande precisione il momento ideale per inviare offerte personalizzate, migliorando drasticamente la gestione del churn e la predizione del CLV.

Questa inclusione risponde direttamente alla *Research Question* della tesi, indicando chiaramente come un framework avanzato che combina metriche *hard*, *soft* e temporali possa migliorare la capacità di prevedere e massimizzare il valore economico e relazionale dei clienti nel settore Fast Food e Food Delivery. Un ulteriore aspetto trascurato dai modelli tradizionali riguarda il fenomeno della "*Promotion Fatigue*".

Questa variabile incide sulle performance delle campagne di marketing: un eccesso di stimoli promozionali, per quanto personalizzati, può finire per diminuire l'*Engagement* del cliente e, in ultima analisi, limitarne il contributo al CLV. L'assenza di una sistematica analisi della "*Promotion Fatigue*" riduce, dunque, la capacità di prevedere correttamente il comportamento futuro dei clienti nei modelli di predizione del CLV e del ROI, rendendo cruciale l'inclusione di tale costrutto nei framework più avanzati.

1.3. Personalizzazione e Intelligenza Artificiale per il Marketing

1.3.1 Il ruolo dell'AI nella predizione del comportamento del consumatore

L'Intelligenza Artificiale (AI) sta rivoluzionando il marketing predittivo, permettendo alle aziende di anticipare con maggiore precisione le decisioni d'acquisto dei consumatori e personalizzare in modo efficace le proprie strategie promozionali.

Grazie alla capacità di elaborare e analizzare enormi quantità di dati, sia comportamentali che transazionali, l'AI offre strumenti avanzati per comprendere in profondità le preferenze e le esigenze dei clienti, anticipandone i comportamenti futuri (De Mauro et al., 2022).

Una delle tecniche più utilizzate dall'AI nel marketing predittivo è rappresentata dai modelli di *Machine Learning*, che identificano pattern complessi nei dati dei clienti per prevedere comportamenti specifici come acquisti, churn e risposta a promozioni. Il lavoro di Lukita et al. (2023), mostra come algoritmi avanzati come *l'Extreme Gradient Boosting* (GBoost) siano particolarmente efficaci nel prevedere il churn, consentendo alle aziende di intervenire proattivamente per migliorare la *retention* nel settore Fast Food e Food Delivery.

Parallelamente, Gao & Liu (2023) sottolineano l'importanza dell'AI nella personalizzazione basata sul *Customer journey*. Attraverso la segmentazione dinamica e l'analisi comportamentale, l'AI permette di individuare precisamente il punto del percorso d'acquisto in cui un cliente è più propenso a rispondere positivamente a una promozione, aumentando così la probabilità di conversione e migliorando il *Customer Lifetime Value*.

Un'altra applicazione cruciale dell'AI riguarda i sistemi di raccomandazione, che sfruttano tecniche di apprendimento automatico per proporre ai clienti prodotti e promozioni altamente personalizzati. Ellickson et al. (2022) evidenziano come l'applicazione di algoritmi di *Machine Learning* in campagne digitali mirate possa incrementare significativamente l'efficacia delle promozioni grazie alla capacità di prevedere quali

contenuti promozionali saranno maggiormente rilevanti per ciascun cliente e, soprattutto, quando proporli.

Akter et al. (2025) e Firmansyah et al. (2024) inoltre dimostrano empiricamente che l'integrazione di metriche qualitative (*soft*), come la *Customer Satisfaction* e l'*Engagement*, in modelli predittivi basati su AI, aumenta significativamente la precisione nel prevedere il comportamento dei clienti. Questo approccio integrato non solo migliora l'accuratezza delle previsioni relative al CLV, ma consente anche strategie promozionali più mirate e tempestive, valorizzando il rapporto tra azienda e consumatore.

1.3.2 Machine Learning e personalizzazione delle offerte

Il *Machine Learning* (ML) rappresenta una potente risorsa per la personalizzazione delle offerte promozionali, consentendo di ottimizzare le strategie di marketing migliorare significativamente il CLV. Nel settore *Fast Food e Food Delivery*, l'applicazione concreta dell'ML si manifesta nella capacità delle piattaforme digitali di anticipare le preferenze dei clienti. Gli algoritmi di ML elaborano grandi quantità di dati in tempo reale, identificando modelli e pattern specifici che permettono di proporre promozioni personalizzate con una precisione mai raggiunta prima.

Ban e Keskin (2021) mostrano come l'utilizzo del ML per il *pricing* dinamico consenta di prevedere accuratamente la domanda e personalizzare le offerte sulla base delle preferenze e sensibilità individuali dei clienti. Nel settore *Fast Food e Food Delivery* algoritmi come *Random Forest* e tecniche di *clustering* possono analizzare i comportamenti storici dei clienti, individuando segmenti con sensibilità diverse a determinati livelli di prezzo o promozioni specifiche, massimizzando così il tasso di conversione e migliorando il ROI.

Patil et al. (2021) evidenziano come modelli predittivi avanzati basati su ML possano aumentare il *Customer Engagement* e la fidelizzazione, identificando precocemente i segnali di insoddisfazione o *churn*. Lukita et al. (2023) confermano questo approccio, dimostrando che algoritmi avanzati consentono di anticipare con grande accuratezza i clienti a rischio di abbandono, permettendo interventi tempestivi con offerte personalizzate.

La ricerca di Chandra et al. (2022) approfondisce ulteriormente il ruolo del ML nella personalizzazione, suggerendo che l'integrazione di dati operativi (frequenza degli acquisti, valore medio dell'ordine) con dati relazionali (*Engagement*, *Satisfaction*) aumenti significativamente l'efficacia delle strategie promozionali. Akter et al. (2025) supportano questa prospettiva, dimostrando come modelli di AI avanzati possano sfruttare efficacemente dati comportamentali per migliorare la precisione predittiva del CLV e personalizzare in modo ottimale le promozioni digitali.

1.3.3 Il ruolo del *Timing* nella personalizzazione delle promozioni e nel miglioramento del CLV

La personalizzazione delle promozioni non si deve limitare esclusivamente ai contenuti delle offerte, ma include in modo essenziale anche il *Timing*, ovvero il momento ottimale per inviare tali promozioni ai clienti. Studi recenti hanno dimostrato che la tempistica delle promozioni gioca un ruolo decisivo nell'influenzare le decisioni di acquisto e migliorare la *Customer Satisfaction*, incrementando il CLV.

Nella ricerca di Goldenberg et al. (2020) possiamo analizzare come tecniche avanzate di *Uplift Modeling*¹ possano ottimizzare il *Timing* delle promozioni, identificando precisamente quando un cliente è più propenso a rispondere positivamente. Zhang e Liu-Thompkins (2024), studiando l'efficacia delle e-mail promozionali nei programmi fedeltà, confermano che inviare le promozioni al momento giusto incrementa significativamente l'impatto e il tasso di conversione.

VenkatesanFarris (2012) sottolineano che i coupon personalizzati, quando distribuiti in momenti strategici, dimostrano maggiore efficacia rispetto a offerte generiche inviate in momenti casuali. Questa strategia risulta particolarmente rilevante nel settore *Fast Food e Food Delivery*, dove l'impulsività delle decisioni di acquisto rende il *Timing* delle promozioni una leva critica per il successo.

Gli studi di Huang e Zhou (2018) e Arenoe e van der Rest (2020) confermano empiricamente che una gestione accurata della finestra temporale delle promozioni può influenzare positivamente il comportamento di acquisto e la *willingness to pay* dei consumatori.

Infine, la ricerca di Rashi et al. (2021) evidenzia come i cambiamenti nel comportamento dei consumatori post-Covid abbiano reso ancora più rilevante il ruolo del *Timing* nelle strategie promozionali. Nel settore *Food Delivery*, promozioni mirate inviate in momenti specifici, aumentano significativamente la probabilità di conversione e migliorano

¹Tecniche avanzate di *Uplift Modeling*:

Two-Models Approach – Stima la differenza tra due modelli distinti per ciascun gruppo (trattamento e controllo).

Transformed Outcome – Modello unico che stima direttamente l'effetto incrementale del trattamento.

Fractional Approximation – Metodo *greedy* basato sulla frazione tra il CATE dell'effetto e il CATE del costo.

Retrospective Estimation (proposta dagli autori) – Modello innovativo che utilizza solo dati con esiti positivi per migliorare la stima dell'effetto incrementale e mantenere il ROI positivo.

l'esperienza complessiva del cliente. Dimostrando come il *Timing* non sia un aspetto secondario della personalizzazione ma una componente centrale delle strategie promozionali avanzate.

1.4. Il *Timing* delle Promozioni e il Comportamento del Consumatore

1.4.1 L'effetto del momento di invio delle promozioni sulle decisioni di acquisto e sul ROI

Nel marketing digitale, il *Timing* delle promozioni si riferisce alla scelta strategica del momento più appropriato per inviare offerte ai consumatori, con l'obiettivo di massimizzare l'efficacia delle campagne promozionali. Questa variabile strategica è particolarmente rilevante, poiché può influenzare significativamente il comportamento d'acquisto e incrementare il *Return on Investment*.

Come evidenziato nel capitolo precedente Venkatesan e Farris (2012) dimostra che l'efficacia dei coupon personalizzati è strettamente legata al *Timing* del loro invio. Analogamente, Zhang e Liu-Thompkins (2024) mostrano che le e-mail promozionali personalizzate raggiungono tassi di conversione più elevati se inviate nei momenti in cui il consumatore è più ricettivo, rafforzando così la relazione tra *Timing* e comportamento di acquisto.

Tong et al. (2022) rafforzano ulteriormente questa visione, mostrando che l'efficacia delle promozioni digitali dipende fortemente dal loro *Timing*, il quale può aumentare significativamente il tasso di conversione e, di conseguenza, migliorare il ROI.

Norman et al. (2020) e Huang e Zhou (2018) sottolineano che il contesto temporale, inteso come il momento e la frequenza con cui vengono inviate le promozioni, è cruciale per influenzare il comportamento d'acquisto del consumatore. Le loro ricerche mostrano che promozioni ben sincronizzate con le abitudini di consumo possono amplificare l'impatto dell'offerta, aumentando non solo la probabilità di acquisto immediato, ma anche la percezione positiva del marchio.

1.4.2 Evidenze empiriche: il legame tra personalizzazione, *Timing* e valore del cliente

Diversi studi empirici confermano che il *Timing* delle promozioni, combinato con un alto grado di personalizzazione, ha un impatto significativo sul *Customer Lifetime Value* e sulla percezione complessiva del valore da parte del cliente.

Goldenberg et al. (2020) utilizzano modelli di *Uplift* per dimostrare che una personalizzazione accurata, sincronizzata con il momento giusto, migliora sensibilmente il tasso di conversione e aumenta il valore percepito dai clienti. Zhang e Liu-Thompkins (2024) confermano che le e-mail promozionali personalizzate, inviate in momenti strategici, rafforzano significativamente il rapporto cliente-azienda, incrementando la soddisfazione complessiva e la fidelizzazione a lungo termine.

Tong et al. (2022) approfondiscono ulteriormente il legame tra *Timing* e personalizzazione, dimostrando che le aziende che integrano queste due dimensioni nelle loro strategie promozionali ottengono risultati superiori in termini di CLV e ROI rispetto a strategie che trascurano l'elemento temporale. Huang e Zhou (2018) confermano empiricamente che il *Timing* delle promozioni personalizzate influisce direttamente sulla *Customer Satisfaction*, aumentando così il valore complessivo generato dal cliente nel tempo.

Inoltre, Akter et al. (2025) e Lukita et al. (2023) evidenziano come l'uso di algoritmi avanzati di *Machine Learning* possa prevedere accuratamente i momenti ideali per l'invio di promozioni personalizzate, migliorando significativamente le strategie di *retention* e la precisione della predizione del CLV. Questi studi dimostrano che una gestione avanzata e integrata del *Timing* e della personalizzazione basata sull'AI permette alle aziende di massimizzare il valore generato da ciascun cliente, migliorando contemporaneamente la redditività delle iniziative di marketing.

Nel marketing digitale, ad esempio, piattaforme come app di *food delivery* possono sfruttare l'AI per analizzare in tempo reale dati storici e comportamentali dei clienti, identificando esattamente quando proporre offerte mirate per massimizzare la conversione e aumentare il valore economico a lungo termine dei clienti.

Tuttavia, non è solo il "momento giusto" a contare, ma anche la frequenza complessiva con cui le promozioni sono inoltrate al cliente. Un eccesso di offerte può infatti generare una "*Promotion Fatigue*" (Huang et al., 2013), ossia una stanchezza del consumatore nei confronti del marchio e dei suoi messaggi. Ciò riduce l'attenzione e la disponibilità a interagire con ulteriori comunicazioni promozionali, annullando i benefici derivanti dal *Timing* personalizzato.

1.4.3 Applicazioni nel settore *Fast Food e Food Delivery*

Il settore *Fast Food e Food Delivery* offre esempi concreti e rilevanti di come il *Timing* delle promozioni possa essere applicato efficacemente per migliorare la conversione e la fidelizzazione dei clienti.

Lo studio di Rashi et al. (2021) mostra come, a seguito dei cambiamenti comportamentali post-Covid, il *Timing* delle offerte promozionali sia diventato ancora più critico, con consumatori sempre più sensibili alla tempestività e alla rilevanza delle promozioni.

Hanaysha (2022) analizza il ruolo cruciale della pubblicità sui social media nel settore Fast Food, dimostrando che la sincronizzazione delle campagne pubblicitarie con eventi e orari specifici migliora significativamente l'*Engagement* e incrementa le vendite. Allo stesso modo, Dandis et al. (2023) evidenziano che la brand experience e i benefici relazionali generati da una promozione tempestiva migliorano notevolmente la fedeltà dei clienti.

Manhas et al. (2024) approfondiscono l'impatto dell'innovazione di prodotto e del suo *Timing* strategico, mostrando come l'introduzione di nuovi prodotti o offerte in momenti particolari (es. festività o periodi promozionali) incrementi notevolmente le prestazioni delle campagne promozionali. Che Ishak et al. (2021) sottolineano l'efficacia dei chioschi *self-service* nel raccogliere dati precisi sul comportamento temporale dei clienti, informazioni che possono essere utilizzate per ottimizzare ulteriormente il *Timing* delle offerte.

Lo studio di Mdletshe (2023), infine, analizza come programmi fedeltà ben strutturati e temporalmente strategici possano aumentare significativamente la *retention* dei clienti nel settore *Fast Food*, evidenziando che offerte personalizzate inviate in momenti strategici incrementano non solo la fidelizzazione ma anche il valore percepito complessivo.

Nel contesto del *Fast Food e Food Delivery*, è dunque opportuno bilanciare la precisione del "quando" con la moderazione del "quanto," ipotizzando che la *Promotion Fatigue* possa fungere da variabile moderatrice nel rapporto tra il *Timing* promozionale e gli esiti desiderati.

1.5. Modelli Esistenti e Nuove Proposte

1.5.1 Modelli attuali per la predizione del CLV e del ROI

Nel marketing contemporaneo, la predizione accurata del *Customer Lifetime Value* e del *Return on Investment* rappresenta un aspetto strategico e cruciale per massimizzare la redditività e ottimizzare le risorse aziendali. Attualmente, diversi modelli vengono impiegati per prevedere queste metriche, ciascuno con caratteristiche, vantaggi e limitazioni proprie.

Ali & Shabn (2024) evidenziano che molti modelli di CLV tradizionali si concentrano prevalentemente su metriche "*hard*" offrendo previsioni solide ma statiche e limitate. Nella ricerca di Petersen et al. (2009) si evidenzia che tali modelli quantitativi, sebbene validi per decisioni operative immediate, risultano insufficienti per catturare la complessità e la dinamicità del comportamento relazionale dei clienti.

Almestarihi et al. (2024) analizzano il ROI delle campagne digitali, evidenziando come i modelli tradizionali, focalizzati sul profitto immediato e diretto delle singole iniziative, non riescano a cogliere l'impatto indiretto sul valore percepito e sulla fidelizzazione dei clienti nel lungo periodo.

Negli ultimi anni, l'integrazione dell'intelligenza artificiale e del *Machine Learning* nei modelli predittivi ha rappresentato un salto evolutivo significativo. Nel paper di Sun et al. (2023), ad esempio, si utilizzano algoritmi avanzati per combinare dati transazionali con metriche qualitative come il *Customer Engagement* e la soddisfazione del cliente. Mentre in quello di Akter et al. (2025) si conferma che modelli basati su AI che integrano metriche qualitative e quantitative possono migliorare sensibilmente la precisione delle previsioni sul CLV, identificando proattivamente clienti ad alto valore e quelli a rischio *churn*.

Questi modelli avanzati rappresentano una significativa evoluzione rispetto ai modelli tradizionali e pongono le basi per ulteriori sviluppi, tra cui la necessaria integrazione della variabile temporale (*Timing*), oggetto della sezione successiva.

1.5.2 Il contributo del *Timing* personalizzato nella predizione del CLV e del ROI

Il *Timing* personalizzato consiste nel determinare e sfruttare il momento ideale in cui il cliente è più incline a rispondere positivamente a una promozione o un'offerta. Goldenberg et al. (2020) e Tong et al. (2022) evidenziano come l'utilizzo strategico del *Timing* possa migliorare sensibilmente il tasso di conversione delle campagne promozionali, incrementando direttamente il ROI delle iniziative di marketing. Zhang e Liu-Thompkins (2024) confermano empiricamente che il *Timing* strategico delle e-mail promozionali nei programmi di fedeltà può incrementare la percezione del valore del brand e migliorare il CLV.

Akter et al. (2025) mostrano che modelli avanzati basati sull'intelligenza artificiale, integrando metriche comportamentali e temporali, consentono alle aziende di prevedere con precisione il momento ottimale per le promozioni, massimizzando sia il valore immediato che quello a lungo termine del cliente. Ellickson et al. (2022) evidenziano come l'applicazione del *double Machine Learning* permetta di stimare con precisione l'impatto delle promozioni digitali personalizzate e temporalmente mirate, migliorando così la performance complessiva delle strategie di marketing.

Questi studi dimostrano che il *Timing* personalizzato può fungere da ponte tra CLV e ROI, ottimizzando l'efficacia delle promozioni. Un uso strategico del *Timing* consente di massimizzare il ritorno immediato (ROI) senza compromettere la percezione del valore del cliente nel lungo periodo (CLV). Tuttavia, è essenziale identificare una soglia di esposizione alle promozioni, poiché una frequenza eccessiva potrebbe ridurre l'*Engagement* e abbassare il CLV nel tempo.

In questa direzione, studi precedenti hanno evidenziato che un'eccessiva esposizione a promozioni può ridurre l'efficacia delle campagne di marketing, generando un effetto di "*Promotion Fatigue*" (Venkatesan & Farris, 2012). Questo fenomeno può abbassare la percezione del brand e ridurre il CLV, con implicazioni negative sul ROI futuro. Pertanto, un'ottimizzazione del *Timing* personalizzato deve considerare non solo il momento ottimale per l'invio di una promozione, ma anche il numero complessivo di interazioni promozionali per ciascun cliente, al fine di bilanciare al meglio conversioni immediate e fidelizzazione a lungo termine.

Capitolo 2: Metodologia della ricerca

2.1 Definizione e rilevanza della domanda di ricerca

In questo capitolo, verranno descritti il disegno di ricerca, le ipotesi di ricerca, gli strumenti e le procedure utilizzate per raccogliere e analizzare i dati.

Per iniziare definiamo la domanda di ricerca (RQ) che questa ricerca si propone di rispondere:

"In che modo un indice integrato di metriche hard e soft, applicato alle promozioni personalizzate inviate in momento strategici, influisce sulle decisioni di acquisto e sulla predizione del CLV e del ROI, tenendo conto della Promotion Fatigue come fattore critico?"

Questa domanda riflette la necessità di andare oltre le strategie tradizionali di personalizzazione, proponendo un nuovo framework che integra le metriche economiche (CLV e ROI) con quelle psicologiche (*Satisfaction*, *Engagement*, *Fatigue*) e la dimensione temporale (*Timing* delle promozioni)

Come abbiamo visto nel capitolo precedente, la formulazione della domanda di ricerca deriva da un'attenta analisi della letteratura. Molti studi hanno evidenziato come il momento di invio di una promozione può influenzare il comportamento immediato d'acquisto. Recenti studi evidenziano che l'introduzione delle variabili temporali (*Timing*) e di stanchezza (*Fatigue*) nelle promozioni personalizzate rappresentino un elemento chiave per ottimizzare sia le conversioni immediate che la fidelizzazione a lungo termine (Goldenberg et al., 2020; Sun et al., 2023).

Dal punto di vista manageriale, questa ricerca fornisce una nuova chiave di lettura:

Comprendere l'efficacia del *Timing* delle promozioni personalizzate permette alle aziende di migliorare le conversioni immediate e la fidelizzazione dei clienti, massimizzando il ROI.

La gestione della *Promotion Fatigue*, identificata come un moderatore critico, offrendo risultati che suggeriscono come dosare la pressione promozionale per massimizzare le

conversioni e fidelizzazione, ma anche per prevenire il rischio di churn legato alla *promotion Fatigue*.

L'esplorazione empirica della RQ viene realizzata tramite la costruzione di un indice composto integrato, elaborato e validato con tecniche di data mining e analisi fattoriale, testato con modelli di mediazione moderata.


2.2 Modello teorico e ipotesi di ricerca

Il modello concettuale di questa ricerca analizza come l'integrazione del *Timing* nelle promozioni personalizzate influenzi la decisione d'acquisto nel settore *Fast Food e Food Delivery*, tenendo conto sia di metriche *hard* sia di quelle *soft*. Questo modello considera le seguenti variabili chiave:

- Variabile Indipendente (X): *Personalized Promotion Time* (specifico vs. generico²). Questa variabile rappresenta il momento in cui le promozioni vengono inviate ai consumatori. Il *Timing* è trattato come una variabile dicotomica, distinguendo tra promozioni inviate in momenti strategici e promozioni inviate in momenti casuali.
- Variabile Dipendente (Y): *Immediate Purchase Intention* (intenzione o comportamento effettivo). Misura l'intenzione di acquisto immediata e il comportamento effettivo di acquisto dei consumatori. Questa variabile è fondamentale per valutare l'efficacia delle promozioni personalizzate e il loro impatto sul comportamento dei clienti, viene misurata nel questionario dopo l'esposizione allo scenario promozionale
- Mediatore (M): Indice integrato *hard/soft*. È un indice composito combinando metriche *hard* (CLV, ROI) e metriche *soft* (*Satisfaction, Engagement, Fatigue*), pesate in base all'analisi fattoriale e alle considerazioni manageriali
- Moderatore (W): *Promotion Fatigue* (percezione di sovraccarico promozionale). Quest'ultima modera la relazione tra l'indice integrato M e l'intenzione d'acquisto. Questa variabile è cruciale per comprendere come un'eccessiva

²Per analizzare questa variabile dicotomica i partecipanti saranno esposti a più scenari

esposizione a promozioni possa ridurre l'attenzione e l'*Engagement* dei clienti, influenzando negativamente le strategie di marketing



Il modello teorico proposto utilizza il *PROCESS Model 14* per analizzare le relazioni tra queste variabili, includendo effetti di mediazione e moderazione.

Le ipotesi di ricerca sono formulate per investigare come il *Timing* personalizzato delle promozioni influenzi il comportamento d'acquisto e migliori la predizione del valore economico dei clienti. Ogni ipotesi è giustificata con riferimenti alla letteratura esistente.

Hp1: Il *Timing* delle promozioni (inviate in momenti strategici per il cliente) ha un effetto positivo e diretto sull'intenzione immediata d'acquisto, rispetto a promozioni inviate in momenti generici.

Il *Timing* strategico aumenta la rilevanza della promozione, migliorando l'intenzione di acquisto.

Hp2: l'effetto del *Timing* personalizzato sull'intenzione d'acquisto è mediato da un indice integrato (M), ottenuto combinando metriche *hard* (CLV e ROI) metriche e *soft* (*Satisfaction*, *Fatigue*, *Engagement*)

Hp3: La *Promotion Fatigue* (W) modera negativamente la relazione tra l'indice integrato (M) e l'intenzione d'acquisto (Y): quando la *Fatigue* è alta, l'effetto positivo di M sull'intenzione si riduce.

Hp4: L'effetto indiretto del *Timing* sulle intenzioni di acquisto, tramite l'indice integrato (M), è più forte quando la *promotion Fatigue* è bassa rispetto a quando è alta.

Queste ipotesi costituiscono il quadro teorico e metodologico per le successive analisi empiriche, utilizzando un modello statistico PROCESS Model 14 (per la mediazione moderata).

2.3 Approccio metodologico adottato

L'approccio metodologico adottato in questa ricerca è di natura quantitativa *between-subject*. Il campione è stato selezionato tramite un campionamento non probabilistico, composto principalmente da studenti e giovani adulti, reclutati attraverso social media. La scelta di questa metodologia deriva dalla necessità di raggiungere rapidamente un grande numero di rispondenti, garantendo sempre la rilevanza del campione rispetto al target principale dei servizi di *Food Delivey e Fast Food*.

È stato scelto questo approccio per la sua capacità di fornire dati oggettivi e misurabili, essenziali per rispondere alla *Research Question (RQ)* e testare le ipotesi formulate. Sono state manipolati sperimentalmente sia il *Timing* della promozione, confrontando un momento generico con uno specifico, sia la *promotion Fatigue*, uno scenario con la presenza di alta esposizione promozionale e uno con bassa esposizione, assegnando casualmente ma in maniera equamente distribuita i partecipanti alle diverse condizioni, sfruttando la randomizzazione su Qualtrics. La RQ richiede un'analisi dettagliata delle variabili coinvolte e delle relazioni tra di esse.

Questo approccio permette di misurare l'effetto del *Timing* delle promozioni e della *Fatigue* utilizzando dati numerici, permettendo così di quantificare l'impatto delle promozioni sulle decisioni di acquisto. Analizzare le relazioni tra le variabili utilizzando modelli statistici e infine la generalizzazione dei risultati.

Per rispondere alle ipotesi di ricerca e alla *Research Question (RQ)*, è stato predisposto un questionario online strutturato, sviluppato per raccogliere informazioni dettagliate sulle variabili rilevanti per la ricerca. Il questionario è composto da diverse sezioni, ciascuna con obiettivi precisi e coerenti con le ipotesi formulate che sono:

- Sezione demografica
- Manipolazione delle condizioni sperimentali, ovvero la visualizzazione dei vari scenari
- Domande sull'intenzione d'acquisto, *Satisfaction*, *Engagement*, *Fatigue* e importanza percepita del *Timing*
- Dati comportamentali: frequenza d'ordine, spesa media, anzianità di utilizzo

2.4 Tecniche di analisi dei dati

In questo studio viene adottata una serie di tecniche di analisi dei dati organizzate in una sequenza metodologica ben precisa.

Questo approccio permette di garantire la robustezza e l'affidabilità dei risultati ottenuti. L'intero processo analitico si articola in quattro fasi principali: pulizia dei dati, analisi descrittiva, validazione delle scale e test delle ipotesi.

2.4.1 Pulizia e preparazione dei dati

Inizialmente, i dati raccolti tramite questionario saranno sottoposti a un processo accurato di pulizia utilizzando il *software* Knime analytics.

Questo processo include la verifica della presenza di *outliers*, l'identificazione e il trattamento dei dati mancanti, e la correzione di eventuali anomalie che potrebbero influenzare negativamente l'analisi. Nello specifico, si procederà con metodi di imputazione dei dati mancanti (come la media o la mediana) e l'identificazione degli *outliers* tramite tecniche statistiche standard come il calcolo dell'intervallo interquartile (De Mauro, 2024).

Successivamente sfruttando i dati puliti verranno calcolate le metriche *hard* CLV e ROI, le metriche *soft*, riguardanti la *Fatigue*, la *Satisfaction*, *Engagement* e importanza del *Timing*. Infine, verrà costruito l'indice integrato M, combinando le metriche *hard* e *soft* tramite una formula pesata utilizzando la regressione lineare con variabile dipendente l'intenzione d'acquisto, validata anche con Analisi delle Componenti Principali (PCA)

2.4.2 Analisi descrittiva

Successivamente alla pulizia, si procederà con un'analisi descrittiva dettagliata per comprendere le caratteristiche principali del campione. Le variabili saranno analizzate attraverso statistiche descrittive quali media, deviazione standard, mediana e frequenze assolute e relative. Questo passo consentirà di verificare la distribuzione delle variabili misurate e di evidenziare eventuali problemi preliminari nella distribuzione dei dati stessi (De Mauro, 2024).

2.4.3 Validazione delle scale

La validazione delle scale adottate nel questionario avverrà in due fasi principali: l'analisi dell'affidabilità e l'analisi fattoriale esplorativa. L'affidabilità interna delle scale sarà testata utilizzando il coefficiente Alpha di Cronbach. L'analisi fattoriale esplorativa (EFA) sarà impiegata sulle variabili *soft* utilizzate per la costruzione dell'indice integrato M. Questo processo, realizzato tramite SPSS, consentirà di confermare l'adeguatezza delle scale utilizzate, di ridurre eventuali ridondanze nelle misurazioni e di confermare l'adeguatezza dei costrutti inclusi nell'indice creato.

2.4.4 Calcolo delle metriche *hard*, *soft* e costruzione dell'indice integrato M

Le variabili utilizzate sono state calcolate mediante procedure specifiche e integrate in un indice composto.

Per quanto riguarda le metriche *hard* sono stati utilizzati una lunga serie di nodi su Knime, al fine di trasformare i dati da nominali a numerici e poter successivamente calcolare il ROI e il CLV, normalizzando i dati ove era necessario con tecniche di normalizzazione *Min-Max scaling* (0-1) e *z-score*. Il Customer Lifetime Value è stato calcolato utilizzando una formulazione presente in letteratura nel lavoro di Gupta et al. (2006):

$$CLV = \frac{\text{Margine netto}}{d} \times \left[1 - \left(\frac{1+r}{1+d} \right)^t \right]$$

Dove *r* è il tasso di *retention*, *d* è il tasso di sconto (ho preso come riferimento 0,10 come suggerito nella letteratura) e *t* è il periodo temporale considerato ricavato nel questionario. Mentre per il ROI è sempre stata utilizzata una formula presente in letteratura e adottata anche da Almestarihi et al. (2024) per valutare l'efficacia delle campagne promozionali.

$$ROI = \frac{\text{Margine netto} - \text{Investimento}}{\text{Investimento}}$$

Il margine netto corrisponde al fatturato netto, già “pulito” delle spese operative.

Le metriche *soft* sono state ottenute grazie alle risposte al questionario, ed è stata fatta la media delle scale Likert a 7 punti relative a:

- *Consumer Satisfaction*; scale prevalidate da Fornell et al. (1996) con un Alpha di Cronbach's > 0,80.
- *Customer Engagement*; scale prevalidate adattate da Hollebeek et al. (2014) con un Alpha di Cronbach's compresa tra 0,86 e 0,94.
- *Promotion Fatigue*; prevaliate nello studio di Lee, J., & Choi, H. (2019) con un Alpha di Cronbach's intorno allo 0,85.
- Importanza del *Timing*; singolo item dove veniva chiesta l'importanza del *Timing* di arrivo della promozione con il fine di intraprendere un'azione (acquisto).

Per sintetizzare in un unico indicatore gli effetti delle metriche *hard* e *soft* sul comportamento d'acquisto, sono state prima normalizzate tutte le variabili affinché siano su una scala comparabile, utilizzando il nodo *Normalizer* su KNIME con formula “*Min-Max scaling*” [0;1]. Costruendo un indice composto M definito così:

$$M = w_1 \times \frac{ROI}{CLV} + w_2 \times Satisfaction + w_3 \times \left(\frac{1 - fatigue}{imp_timing} \right)$$

I pesi verranno stimati utilizzando una regressione lineare multipla sempre su KNIME, ponendo l'intenzione d'acquisto come variabile dipendente e Ratio (rapporto tra ROI e CLV), *Satisfaction* e S (sintetizza la *promotion Fatigue* e l'importanza percepita del *Timing*) come predittori.

Il *Ratio* è un indicatore che esprime quanto l'efficacia a breve termine si confronta con il valore a lungo termine. La *Satisfaction* è la media dei punteggi raccolte durante il questionario normalizzata in scala 0-1.

Dopo aver ottenuto i pesi preliminari, è stata verificata la struttura fattoriale con un'analisi PCA per capire se le tre variabili soft possano essere sintetizzate in un singolo fattore, questa procedura viene eseguita su SPSS.

Questa procedura garantisce che ogni peso rifletta empiricamente il contributo di ciascuna componente nella spiegazione dell'intenzione d'acquisto. L'indice M, con i pesi definiti è un predittore robusto dell'effetto mediato del *Timing* personalizzato sulle decisioni di acquisto, tenendo conto della *Fatigue* percepita dal cliente.

2.5 Limiti della Ricerca

Nonostante l'approccio metodologico adottato in questa ricerca, emergono alcuni limiti importanti che devono essere considerati nella lettura e interpretazione dei risultati.

In primo luogo, i dati utilizzati nell'analisi derivano interamente da questionari auto somministrati, basati quindi sulle risposte dichiarate dai partecipanti, senza il supporto di informazioni comportamentali oggettive. L'utilizzo di scenari ipotetici, infatti, comporta un rischio dovuto a distorsioni per mezzo dei *bias* di desiderabilità sociale, a errori nella memoria o nella percezione soggettiva delle proprie intenzioni d'acquisto e valutazioni. L'assenza di dati transazionali come gli effettivi ordini effettuati o informazione dettagliate sulle transazioni reali, limitano la possibilità di confermare empiricamente se le intenzioni dichiarate corrispondono a comportamenti concreti. Inoltre il campionamento utilizzato è di tipo non probabilistico e basato su convenienza. Tale scelta metodologica, pur necessaria per ragioni pratiche e temporali, potrebbe limitare la generalizzazione dei risultati. Il campione potrebbe non rappresentare accuratamente l'intera popolazione dei consumatori dei servizi di *Food Delivery* e *Fast Food*, essendo stato reclutato prevalentemente tramite canali online e *social media*.

In secondo luogo, il disegno sperimentale è *cross-sectional*. Sebbene questo approccio consenta di individuare associazioni significative tra le variabili come il *Timing* personalizzato, la *promotion Fatigue* e l'intenzione d'acquisto immediata non consente di trarre inferenze causali definitive, non è possibile trarre conclusioni definitive dagli effetti osservati. Uno studio longitudinale, che monitorasse nel tempo lo stesso campione di consumatori, potrebbe contribuire a chiarire ulteriormente la natura di queste relazioni, tramite A/B testing, permettendo così di comprendere come le preferenze e le intenzioni evolvano con l'esposizione ripetuta a promozioni altamente personalizzate.

Un ulteriore limite riguarda il metodo utilizzato per la costruzione e validazione dell'indice integrato M. la regressione lineare multipla impiegata per determinare i pesi relativi alle metriche *hard* e *soft* è stata condotta su una parte dello stesso campione utilizzato per testare l'indice stesso.

Per quanto riguarda il trattamento statistico dei dati, la scelta di tecniche di normalizzazione (*Min-Max* e *z-score*) e la gestione degli *outlier* potrebbero aver

influenzato la robustezza dei risultati, in particolare alcuni valori estremi individuati come *outlier*, pur giudicati come validi dal nodo KNIME utilizzato potrebbe aver influito sui coefficienti della regressione lineare e sulle azioni di mediazione moderata con PROCESS Model 14.


Infine, bisogna considerare che le formule utilizzate per le metriche *hard* utilizzano assunzioni standardizzate, dovendo tralasciare dettagli operativi reali come costi specifici dei singoli prodotti o i margini variabili dei singoli *delivery*. Queste semplificazioni possono generare stime economiche meno precise rispetto a quelle che potrebbero derivare da analisi basate su dati aziendali dettagliati.

Nonostante questi limiti metodologici e tecnici, la presente ricerca offre comunque un contributo significativo alla comprensione delle dinamiche di *Timing* promozionale e alla validità dell'integrazione tra metriche *hard* e *soft* in un unico indice predittivo. Le considerazioni qui esposte possono servire come base per ulteriori indagini future più approfondite.


Capitolo 3: Risultati e Implicazioni

3.1 Preparazione dei dati e caratteristiche del campione

Il dataset finale utilizzato per l'analisi comprende un totale di 152 casi validi, ovvero che hanno risposto correttamente alle domande di controllo. Questi partecipanti sono stati assegnati a quattro condizioni sperimentali distinte:



Il campione totale raggiunto è stato di 188 rispondenti, tuttavia nella fase preliminare ne sono stati esclusi 11 poiché le loro risposte erano incomplete. Successivamente il dataset è stato sottoposto a una procedura di pulizia dei dati per andare a verificare chi non avesse passato *l'attention check* sugli scenari visualizzati, da questa analisi effettuata su KNIME, facendo un confronto tra lo scenario visualizzato effettivamente e la domanda di attenzione, dal quale sono emersi 16 rispondenti che essendo inadatti all'inclusione nel campione finale sono stati esclusi. Con il proseguimento dell'analisi su KNIME grazie al nodo "*numeric outlier*" sono stati rimossi 3 rispondenti identificati come *outliers* univariati sulla base del criterio dell'Interquartile Range (IQR). Il campione è compreso



di 82 femmine, 68 maschi e 2 rispondenti che preferiscono non specificare, distribuiti in base all'età nel grafico sopra

3.2 Validazione degli strumenti di misurazione

3.2.1 Affidabilità interna

Prima di procedere con le analisi inferenziali, è stato verificato che le scale utilizzate già prevaliate in letteratura presentassero un adeguata coerenza interna sul campione raccolto. Per la *Customer Satisfaction* l' α di Cronbach è risultato pari a 0,88 confermando la bontà del costrutto. Il *Customer Engagement* ha ottenuto un α di Cronbach di 0,91 dopo il riadattamento della scala adottata da Hollebeek et al. (2014). La *Promotion Fatigue* ha fornito un α di Cronbach uguale a 0,85 ed infine l'importanza del *Timing*, rappresentato da un unico item, ha come statistiche descrittive Media = 5,2 e SD = 1,3.

Questa consistenza interna garantisce che le misure di *Satisfaction*, *Engagement* e *Fatigue* riflettano senza eccessiva ridondanza i rispettivi costrutti per la misurazione dell'indice composto M.

3.2.2 Analisi Fattoriale esplorativa (EFA)


Per verificare empiricamente che gli item “soft” misurati nel questionario si raggruppino in costrutti distinti e sfruttare le varianze relative per la costruzione dell'indice composto M, è stata eseguita l'EFA sugli indicatori.

Il test Kaiser–Meyer–Olkin (KMO) restituisce come un valore di 0,70, indicando una discreta adeguatezza del campione per l'analisi fattoriale. Il test di Barlett risulta

$\chi^2(21)=436,616$; $p<.001$, confermando anche qui che la matrice di correlazione non è identità e che gli item condividono sufficienti correlazioni per estrarre fattori comuni.

Per l'estrazione dei valori è stata effettuata l'Analisi delle componenti principali (PCA) come metodo di estrazione e il criterio di *eigenvalue* >1 , che ha suggerito l'estrazione di tre fattori latenti.

Il grafico scree mostra un “ginocchio” dopo il terzo autovalore.



Tutti gli item presentano comunaltà di estrazione superiore a 0,75 dimostrando che ciascuna variabile contribuisce in modo consistente alla struttura fattoriale complessiva. Infine, è stata effettuata la rotazione Varimax con normalizzazione Kaiser per migliorare l'interpretabilità. Dal confronto tra le matrici di componenti non ruotate e ruotate emergono chiaramente 3 blocchi di item. Il primo fattore (29,9% della varianza ruotata) raggruppa gli item di *Satisfaction* e *Engagement*; il secondo fattore (28,1%) è composto dagli item di *Fatigue*; il terzo fattore (22,2%) contenente l'unico item di importanza del *Timing*, confermando che la variabile si configura come distinta.

Questa analisi non solo conferma la presenza dei tre costrutti empirici, coerenti con la teoria ma le percentuali della varianza spiegata da ciascun fattore (circa 44,5% il primo, 21,1% il secondo e 14,6% il terzo) forniscono un solido criterio per attribuire i pesi relativi alle componenti *soft* all'interno dell'indice costruito M accanto alla metrica *hard* (rapporto ROI/CLV).

3.3 Controllo delle manipolazioni

Prima di procedere con l'analisi delle ipotesi principali è stata effettuata la verifica che i rispondenti abbiano percepito la manipolazione sperimentale per gli scenari realizzati. Per quanto riguarda la manipolazione della *Promotion Fatigue* sono stati effettuati due t-test per campioni indipendenti, uno sull'intenzione d'acquisto e l'altro sulla percezione di *Fatigue*.

Statistiche gruppo

	X	N	Media	Deviazione std.	Errore standard della media
Intenzion d'acquisto	0	74	2,30	1,311	,152
	1	78	4,97	1,486	,168

In questa prima analisi è stata effettuato il t-test in funzione del *Timing*, dove 0 rappresenta il gruppo che ha visualizzato il *Timing* generico, mentre 1 il gruppo che ha visualizzato lo scenario di *Timing* specifico.

Ottenendo come risultati le statistiche di gruppo rappresentate nella tabella sopraindicata. Dal test di Leven: $F = 0,941$ e $p = 0,333$ (varianze omogenee); $t(150) = -11,76$ con $p < 0,001$; $\Delta M = -2,68$ (95% CI $[-3.127, -2.227]$) e come effetti Cohen's $d = 1,40$; Hedges' $g = 1,41$; Glass's $\Delta = 1,49$.

Il gruppo "*Timing* specifico" ha riportato un'intenzione d'acquisto significativamente più alta, con un effetto di entità molto grande, osservabile dalla deviazione standard.

Statistiche gruppo

	W	N	Media	Deviazione std.	Errore standard della media
Intenzion d'acquisto	0	80	4,06	2,058	,230
	1	72	3,24	1,707	,201
percezione fatigue	0	80	5,41	1,099	,123
	1	72	2,58	1,172	,138

Osservando anche che la condizione sperimentale relativa alla *Promotion Fatigue* avesse effettivamente introdotto differenze nella percezione di sovraccarico promozionale. In questo caso $W = 0$ rappresenta il gruppo che ha visualizzato lo scenario con alta esposizione, mentre $W = 1$ lo scenario con bassa esposizione.

Dal test di Leven: $F = 0,968$ e $p = 0,327$ (anche qui varianze omogenee); $t(150) = 15,358$, $p < 0,001$; $\Delta M = 2,829$ (95 % CI [2,465; 3,193]). Pure in questo caso le dimensioni dell'effetto risultano elevate, confermando la bontà della manipolazione: Cohen's $d = 1,1$; Hedges' $g = 1,14$; Glass's $\Delta = 1,17$.

Questi risultati dimostrano che lo scenario di “alta esposizione promozionale” ha prodotto una percezione di *Fatigue* significativamente maggiore rispetto all'altro scenario.

In entrambi i casi la manipolazione sperimentale può essere quindi ritenuta efficace e riuscita.

3.4 Analisi descrittive

Per quanto riguarda le due metriche *soft*, per la *Satisfaction* abbiamo $M \approx 5,1$; $SD \approx 1,0$, mentre per la *Customer Engagement* $M \approx 4,9$; $SD \approx 1,1$. Entrambe le medie indicano un buon livello di soddisfazione e coinvolgimento. Allo stesso tempo la variabilità intorno a 1 punto Likert è normale vista la possibilità di diverse abitudini dei rispondenti.

La *Promotion Fatigue* ha come valore medio circa 4 e la deviazione standard relativamente alta riflettono efficacemente la presenza delle due condizioni sperimentali. L'importanza del *Timing* invece ha una media ben superiore al punto centrale, sottolineando come gli utenti percepiscano davvero l'importanza del “quando” viene ricevuta una promozione.

Dal punto di vista delle metriche *hard* invece osserviamo che il ROI medio è di circa il 42% sugli investimenti promozionali ed è in linea con i risultati di campagne digitali osservate da (Almestarihi et al., 2024).

L'indice M ha come media circa 0,58 e deviazione standard pari a 0,17, questo indica che complessivamente le metriche *hard* e *soft* si bilanciano in modo equilibrato.

3.5 Analisi dell'indice integrato M

L'indice integrato M è stato sviluppato per sintetizzare in un unico valore le dimensioni economiche e relazionali dei comportamenti d'acquisto. Come discusso nella sezione della metodologia, più precisamente nella sezione 2.4.4, questo indicatore combina metriche *hard* come rapporto tra ROI e CLV e *soft* come la *Satisfaction* e il rapporto tra *Fatigue* e importanza percepita del *Timing*. La formula utilizzata è:

$$M = w_1 \times \frac{ROI}{CLV} + w_2 \times Satisfaction + w_3 \times \left(\frac{1 - fatigue}{imp_timing} \right)$$

Ciascun elemento è normalizzato tra 0 e 1 per garantire confrontabilità tra le variabili, oltre a semplificare l'interpretazione.

I pesi stimati tramite regressione lineare mostrano che il rapporto ROI/CLV, *Satisfaction* e il rapporto tra *Fatigue* e importanza del *Timing* hanno un peso significativo, mentre l'*Engagement* risulta meno rilevante.

S Variable	D Coeff.	D Std. Err.	D t-value	D P> t
Engagement_tot	0.139	0.121	1.154	0.25
Satisfaction_tot	0.485	0.138	3.507	0.001
Ratio	0.324	0.066	4.919	0
S	0.27	0.089	3.035	0.003
Intercept	0	0.065	0	1

3.6 Test dell'ipotesi (PROCESS Model 14)

Per valutare in modo integrato come il *Timing* delle promozioni (X) influenzi l'intenzione d'acquisto (Y) sia direttamente che attraverso l'indice integrato M che appunto combina metriche *hard* e *soft* moderato dalla *Promotion Fatigue*, è stato utilizzato il modello di mediazione moderata PROCESS Model 14 di Hayes (2018).

Il primo passaggio è quello di verificare se il *Timing* delle promozioni abbia un impatto significativo sull'indice composto M. Osservando l'output del modello di mediazione moderata, vediamo che dal passaggio dal gruppo *Timing* specifico a quello generico l'indice M medio aumenta di circa 0,087 unità; quindi, il valore composto si innalza rispetto ad una promozione inviata in un momento casuale. Il coefficiente di X sul punteggio M è pari a 0,0874 (SE = 0,0231; t = 3,7819; p = 0,0002; 95 % CI [0,0417; 0,1330])

Dunque, l'ipotesi secondo cui il *Timing* specifico della promozione migliora l'indice M risulta pienamente supportata.

Nel secondo stadio sono stati inclusi tutti e quattro i predittori X, M, W e il termine di interazione M x W, osservando gli effetti diretti e moderati su Y.

Questo modello spiega il 61,7% della varianza dell'intenzione d'acquisto Y ($R = 0,7856$; $R^2 = 0,6171$; $F(4, 147) = 59,2284$; $p < 0,001$).

Effetto diretto di X su Y: Il coefficiente di X è pari a 2,2929 ($SE = 0,2071$; $t = 11,0699$; $p < 0,001$), con 95 % CI [1,8836; 2,7022]. Indicando che indipendentemente dagli altri fattori, il “*Timing* specifico” aumenta l'intenzione di acquisto di circa 2,29 punti sulla scala Likert rispetto al “*Timing* generico”. Anche dopo aver tenuto in conto dell'indice composito M, rimane dunque un effetto netto e molto pronunciato del *Timing* sull'intenzione di acquisto.

Effetto di M su Y: M risulta un predittore molto forte di Y: il coefficiente è 5,6910 ($SE = 0,9796$; $t = 5,8096$; $p < 0,001$; 95 % CI [3,7551; 7,6269]). In assenza di *Promotion Fatigue*, ogni incremento unitario nell'indice integrato M si traduce in un aumento di 5,691 punti nell'intenzione d'acquisto.

Effetto principale W su Y: Il coefficiente di W ($b = 0,1300$; $SE = 0,4479$; $t = 0,2902$; $p = 0,7721$) non risulta significativo. Il fatto di trovarsi in condizioni di “alta *Promotion Fatigue*” rispetto a “bassa *Promotion Fatigue*” non modifica in modo significativo l'intenzione di acquisto quando gli altri fattori sono tenuti costanti.

Interazione M x W: Il coefficiente di interazione è -2,9442 ($SE = 1,3359$; $t = -2,2039$; $p = 0,0291$; 95 % CI [-5,5842; -0,3041]). Questo risultato conferma che la relazione fra M e Y cambia in funzione del livello di *Promotion Fatigue*. In particolare, l'effetto positivo di M, si riduce di quasi 2,95 punti quando cresce la *Fatigue* da bassa ad alta. Quindi possiamo dire che l'elevata percezione di “troppi messaggi promozionali” attenua drasticamente l'impatto di tutte le metriche combinate su Y.

Per misurare in che misura il *Timing* X influenzi l'intenzione d'acquisto Y attraverso l'indice M a differenza dei livelli di *Promotion Fatigue* abbiamo calcolato e osservato gli effetti indiretti condizionati.

Quando $W = 0$ (bassa fatica promozionale), l'effetto indiretto di X su Y è pari a 0,4972 ($BootSE = 0,1329$; 95 % CI [0,2950; 0,8096]). Il fatto che l'intervallo di confidenza non includa lo zero indica che questa via indiretta è altamente significativa: in condizioni di

bassa fatica, la combinazione fra ROI/CLV e metriche *soft* combinate dall'indice M contribuisce notevolmente a spiegare come il *Timing* influisca sull'intenzione di acquisto. Quando $W = 1$ (alta fatica promozionale), l'effetto indiretto $X \rightarrow M \rightarrow Y$ si riduce a 0,2400 (BootSE = 0,0749; 95 % CI [0,1263; 0,4144]), anch'esso significativamente diverso da zero. Sebbene rimanga presente una mediazione positiva, essa è decisamente più attenuata. L'“indice di mediazione moderata” è pari a -0,2572 (BootSE = 0,1429; 95 % CI [-0,5621; -0,0054]). Poiché l'intervallo di confidenza non comprende lo zero, possiamo affermare che il grado di *Promotion Fatigue* modera l'intensità dell'effetto mediato: l'“ottimo” *Timing* genera un maggior incremento in Y attraverso M quando la fatica è bassa, mentre questo percorso si indebolisce in presenza di elevata fatica promozionale.

3.7 Discussione dei risultati

Nel loro complesso, i risultati ottenuti confermano le quattro ipotesi principali:

Effetto diretto del *Timing* sul comportamento (H_1)

Le promozioni inviate in un momento strategico ($X = 1$) comportano un aumento medio di 2,29 punti nella scala di intenzione di acquisto, anche una volta controllato l'indice M. Ciò dimostra che, oltre a tutti i meccanismi mediati, il “quando” una proposta arriva gioca un ruolo cruciale e produce un impatto diretto sulla propensione all'acquisto.

Mediazione dell'indice integrato (H_2)

Il *Timing* influenza positivamente l'indice M ($b = 0,0874$), e M a sua volta, contribuisce in modo molto marcato a innalzare l'intenzione di acquisto ($b = 5,6910$). L'effetto indiretto $X \rightarrow M \rightarrow Y$, pari a 0,4972 in condizioni di bassa fatica, è sostanziale e conferma come metriche *hard* e *soft* siano il canale mediante il quale un *Timing* appropriato si traduce in una maggiore intenzione di acquisto.

Moderazione della *Promotion Fatigue* (H_3)

L'interazione $M \times W$ è significativa e negativa: quando un consumatore percepisce elevata “*Fatigue*” ($W = 1$), l'impatto di M su Y diminuisce di circa 2,94 punti rispetto a quando la fatica è bassa. Di conseguenza, la stessa qualità di M si traduce in un ridotto incremento di intenzione di acquisto se l'utente si sente “straccato” dagli eccessi promozionali.

Mediazione moderata (H_4)

L'effetto indiretto condizionato dimostra che, con $W = 0$, l'incremento stimato in Y tramite M è quasi il doppio rispetto a quando $W = 1$ (0,4972 vs. 0,2400). Il confronto dei due intervalli di confidenza (che non si sovrappongono) e l'indice di mediazione moderata ($-0,2572$; 95 % CI $[-0,5621; -0,0054]$) provano in modo inequivocabile che, se l'attenzione del consumatore è attenuata dalla ripetitività delle comunicazioni, la leva *Timing*+indice integrato perde in efficacia.

Nel dettaglio, utilizzando il PROCESS Model 14, è stata ulteriormente confermata la capacità di M di mediare l'effetto del *Timing* sull'intenzione di acquisto, considerando la moderazione esercitata dalla *Promotion Fatigue*. L'analisi ha evidenziato come l'indice M eserciti un effetto positivo e significativo sull'intenzione d'acquisto ($B = 0,406$; $p < 0,001$), ma tale effetto risulti significativamente indebolito dall'incremento della *Promotion Fatigue* (interazione $M \times Promotion Fatigue$: $B = -0,027$; $p = 0,015$). In termini pratici, quando la *Promotion Fatigue* è alta, anche elevati livelli dell'indice M vedono ridursi parte della loro efficacia predittiva.

Dal punto di vista del marketing manageriale, questi risultati racchiudono un duplice insegnamento: Inviare offerte “al momento giusto” rappresenta di per sé una leva molto potente, in grado di innalzare l'intenzione di acquisto in maniera significativa.

Allo stesso tempo, è fondamentale monitorare la frequenza e la qualità complessiva delle promozioni (ossia mantenere bassa la “*Promotion Fatigue*”), perché solo in questa condizione il mix di metriche *hard* (ROI/CLV) e *soft* (soddisfazione, *Engagement* e *Fatigue*) espresso dall'indice composito M riesce a sprigionare il massimo effetto sulla decisione di acquisto.

L'organizzazione deve trovare un equilibrio tra il tempismo nell'inviare le offerte (per massimizzare l'impatto immediato) e la cura con cui queste offerte vengono percepite (per non generare saturazione). Una strategia ottimale, dunque, non può prescindere da una segmentazione dinamica dei consumatori ma sfruttando il ML e l'AI deve essere capace di calcolare in real time il momento ottimale per inviare un coupon o uno sconto altamente personalizzato, questo è possibile andando ad analizzare i record di dati storici dei clienti, ovvero il momento in cui viene effettuato l'ordine e il tipo di prodotto scelto. Così da avere un dosaggio intelligente dei messaggi nel tempo, in modo da evitare di erodere la “carica” motivazionale dei clienti.

Con questi risultati l'analisi PROCESS Model 14 ha permesso di mettere in luce come il *Timing* delle promozioni eserciti contemporaneamente un effetto diretto e un effetto indiretto (mediato dall'indice integrato M), e come il livello di *Promotion Fatigue* condizionali negativamente quest'ultimo. Complessivamente, i risultati confermano la centralità del “quando” una promozione viene proposta, ma ribadiscono che, senza un'adeguata attenzione alla soglia di “*Fatigue*,” il valore di medio-lungo periodo (CLV) e le percezioni qualitative (soddisfazione, *Engagement*) rischiano di non tradursi pienamente in azione di acquisto.

Appendicie

```
. Model : 14
. Y : Y
. X : X
. M : M
. W : W

. Sample
. Size: 152

*****

. OUTCOME VARIABLE:
. M

. Model Summary
.      R      R-sq      MSE      F      df1      df2      |      p
.    ,2950    ,0870    ,0203    14,3024    1,0000    150,0000    |    ,0002

. Model
.      coeff      se      t      p      LLCI      ULCI
. constant ,2554    ,0165    15,4310    ,0000    ,2227    ,2881
. X         ,0874    ,0231     3,7819    ,0002    ,0417    ,1330

*****
```

OUTCOME VARIABLE:

Y

Model Summary

R	R-sq	MSE	F	df1	df2	p
,7856	,6171	1,4783	59,2284	4,0000	147,0000	,0000

Model

	coeff	se	t	p	LLCI	ULCI
constant	1,1511	,3204	3,5922	,0004	,5178	1,7844
X	2,2929	,2071	11,0699	,0000	1,8836	2,7022
M	5,6910	,9796	5,8096	,0000	3,7551	7,6269
W	,1300	,4479	,2902	,7721	-,7551	1,0150
Int_1	-2,9442	1,3359	-2,2039	,0291	-5,5842	-,3041

Product terms key:

Int_1 : M x W

Test(s) of X by M interaction:

F	df1	df2	p
14,8322	1,0000	146,0000	,0002

Test(s) of highest order unconditional interaction(s):

R2-chng	F	df1	df2	p
M*W ,0127	4,8570	1,0000	147,0000	,0291

Focal predict: M (M)

Mod var: W (W)

Conditional effects of the focal predictor at values of the moderator(s):

W	Effect	se	t	p	LLCI	ULCI
,0000	5,6910	,9796	5,8096	,0000	3,7551	7,6269
1,0000	2,7468	,9534	2,8811	,0046	,8627	4,6310


```

***** DIRECT AND INDIRECT EFFECTS OF X ON Y *****
Direct effect of X on Y
  Effect      se      t      p      LLCI      ULCI
  2,2929      ,2071  11,0699  ,0000  1,8836  2,7022

Conditional indirect effects of X on Y:

INDIRECT EFFECT:
X      ->  M      ->  Y

  W      Effect  BootSE  BootLLCI  BootULCI
,0000      ,4972      ,1329      ,2950      ,8096
1,0000      ,2400      ,0749      ,1263      ,4144

Index of moderated mediation (difference between conditional indirect effects):
  Index  BootSE  BootLLCI  BootULCI
W  -,2572      ,1429      -,5621      -,0054

***** ANALYSIS NOTES AND ERRORS *****

Level of confidence for all confidence intervals in output:
95,0000

Number of bootstrap samples for percentile bootstrap confidence intervals:
5000

----- END MATRIX -----

```

Analisi fattoriale

Test di KMO e Bartlett

Misura di Kaiser-Meyer-Olkin di adeguatezza del campionamento.		,701
Test della sfericità di Bartlett	Appross. Chi-quadrato	436,616
	gl	21
	Sign.	<,001

Comunalità

	Iniziale	Estrazione
Q timing _1	1,000	,794
Q fatigue_2	1,000	,764
Q fatigue_1	1,000	,793
satisfaction_1	1,000	,832
satisfaction_2	1,000	,772
engagement_1	1,000	,862
engagement_2	1,000	,798

Metodo di estrazione: Analisi dei componenti principali.

Varianza totale spiegata

Componente	Autovalori iniziali			Caricamenti somme dei quadrati di estrazione			Caricamenti somme dei quadrati di rotazione		
	Totale	% di varianza	% cumulativa	Totale	% di varianza	% cumulativa	Totale	% di varianza	% cumulativa
1	3,118	44,536	44,536	3,118	44,536	44,536	2,093	29,893	29,893
2	1,479	21,128	65,664	1,479	21,128	65,664	1,968	28,117	58,010
3	1,020	14,565	80,229	1,020	14,565	80,229	1,555	22,219	80,229
4	,471	6,735	86,964						
5	,460	6,571	93,535						
6	,232	3,313	96,848						
7	,221	3,152	100,000						

Metodo di estrazione: Analisi dei componenti principali.

Matrice dei componenti^a

	Componente		
	1	2	3
Q timing _1	,581	,127	-,664
Q fatigue_2	-,354	,798	,032
Q fatigue_1	-,226	,844	,174
satisfaction_1	,795	,031	,446
satisfaction_2	,818	,218	-,234
engagement_1	,768	-,023	,521
engagement_2	,843	,254	-,151

Metodo di estrazione: Analisi dei componenti principali.

a. 3 componenti estratti.

Matrice dei componenti ruotati^a

	Componente		
	1	2	3
Q timing _1	-,039	,883	-,111
Q fatigue_2	-,181	-,042	,854
Q fatigue_1	,012	-,046	,889
satisfaction_1	,881	,221	-,086
satisfaction_2	,436	,763	-,014
engagement_1	,911	,136	-,120
engagement_2	,513	,731	,028

Metodo di estrazione: Analisi dei componenti principali.

Metodo di rotazione: Varimax con normalizzazione Kaiser.^a

a. Convergenza per la rotazione eseguita in 5 iterazioni.

Matrice di trasformazione dei componenti

Componente	1	2	3
1	,715	,661	-,230
2	,062	,267	,962
3	,697	-,701	,150

Metodo di estrazione: Analisi dei componenti principali.

Metodo di rotazione: Varimax con normalizzazione Kaiser.

Intro alta fatigue

Scenario alta fat

Scenario 2

Immagina che ultimamente stai ricevendo molte comunicazioni e promozioni generiche da servizi di food delivery e fast food. Alcune di queste sono generiche e non particolarmente rilevanti per te. Tieni a mente questa situazione mentre rispondi alle prossime domande.

Intro bassa fatigue

Scenario bassa fat

Scenario 1

Immagina che ultimamente stai ricevendo poche promozioni e comunicazioni, ma tutte altamente mirate e personalizzate in base ai tuoi gusti e preferenze. Tieni a mente questa situazione mentre rispondi alle prossime domande.

Scenario specifico

...

Immagina di trovarti a casa poco prima di un pasto (ad esempio pranzo o cena). Sei indeciso se cucinare oppure ordinare da un servizio di Food Delivery. Proprio in questo momento ricevi sul tuo smartphone una promozione personalizzata solo per te valida per breve tempo (entro le prossime due ore). Ricorda che ultimamente ricevi poche promozioni ma molto rilevanti.

Scenario generico

...

Immagina di trovarti in un momento qualsiasi della tua giornata, non specifico, durante il quale NON è il TUO orario abituale per mangiare o ordinare. Proprio in questo momento ricevi sul tuo smartphone una promozione generica da parte del tuo servizio di food delivery, senza particolari personalizzazioni, una promozione standard.

Ricorda che ultimamente ricevi molte comunicazioni e promozioni poco rilevanti.

Statistiche

		CLV	ROI	Engagement_tot	Satisfaction_tot	indice	Ratio	S
N	Valido	152	152	152	152	152	152	152
	Mancante	0	0	0	0	0	0	0
Media		2347,6913477	43,789240406	3,8815789474	3,9703947368	,30020022825	122,44468776	-1,106077694
Deviazione std.		2325,6642695	50,074993694	1,3068044566	1,2101030998	,14849792566	209,73293252	,99132484056
Minimo		,00000000000	-1,0000000000	1,0000000000	1,0000000000	,01890581065	,00000000000	-6,0000000000
Massimo		13769,929992	324,52083333	7,0000000000	6,5000000000	,95124343741	1128,2303214	-,2500000000

Test t

Statistiche gruppo

	X	N	Media	Deviazione std.	Errore standard della media
Intenzion d'acquisto	0	74	2,30	1,311	,152
	1	78	4,97	1,486	,168

Test campioni indipendenti

		Test di Levene per l'uguaglianza delle varianze				Test t per l'uguaglianza delle medie						Intervallo di confidenza della differenza di 95%	
		F	Sign.	t	gl	Significatività P unilaterale	Significatività P bilaterale	Differenza della media	Differenza errore std.			Inferiore	Superiore
Intenzion d'acquisto	Varianze uguali presunte	,941	,333	-11,755	150	<,001	<,001	-2,677	,228			-3,127	-2,227
	Varianze uguali non presunte			-11,794	149,231	<,001	<,001	-2,677	,227			-3,126	-2,229

Dimensioni effetto campioni indipendenti

		Standardizzator e ^a	Stima del punto	Intervallo di confidenza 95%	
				Inferiore	Superiore
Intenzion d'acquisto	D di Cohen	1,403	-1,908	-2,290	-1,521
	Correzione di Hedges	1,410	-1,898	-2,278	-1,513
	Delta di Glass	1,486	-1,802	-2,225	-1,372

a. Il denominatore utilizzato per stimare le dimensioni dell'effetto.

La d di Cohen utilizza la deviazione standard raggruppata.

La correzione di Hedge utilizza la deviazione standard raggruppata, più un fattore di correzione.

Il delta di Glass utilizza la deviazione standard del campione del gruppo di controllo (ovvero il secondo).

Statistiche gruppo

	W	N	Media	Deviazione std.	Errore standard della media
Intenzion d'acquisto	0	80	4,06	2,058	,230
	1	72	3,24	1,707	,201
percezione fatigue	0	80	5,41	1,099	,123
	1	72	2,58	1,172	,138

Test campioni indipendenti

		Test di Levene per l'uguaglianza delle varianze				Test t per l'uguaglianza delle medie						Intervallo di confidenza della differenza di 95%	
		F	Sign.	t	gl	Significatività P unilaterale	Significatività P bilaterale	Differenza della media	Differenza errore std.			Inferiore	Superiore
Intenzion d'acquisto	Varianze uguali presunte	4,632	,033	2,677	150	,004	,008	,826	,309			,216	1,436
	Varianze uguali non presunte			2,703	149,042	,004	,008	,826	,306			,222	1,430
percezione fatigue	Varianze uguali presunte	,968	,327	15,358	150	<,001	<,001	2,829	,184			2,465	3,193
	Varianze uguali non presunte			15,306	145,784	<,001	<,001	2,829	,185			2,464	3,194

Dimensioni effetto campioni indipendenti


		Standardizzator e ^a	Stima del punto	Intervallo di confidenza 95%	
				Inferiore	Superiore
Intenzion d'acquisto	D di Cohen	1,900	,435	,112	,756
	Correzione di Hedges	1,910	,433	,111	,753
	Delta di Glass	1,707	,484	,154	,811
percezione fatigue	D di Cohen	1,134	2,495	2,067	2,918
	Correzione di Hedges	1,140	2,482	2,057	2,903
	Delta di Glass	1,172	2,414	1,902	2,919


a. Il denominatore utilizzato per stimare le dimensioni dell'effetto.




La d di Cohen utilizza la deviazione standard raggruppata.


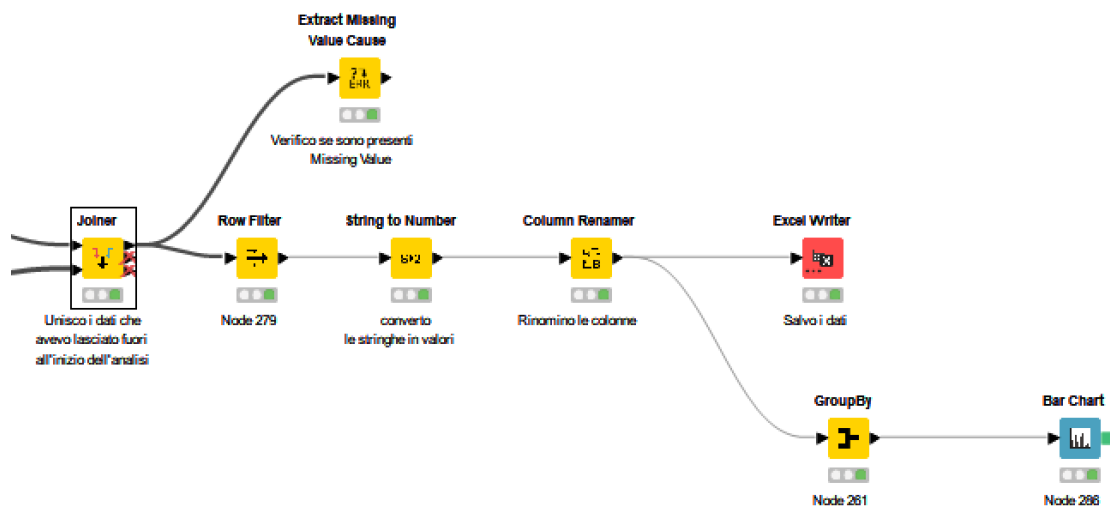
La correzione di Hedge utilizza la deviazione standard raggruppata, più un fattore di correzione.

Il delta di Glass utilizza la deviazione standard del campione del gruppo di controllo (ovvero il secondo).









Bibliografia

1. Akter, J., Roy, A., Rahman, S., Mohona, S., & Ara, J. (2025). Artificial Intelligence-Driven Customer Lifetime Value (CLV) Forecasting: Integrating RFM Analysis with Machine Learning for Strategic Customer Retention. <https://doi.org/10.32996/jcsts>
2. Ali, N., & Shabn, O. S. (2024). Customer lifetime value (CLV) insights for strategic marketing success and its impact on organizational financial performance. *Cogent Business and Management*, 11(1). <https://doi.org/10.1080/23311975.2024.2361321>
3. Almestarihi, R., Ahmad, A. Y. A. B., Frangieh, R. H., Abualsondos, I. A., Nser, K. K., & Ziani, A. (2024). Measuring the ROI of paid advertising campaigns in digital marketing and its effect on business profitability. *Uncertain Supply Chain Management*, 12(2), 1275–1284. <https://doi.org/10.5267/j.uscm.2023.11.009>
4. Arenoe, B., & van der Rest, J. P. I. (2020). Does Willingness to Pay for Rate Conditions Depend on the Booking Window? A Novel Time-Dependent Conjoint Analysis Approach. *Cornell Hospitality Quarterly*, 61(2), 213–222. <https://doi.org/10.1177/1938965519864863>
5. Asadi Ejgerdi, N., & Kazerooni, M. (2024). A stacked ensemble learning method for customer lifetime value prediction. *Kybernetes*, 53(7), 2342–2360. <https://doi.org/10.1108/K-12-2022-1676>
6. Ban, G. Y., & Keskin, N. B. (2021). Personalized dynamic pricing with machine learning: High-dimensional features and heterogeneous elasticity. *Management Science*, 67(9), 5549–5568. <https://doi.org/10.1287/mnsc.2020.3680>
7. Bhaulal Patil, G., Krishna Padyana, U., Premshankar Rai, H., Ogeti, P., & Sharad Fadnavis, N. (2021). Personalized Marketing Strategies Through Machine Learning: Enhancing Customer Engagement. In *Journal of Informatics Education and Research* (Vol. 1). <http://jier.org>
8. Chandra, S., Verma, S., Lim, W. M., Kumar, S., & Donthu, N. (2022). Personalization in personalized marketing: Trends and ways forward. In *Psychology and Marketing* (Vol. 39, Issue 8, pp. 1529–1562). John Wiley and Sons Inc. <https://doi.org/10.1002/mar.21670>
9. Che Ishak, F. A., Che Lah, N. A., Samengon, H., Mohamad, S. F., & Abu Bakar, A. Z. (2021). The Implementation of Self-Ordering Kiosks (SOKs): Investigating the Challenges in Fast Food Restaurants. *International Journal of Academic Research in Business and Social Sciences*, 11(10). <https://doi.org/10.6007/ijarbss/v11-i10/11491>
10. Chen, T., Samaranayake, P., Cen, X. Y., Qi, M., & Lan, Y. C. (2022). The Impact of Online Reviews on Consumers' Purchasing Decisions: Evidence From an Eye-Tracking Study. *Frontiers in Psychology*, 13. <https://doi.org/10.3389/fpsyg.2022.865702>
11. Dai, X. (2022). Customer Lifetime Value Analysis Based on Machine Learning. *ACM International Conference Proceeding Series*, 13–17. <https://doi.org/10.1145/3546157.3546160>
12. Dandis, A. O., Wallace-Williams, D. M., Ni, A. K., Wright, L. T., & Abu Siam, Y. I. (2023). The effect of brand experiences and relational benefits on loyalty in the fast-food restaurants. *TQM Journal*, 35(7), 2028–2051. <https://doi.org/10.1108/TQM-03-2022-0091>
13. de Mauro, A., Sestino, A., & Bacconi, A. (2022). Machine learning and artificial intelligence use in marketing: a general taxonomy. *Italian Journal of Marketing*, 2022(4), 439–457. <https://doi.org/10.1007/s43039-022-00057-w>
14. Ellickson, P. B., Kar, W., & Reeder, J. C. (2023). Estimating Marketing Component Effects: Double Machine Learning from Targeted Digital Promotions. *Marketing Science*, 42(4), 704–728. <https://doi.org/10.1287/mksc.2022.1401>
15. Firmansyah, E. B., Machado, M. R., & Moreira, J. L. R. (2024). How can Artificial Intelligence (AI) be used to manage Customer Lifetime Value (CLV)—A systematic literature review. In *International Journal of Information Management Data Insights* (Vol. 4, Issue 2). Elsevier B.V. <https://doi.org/10.1016/j.ijime.2024.100279>
16. Følstad, A., & Kvale, K. (2018). Customer journeys: a systematic literature review. In *Journal of Service Theory and Practice* (Vol. 28, Issue 2, pp. 196–227). Emerald Group Holdings Ltd. <https://doi.org/10.1108/JSTP-11-2014-0261>
17. Gao, Y., & Liu, H. (2023). Artificial intelligence-enabled personalization in interactive marketing: a customer journey perspective. *Journal of Research in Interactive Marketing*, 17(5), 663–680. <https://doi.org/10.1108/JRIM-01-2022-0023>
18. Goldenberg, D., Albert, J., Bernardi, L., & Estevez, P. (2020). Free Lunch! Retrospective Uplift Modeling for Dynamic Promotions Recommendation within ROI Constraints. *RecSys 2020 - 14th ACM Conference on Recommender Systems*, 486–491. <https://doi.org/10.1145/3383313.3412215>
19. Hanaysha, J. R. (2022). An examination of social media advertising features, brand Engagement and purchase intention in the fast food industry. *British Food Journal*, 124(11), 4143–4160. <https://doi.org/10.1108/BFJ-08-2021-0907>
20. Hanaysha, J. R., Sharma, A., & Momani, A. M. (2021). AN EXPLORATION OF SOCIAL MEDIA MARKETING FEATURES AND BRAND LOYALTY IN THE FAST FOOD INDUSTRY. *Journal of Content, Community and Communication*, 14(7), 81–92. <https://doi.org/10.31620/JCCC.12.21/08>
21. Horta, P. M., de Paula Matos Souza, J., Rocha, L. L., & Mendes, L. L. (2021). Digital food environment of a Brazilian metropolis: Food availability and marketing strategies used by delivery apps. *Public Health Nutrition*, 24(3), 544–548. <https://doi.org/10.1017/S1368980020003171>
22. Huang, J., & Zhou, L. (2018). Timing of web personalization in mobile shopping: A perspective from Uses and Gratifications Theory. *Computers in Human Behavior*, 88, 103–113. <https://doi.org/10.1016/j.chb.2018.06.035>

23. Järvinen, J., & Karjaluo, H. (2015). The use of Web analytics for digital marketing performance measurement. *Industrial Marketing Management*, 50, 117–127. <https://doi.org/10.1016/j.indmarman.2015.04.009>
24. Koay, K. Y., Ong, D. L. T., Khoo, K. L., & Yeoh, H. J. (2021). Perceived social media marketing activities and consumer-based brand equity: Testing a moderated mediation model. *Asia Pacific Journal of Marketing and Logistics*, 33(1), 53–72. <https://doi.org/10.1108/APJML-07-2019-0453>
25. Lukita, C., Bakti, L. D., Rusilowati, U., Sutarman, A., & Rahardja, U. (2023). Predictive and Analytics using Data Mining and Machine Learning for Customer Churn Prediction. *Journal of Applied Data Sciences*, 4(4), 454–465. <https://doi.org/10.47738/jads.v4i4.131>
26. Manhas, P. S., Sharma, P., & Quintela, J. A. (2024). Product Innovation and Customer Experience: Catalysts for Enhancing *Satisfaction* in Quick Service Restaurants. *Tourism and Hospitality*, 5(3), 559–576. <https://doi.org/10.3390/tourhosp5030034>
27. Mao, W., Ming, L., Rong, Y., Tang, C. S., & Zheng, H. (2025). Faster Deliveries and Smarter Order Assignments for an On-Demand Meal Delivery Platform. *Journal of Operations Management*. <https://doi.org/10.1002/joom.1354>
28. Mashrur, F. R., Rahman, K. M., Miya, M. T. I., Vaidyanathan, R., Anwar, S. F., Sarker, F., & Mamun, K. A. (2024). Intelligent neuromarketing framework for consumers' preference prediction from electroencephalography signals and eye tracking. *Journal of Consumer Behaviour*, 23(3), 1146–1157. <https://doi.org/10.1002/cb.2253>
29. Mdletshe, N. E. (2023). CRAVING LOYALTY: EXAMINING THE INFLUENCE OF LOYALTY PROGRAMS ON CUSTOMER RETENTION IN SOUTH AFRICA'S FAST-FOOD LANDSCAPE. *European Journal of Management and Marketing Studies*, 8(3). <https://doi.org/10.46827/ejmm.v8i3.1607>
30. Mishra, R., Singh, R. K., & Koles, B. (2021). Consumer decision-making in omnichannel retailing: Literature review and future research agenda. In *International Journal of Consumer Studies* (Vol. 45, Issue 2, pp. 147–174). Blackwell Publishing Ltd. <https://doi.org/10.1111/ijcs.12617>
31. Morgan, N. A., Jayachandran, S., Hulland, J., Kumar, B., Katsikeas, C., & Somosi, A. (2022). Marketing performance assessment and accountability: Process and outcomes. *International Journal of Research in Marketing*, 39(2), 462–481. <https://doi.org/10.1016/j.ijresmar.2021.10.008>
32. Norman, J., Kelly, B., McMahon, A. T., Boyland, E., Chapman, K., & King, L. (2020). Remember Me? Exposure to Unfamiliar Food Brands in Television Advertising and Online Advergaming Drives Children's Brand Recognition, Attitudes, and Desire to Eat Foods: A Secondary Analysis from a Crossover Experimental-Control Study with Randomization at the Group Level. *Journal of the Academy of Nutrition and Dietetics*, 120(1), 120–129. <https://doi.org/10.1016/j.jand.2019.05.006>
33. Oblander, E. S., Gupta, S., Mela, C. F., Winer, R. S., & Lehmann, D. R. (2020). The past, present, and future of customer management. <https://doi.org/10.2307/48739832>
34. Petersen, J. A., McAlister, L., Reibstein, D. J., Winer, R. S., Kumar, V., & Atkinson, G. (2009). Choosing the Right Metrics to Maximize Profitability and Shareholder Value. *Journal of Retailing*, 85(1), 95–111. <https://doi.org/10.1016/j.jretai.2008.11.004>
35. Rachmawati, M., Patria Awaluddin, J., & Nurhadi Syarifuddin, M. (n.d.). THE EFFECT OF LIFESTYLE AND PROMOTION, TO PURCHASE DECISION FOOD AND BEVERAGES AT "HOLYWINGS" BANDUNG.
36. Rashi, P., Bist, A. S., Asmawati, A., Budiarto, M., & Prihastiw, W. Y. (2021). Influence Of Post Covid Change In Consumer Behavior Of Millennials On Advertising Techniques And Practices. *APTISI Transactions on Technopreneurship*, 3(2), 201–208. <https://doi.org/10.34306/att.v3i2.210>
37. Singh, R., & Sarangal, R. K. (2021). Innovation in Quick Service Restaurants (QSRs): A Future Perspective. *European Journal of Tourism, Hospitality and Recreation*, 11(2), 210–218. <https://doi.org/10.2478/ejthr-2021-0019>
38. Sun, Y., Liu, H., & Gao, Y. (2023). Research on customer lifetime value based on machine learning algorithms and customer relationship management analysis model. *Heliyon*, 9(2). <https://doi.org/10.1016/j.heliyon.2023.e13384>
39. Tong, T., Xu, X., Yan, N., & Xu, J. (2022). Impact of different platform promotions on online sales and conversion rate: The role of business model and product line length. *Decision Support Systems*, 156. <https://doi.org/10.1016/j.dss.2022.113746>
40. Ulmer, M. W., Thomas, B. W., Campbell, A. M., & Woyak, N. (2021). The restaurant meal delivery problem: Dynamic pickup and delivery with deadlines and random ready times. *Transportation Science*, 55(1), 75–100. <https://doi.org/10.1287/TRSC.2020.1000>
41. Venkatesan, R., & Farris, P. W. (2012). Measuring and Managing Returns from Retailer-Customized Coupon Campaigns. In *Source: Journal of Marketing* (Vol. 76, Issue 1).
42. Wedel, M., & Kannan, P. K. (2016). Marketing analytics for data-rich environments. *Journal of Marketing*, 80(6), 97–121. <https://doi.org/10.1509/jm.15.0413>
43. Zhang, J., & Liu-Thompkins, Y. (2024). Personalized email marketing in loyalty programs: The role of multidimensional construal levels. *Journal of the Academy of Marketing Science*, 52(1), 196–216. <https://doi.org/10.1007/s11747-023-00927-5>
44. Lu, X., Ba, S., Huang, L., & Feng, Y. (2013). Promotional marketing or word-of-mouth? Evidence from online restaurant reviews. *Information Systems Research*, 24(3), 596–612. <https://doi.org/10.1287/isre.1120.0454>
45. Dholakia, U. M., & Kimes, S. E. (2011). Daily Deal *Fatigue* or Unabated Enthusiasm? A Study of Consumer Perceptions of Daily Deal Promotions. <http://ssrn.com/abstract=1925865Electroniccopyavailableat:ht>

<https://ssrn.com/abstract=1925865>Electronic copy available at: <https://ssrn.com/abstract=1925865>

46. Hayes, A. F. (2012). PROCESS: A Versatile Computational Tool for Observed Variable Mediation, Moderation, and Conditional Process Modeling 1. <http://www.afhayes.com/>
47. Hayes, A. F., Montoya, A. K., & Rockwood, N. J. (2017). The analysis of mechanisms and their contingencies: PROCESS versus structural equation modeling. In *Australasian Marketing Journal* (Vol. 25, Issue 1, pp. 76–81). Elsevier Australia. <https://doi.org/10.1016/j.ausmj.2017.02.001>