



UNIVERSITÀ DEL PIEMONTE ORIENTALE

DIPARTIMENTO DI STUDI PER L'ECONOMIA E L'IMPRESA

Corso di Laurea Magistrale in Management e Finanza

Curriculum: Marketing and Operations Management

TESI DI LAUREA

L'efficacia dei touchpoint lungo il customer journey: un'analisi  
della relazione tra punti di interazione e scelte di acquisto  
nel settore dell'abbigliamento

*Relatore:*

*Prof.ssa Clementina Bruno*

*Candidato: Luca De Grandis*

*Matricola 20034132*

Anno Accademico: 2023/2024



# INDICE

## Sommario

1. INTRODUZIONE .....	5
1.1. IL VENDITORE NELL'ERA DIGITALE: TRA MULTI E OMNI CHANNEL .....	5
1.2. STRATEGIE OMNI-CHANNEL NEL MERCATO DELL'ABBIGLIAMENTO .....	6
1.3. OBIETTIVO DELL'ELABORATO .....	8
2. ANALISI DELLA LETTERATURA .....	10
2.1. CUSTOMER JOURNEY E CUSTOMER EXPERIENCE .....	10
2.1.1. LA STRUTTURA DEL CUSTOMER JOURNEY .....	11
2.2. L'ADOZIONE DI UNA STRATEGIA OMNI-CHANNEL INTEGRATA .....	13
2.3. CLASSIFICAZIONE DEI TOUCHPOINTS.....	16
2.4. TECNICHE DI MISURAZIONE DELL'EFFICACIA DEI TOUCHPOINTS.....	18
2.4.1. METODO DI ZHAO ET AL.....	18
2.4.2. METODO DI ZIMMERMANN ET AL.....	21
2.4.3. METODO DI CAMBRA-FIERRO ET AL. ....	25
2.4.4. METODO DI ZHANG ET AL.....	28
2.4.5. EFFICACIA DEI TOUCHPOINTS DIGITALI .....	29
3. ANALISI EMPIRICA .....	30
3.1. METODOLOGIA.....	30
3.1.1. STRUTTURA DEL QUESTIONARIO .....	31
3.1.2. TECNICHE DI ANALISI DEI DATI .....	34
3.2. ANALISI DESCRITTIVA: DATI QUALITATIVI .....	36
3.2.1. VARIABILE GENERE .....	36
3.2.2. VARIABILE ETÀ .....	36
3.2.3. VARIABILE RESIDENZA .....	39
3.2.4. VARIABILE ACQUISTO .....	40
3.2.5. I TOUCHPOINTS .....	41
3.3. ANALISI DESCRITTIVA: DATI QUANTITATIVI.....	47
3.3.1. VARIABILE SPESA .....	47
3.3.2. VARIABILE REDDITO.....	48
3.3.3. LE VARIABILI ESPOSIZIONE .....	49
3.3.4. LE VARIABILI INFLUENZA .....	54
3.4. ANALISI MULTIVARIATA .....	57
3.4.1. ANALISI BIVARIATA: VARIABILE EXP .....	58

3.4.2. APPLICAZIONE DI UN MODELLO STATISTICO: VARIABILE EXP .....	69
3.4.3. INTERPRETAZIONE DEI RISULTATI: VARIABILE EXP .....	81
3.4.4. ANALISI BIVARIATA: VARIABILE PUR .....	84
3.4.5. APPLICAZIONE DI UN MODELLO STATISTICO: VARIABILE PUR .....	91
3.4.6. INTERPRETAZIONE DEI RISULTATI: VARIABILE PUR.....	100
4. CONCLUSIONI E IMPLICAZIONI MANAGERIALI .....	103
4.1. SINTESI DEI RISULTATI PRINCIPALI.....	103
4.2. IMPLICAZIONI MANAGERIALI PER IL MARKETING .....	104
4.3. LIMITI DELLO STUDIO E SUGGERIMENTI PER FUTURE RICERCHE.....	105
5. REFERENZE.....	108

## 1. INTRODUZIONE

### 1.1. IL VENDITORE NELL'ERA DIGITALE: TRA MULTI E OMNI CHANNEL

Con l'avvento del digitale, il ruolo del venditore ha subito trasformazioni significative, che hanno portato le aziende a dover revisionare le proprie strategie di interazione con il consumatore. L'integrazione tra canali fisici e digitali ha rivoluzionato l'approccio alla vendita, dando vita a strategie di marketing in grado di soddisfare le aspettative di un consumatore sempre più informato. In questo contesto, i concetti di multi-channel e omni-channel hanno assunto importanza cruciale per le aziende che vogliono continuare ad essere competitive nel mercato odierno.

Le strategie multi-channel sono state una delle prime soluzioni adottate dalle imprese in risposta all'aumento del numero dei punti di interazione. Attraverso queste strategie, le aziende hanno consentito ai clienti di accedere a prodotti e servizi tramite canali differenti, tra cui negozi fisici, siti web, social media ecc.

La strategia multi-channel ha l'obiettivo di offrire al consumatore diverse possibilità di interazione con l'azienda, mantenendo, tuttavia, una certa indipendenza tra i differenti punti di contatto fruibili.

Nonostante i vantaggi offerti dalle strategie multi-channel, le aziende hanno rapidamente compreso che il semplice utilizzo di canali differenti non era sufficiente. L'efficacia di questo approccio, infatti, veniva limitata dalla mancanza di sinergia tra i punti di contatto.

Per superare i limiti della strategia multi-channel, le aziende si sono orientate verso un approccio omni-channel. Queste strategie si caratterizzano per l'integrazione e la sinergia tra tutti i punti di contatto.

L'approccio omni-channel, quindi, non si limita ad aggiungere touchpoints, ma punta a creare un'esperienza senza soluzione di continuità. In altre parole, al consumatore viene data la possibilità di passare senza difficoltà dal negozio fisico al sito web, così come dallo smartphone al punto vendita.

Tale scenario ha portato alla nascita di un vero e proprio "consumatore omnicanale". Questa tipologia di consumatori risulta essere particolarmente preziosa per le aziende: un'indagine di Harvard Business Review ha evidenziato che i clienti che utilizzano più canali tendono a spendere in media tra il 4% (nel caso in cui acquistino in negozi fisici)

e il 10% (nel caso in cui acquistino online) in più ogni volta che acquistano, rispetto a quelli che utilizzano un solo canale (Sopadjieva et al., 2017).

Questi consumatori si aspettano che i vari touchpoints dell'azienda "comunichino", condividendo tra loro i dati raccolti sul cliente stesso. Ad esempio, un cliente che inizia la ricerca di un prodotto da PC, sul sito web aziendale, si aspetta di poter proseguire l'esperienza sul proprio smartphone senza soluzione di continuità.

Di conseguenza, diventa fondamentale per le aziende sviluppare strategie omnicanale su misura, che consentano a ciascun cliente di entrare in contatto con il brand tramite il canale desiderato e, soprattutto, in modo personalizzato.

L'adozione di strategie omni-channel personalizzate ha comportato risultati concreti per le aziende. Uno studio condotto da McKinsey ha evidenziato un incremento medio delle vendite del 5-15% per le imprese che hanno integrato con successo canali di vendita personalizzati (McKinsey & Company, 2022).

Ciò dimostra che l'adozione di una strategia omni-channel integrata non solo migliora l'esperienza del cliente, ma comporta anche un impatto diretto sulle performance economiche.

L'avvento dell'era del digitale ha comportato sfide significative per i venditori. Tuttavia, le aziende che sono riuscite a evolvere da un approccio multi-channel basato su canali separati, a una strategia omnicanale integrata, hanno ottenuto miglioramenti tangibili. La capacità di offrire un'esperienza coerente e personalizzata su tutti i canali è diventata requisito indispensabile per le imprese, che si trovano ad operare in un mercato sempre più competitivo e digitalizzato.

## 1.2. STRATEGIE OMNI-CHANNEL NEL MERCATO DELL'ABBIGLIAMENTO

Quanto detto finora sulle strategie omni-channel è particolarmente rilevante nel settore dell'abbigliamento, dove l'integrazione tra e-commerce e negozi fisici si è dimostrata cruciale per far fronte a un mercato altamente competitivo.

Il settore del vestiario rappresenta uno dei pilastri fondamentali dell'economia italiana ed europea. In Italia, il fatturato dell'industria della moda ha superato i 100 miliardi di euro nel 2022 (CPP-Luxury, 2023); la crescita è stata principalmente alimentata dalle esportazioni, che rappresentano circa il 70% del fatturato, con un aumento del 19% rispetto all'anno precedente. Più in generale, l'Unione Europea risulta essere uno dei

maggiori mercati per la moda a livello globale, con Francia, Germania e Italia che giocano ruoli di spicco.

In questo contesto, le strategie omnicanale si sono rivelate di essenziale importanza al fine di competere in un mercato sempre più competitivo e customer-oriented.

Negli ultimi anni, il comportamento dei consumatori del settore dell'abbigliamento si è evoluto: sempre più spesso i clienti effettuano ricerche online prima di recarsi in un negozio fisico (webrooming) o provano capi in negozio per poi acquistare online (showrooming). Ad esempio, il 73% dei consumatori europei ha dichiarato di aver utilizzato la modalità "click-and-collect" per ritirare un ordine effettuato online presso un punto vendita fisico nel 2022 (Accenture, 2023). Questa tendenza dimostra l'importanza di creare esperienze coese e personalizzate su più canali.

Inoltre, l'adozione di un approccio omni-channel consente alle aziende di offrire esperienze più personalizzate, che risultano essere fattore chiave per la fidelizzazione del cliente.

L'importanza dell'omnicanalità è confermata anche dalla crescente domanda di soluzioni digitali all'interno dei negozi fisici, come i totem interattivi o i sistemi di pagamento mobile. I consumatori desiderano avere la fluidità d'uso che trovano online anche nei punti vendita tradizionali.

In aggiunta, lo sviluppo di nuove tecnologie, come l'intelligenza artificiale e la realtà aumentata, ha introdotto nuove possibilità per personalizzare l'esperienza d'acquisto. Le soluzioni di "virtual try-on", ad esempio, permettono ai clienti di visualizzare come un capo potrebbe apparire su di loro senza che sia necessario indossarlo (sia online, che in negozio). Questa tecnologia non solo migliora l'engagement del cliente, ma riduce anche i resi, che risultano essere un problema significativo per il settore della moda.

Come evidenziato, nel mercato dell'abbigliamento, l'omnicanalità non è solo un'opzione strategica, ma una necessità per rimanere competitivi in un panorama in continua evoluzione. Le aziende che riescono a sfruttare efficacemente le opportunità offerte dall'integrazione tra touchpoints possono costruire relazioni più forti con i clienti, migliorare l'efficienza operativa e, di conseguenza, aumentare la redditività.

### 1.3. OBIETTIVO DELL'ELABORATO

L'obiettivo principale di questo elaborato è quello di indagare la relazione tra i touchpoints e le scelte di consumo nel contesto del mercato del vestiario.

Attraverso un'analisi empirica basata su un questionario somministrato a un campione di consumatori, si intende comprendere come le diverse categorie di touchpoints (media classici, social media, pubblicità online, negozi fisici, ecc.) influenzino le scelte di acquisto.

Ispirandosi alla letteratura esistente sul tema in oggetto, lo studio si propone di esaminare il modo in cui l'esposizione ai vari touchpoints, l'influenza percepita dei punti di contatto, e le caratteristiche socio-demografiche dei consumatori influenzano due variabili chiave: la spesa sostenuta per capi di abbigliamento e la scelta di acquistare nei negozi fisici di vestiario.

La selezione del mercato dell'abbigliamento è stata motivata dalla sua accessibilità e frequenza di acquisto, rendendolo un settore ideale per l'analisi delle dinamiche di consumo.

Attraverso l'impiego di tecniche di analisi dei dati e modelli statistici, questa ricerca punta a fornire insights utili per le imprese, aiutandole a comprendere meglio quali touchpoints risultino più efficaci nel generare valore e promuovere decisioni di acquisto, contribuendo così all'evoluzione delle strategie di marketing omnichannel.

L'argomento trattato dal presente elaborato risulta di fondamentale importanza per il marketing contemporaneo in quanto riflette il cambiamento delle modalità con cui i consumatori interagiscono con i brand e prendono decisioni d'acquisto.

In un contesto sempre più digitalizzato e omnichannel, i touchpoints rappresentano punti di contatto essenziali per le imprese nel generare valore per i propri clienti e influenzare il loro percorso decisionale. L'efficacia di questi punti di interazione – siano essi touchpoints fisici o digitali – diventa cruciale per la costruzione di strategie di marketing mirate e personalizzate.

Il crescente impatto dei canali digitali e l'emergere di nuove forme di interazione dimostrano come i consumatori moderni siano costantemente esposti a una varietà di stimoli. Essi ricercano esperienze senza soluzione di continuità, dove ogni touchpoint si

integri in modo coerente con l'altro, semplificando il processo d'acquisto e apportando un valore aggiunto che arricchisca la loro esperienza complessiva con il brand.

Pertanto, la capacità di un'azienda di comprendere quali touchpoints siano più efficaci nel generare engagement e conversioni si traduce in un vantaggio competitivo significativo, consentendo una maggiore personalizzazione dell'offerta e una migliore gestione del customer journey.

Inoltre, lo studio dell'efficacia dei touchpoints è fondamentale per ottimizzare le risorse a disposizione dell'azienda. Con la frammentazione dei media e la diversificazione dei canali di comunicazione, le imprese devono allocare il proprio budget in maniera efficiente.

Ciò non significa che le aziende debbano abbandonare i touchpoints con minore influenza sulle conversioni. I punti di contatto hanno caratteristiche differenti, che potrebbero renderli più efficaci, ad esempio, in termini di immagine per il brand.

È importante, quindi, conservare una visione d'insieme dei punti di interazione, sfruttandoli in modo sinergico al fine di proporre esperienze di livello superiore per i consumatori.

Complessivamente, la ricerca presentata in questo elaborato offre spunti preziosi per migliorare la comprensione di queste dinamiche e fornire raccomandazioni concrete per le aziende che intendono ottimizzare le loro strategie di marketing omnichannel.

## 2. ANALISI DELLA LETTERATURA

In questo capitolo andremo ad analizzare quanto riportato dalla letteratura sullo studio dell'efficacia dei touchpoints all'interno della customer experience. Analizzeremo alcune tecniche di valutazione dell'efficacia dei punti di interazione, non prima -però- di aver discusso del concetto di customer journey, e dell'importanza per le aziende di adottare strategie omni-channel.

### 2.1. CUSTOMER JOURNEY E CUSTOMER EXPERIENCE

Negli ultimi decenni, il concetto di customer experience ha acquisito importanza cruciale all'interno delle strategie di marketing, diventando fattore chiave per il successo delle aziende. Al giorno d'oggi, il cliente ha la possibilità di interagire con un brand attraverso molteplici e diversificati punti di contatto; l'obiettivo per le aziende deve essere quello di gestire efficacemente tutti questi touchpoints, dando vita a una vera e propria esperienza a 360 gradi per il cliente (Lemon e Verhoef, 2016). Ciò si verifica quando le aziende sono in grado di generare customer engagement, ovvero quando ai consumatori viene data la possibilità di partecipare attivamente a interazioni co-creative con il brand, andando oltre il semplice acquisto (Brodie et al., 2011).

Tale evoluzione ha reso fondamentale per le imprese monitorare efficacemente l'esperienza del cliente lungo l'intero customer journey. Soltanto tenendo traccia di tutte le interazioni con il cliente, le aziende avranno la possibilità di offrire un'esperienza personalizzata, ormai necessaria per generare vantaggio competitivo (Fain, 2014) (Melero, Sese, Verhoef, 2016).

Uno dei fattori di criticità per il monitoraggio del customer journey è la crescente frammentazione dei punti di contatto tra azienda e consumatore; questo aspetto, sommato alla possibilità in capo al cliente di passare senza soluzione di continuità da un canale all'altro, rende il comportamento dei consumatori di difficile interpretazione. Fenomeni come lo showrooming (visionare un prodotto in uno store fisico, per poi comprarlo online) o il webrooming (visionare un prodotto online, per poi comprarlo in un negozio fisico) dimostrano quanto sia diventato difficile monitorare il percorso del cliente (Brynjolfsson, Hu e Rahman, 2013).

Prima di comprendere come un'azienda possa efficacemente gestire i touchpoints e monitorare il customer journey dei propri clienti, è necessario inquadrare il concetto di esperienza del cliente. La customer experience può essere immaginata come il percorso

che il cliente compie con un'azienda durante il proprio processo di acquisto; percorso attraverso il quale il consumatore viene a contatto con diversi touchpoints dell'impresa o esterni al controllo di quest'ultima (Lemon e Verhoef, 2016). È importante comprendere che si sta facendo riferimento al processo di acquisto, non al semplice atto di acquisto. Durante questo processo, infatti, il cliente passa attraverso diverse fasi, dal momento in cui viene a conoscenza del brand, al periodo che segue l'atto di acquisto. Attraverso queste fasi, il consumatore è esposto con differente frequenza a differenti touchpoints, che possono avere un diverso livello di influenza sul processo di acquisto del cliente stesso.

### 2.1.1. LA STRUTTURA DEL CUSTOMER JOURNEY

Sebbene diversi studi trattino il customer journey come un unico processo olistico, Lemon e Verhoef propongono una struttura di più semplice interpretazione, suddivisa in tre fasi principali: pre-acquisto, acquisto e post-acquisto (Lemon e Verhoef, 2016). Ogni fase comprende diversi touchpoints che influenzano sia la scelta di acquisto del cliente, che la sua esperienza complessiva.

1. Fase di pre-acquisto: la fase ha inizio con il riconoscimento del bisogno, prosegue con la ricerca di informazioni e termina con la decisione di acquisto. Lungo tutta la fase, i clienti possono interagire con il brand attraverso diversi canali digitali e fisici. La scelta di acquisto dipende spesso dalla capacità del brand di influenzare il processo decisionale attraverso un'efficace gestione dei touchpoints durante questa fase.
2. Fase di acquisto: questa fase comprende le interazioni tra brand e cliente durante l'atto di acquisto, come la scelta o il pagamento. I fattori chiave includono l'uso delle informazioni raccolte nella fase precedente e l'esperienza che il cliente vive durante il processo di acquisto. Un ambiente di vendita ottimale, sia online che offline, può aumentare la probabilità di completamento dell'acquisto.
3. Fase di post-acquisto: quest'ultima fase comprende l'uso del prodotto, l'assistenza post-vendita e il possibile riacquisto. L'importanza di questa fase per l'azienda risiede principalmente nella possibilità che il cliente si fidelizzi, accedendo al cosiddetto "loyalty loop". Per questo motivo, il coinvolgimento continuo del cliente, attraverso strategie di customer engagement, è fondamentale per mantenere relazioni positive.

La Figura 1 raffigura la struttura del customer journey proposta da Lemon e Verhoef, evidenziando la suddivisione nelle tre fasi. All'interno di ogni fase, vengono elencati i "Behaviors", ovvero le interazioni che cliente e azienda possono avere durante una specifica fase della customer experience (e.g. ricerca di informazioni, pagamento, engagement...).

Per ogni fase, vengono anche evidenziate diverse tipologie di punti di contatto (Touch Points). Questi ultimi sono classificati in touchpoints di proprietà del brand (generati dal brand e sotto il suo controllo), touchpoints di proprietà del partner (generati o controllati dal brand e da almeno un suo partner), touchpoints di proprietà del cliente (elementi che scaturiscono autonomamente dal cliente, senza essere sotto il controllo del brand o di un suo partner) e touchpoints sociali/esterni (fattori esterni al cliente, che non sono sotto il suo controllo o sotto quello del brand e dei suoi partner) (Lemon e Verhoef, 2016).

La struttura proposta da Lemon e Verhoef (2016) è sicuramente utile per comprendere come la customer experience sia articolata, tuttavia, resta fondamentale per le imprese adottare una gestione sinergica dei vari punti di contatto, al fine di creare un'esperienza cliente coesa e personalizzata (Melero, Sese, Verhoef, 2016).

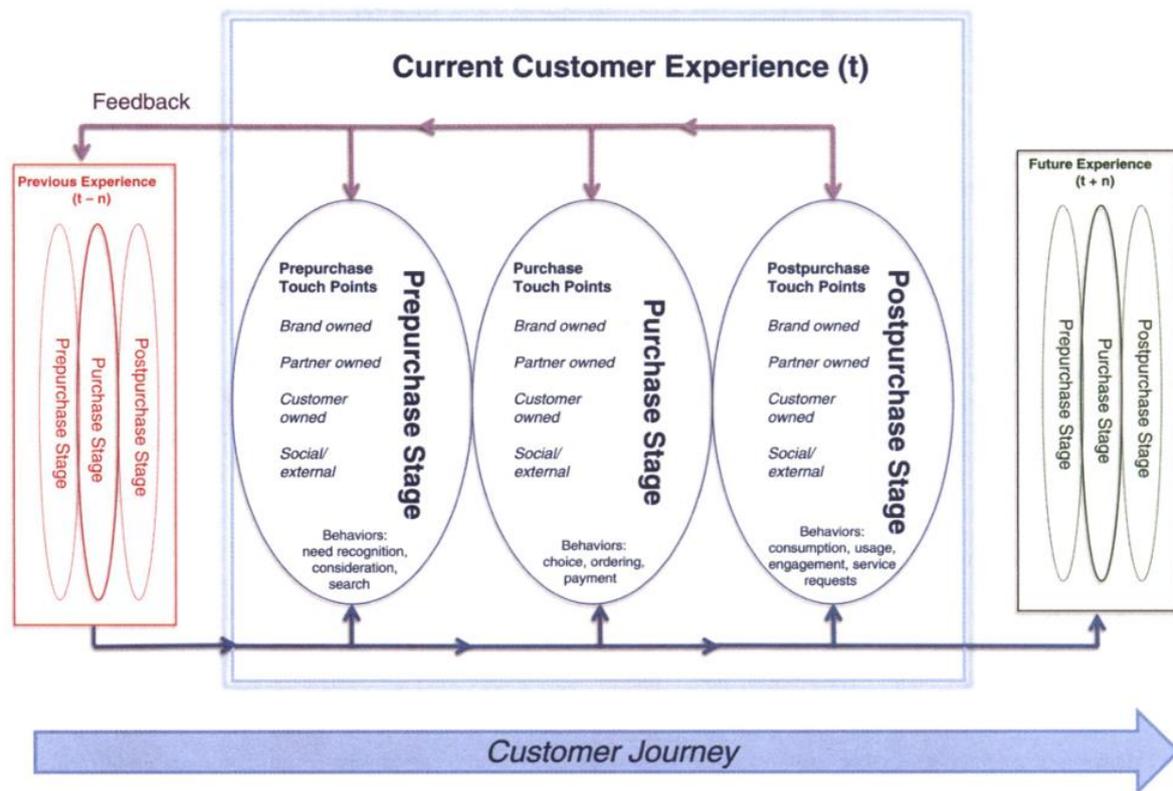


Figura 1. "Process Model for Customer Journey and Experience". Fonte: Lemon, K. N., & Verhoef, P. C. (2016). Pag 10.

## 2.2. L'ADOZIONE DI UNA STRATEGIA OMNI-CHANNEL INTEGRATA

Negli ultimi decenni, il crescente interesse del consumatore verso i nuovi canali di vendita online ha creato, nei clienti, l'aspettativa di poter trovare un prodotto disponibile in qualsiasi momento e luogo, rendendo necessaria per le aziende l'adozione di strategie multi-channel (Pluta-Olearnik e Jadach, 2019).

Tuttavia, secondo Pluta-Olearnik e Jadach (2019), i brand che adottano strategie multi canale non possono limitarsi a offrire i propri prodotti attraverso canali indipendenti. Essi devono pianificare la multi-channel strategy in modo da garantire che ogni canale contribuisca in modo sinergico al valore totale dell'offerta. Il cliente, inoltre, deve poter passare da un canale all'altro senza soluzione di continuità (Pluta-Olearnik e Jadach, 2019).

Un esempio di strategia multi-channel, senza confini tra i vari touchpoints, è quella proposta da Dell. La multinazionale statunitense offre la possibilità di visionare i propri PC presso un outlet fisico, controllare le specifiche online, contattare il call center e infine concludere l'acquisto sempre via Internet (Payne e Frow, 2004).

Quest'idea di coerenza e integrità tra i diversi touchpoints trova riscontro nelle strategie omni-channel. Le strategie omni canale nascono a seguito dell'evoluzione del concetto di customer experience; tale evoluzione ha portato le aziende a rivedere il proprio modo di interagire con i clienti, introducendo una gestione integrata di tutti i canali disponibili, con l'obiettivo di ottimizzare l'esperienza del cliente (Melero, Sese, Verhoef, 2016).

La tabella 1 (Verhoef, Kannan e Inman, 2015) mostra le principali differenze tra strategie multi canale tradizionali e strategie omni canale. Anche la ricerca di Verhoef et al. (2015) evidenzia come il mondo del retail stia evolvendo sempre più verso un approccio omni-channel integrato.

	<b>MULTI-CHANNEL MANAGEMENT</b>	<b>OMNI-CHANNEL MANAGEMENT</b>
<b>Channel Focus</b>	Interactive channels only	Interactive and mass-communication channels
<b>Channel scope</b>	Retail channels: store, online website, and direct marketing (catalog)	Retail channels: store, online website, and direct marketing, mobile channels, social media Customer Touchpoints
<b>Separation of channels</b>	Separate channels with no overlap	Integrated channels providing seamless retail experiences
<b>Brand versus channel customer relationship focus</b>	Customer – Retail channel focus	Customer – Retail channel – Brand focus
<b>Channel management</b>	Per channel	Cross-channel
<b>Objectives</b>	Channel objectives (i.e., sales per channel; experience per channel)	Cross-channel objectives (i.e., overall retail customer experience, total sales over channels)

Tabella 1. "Multi-channel versus omni-channel management". Fonte: adattamento da Verhoef, P. C., Kannan, P. K., & Inman, J. J. (2015). Pag. 3.

Lo studio di Melero et al. (2016), che andremo ad analizzare di seguito, si pone l'obiettivo di comprendere come le aziende possano efficacemente adottare una strategia omni

canale integrata; viene individuato un insieme di fattori chiave che deve essere considerato nell'adozione di una omni-channel strategy (evidenziato nella Tabella 2).

<b>KEY FACTORS FOR AN EFFECTIVE OMNI-CHANNEL STRATEGY</b>
<b>1. Customer-centric approach</b>
<b>2. Unify all touchpoints across all channels</b>
<b>3. Deliver personalized customer experiences</b>
<b>4. Cross-channel integration</b>
<b>5. Delight your customers across channels</b>
<b>6. The role of the physical store</b>
<b>7. Embrace mobile channels</b>

Tabella 2. "Key factors for an effective omni-channel strategy". Fonte: elaborazione propria su dati Melero, I., Sese, F. J., & Verhoef, P. C. (2016).

Uno dei fattori chiave individuati dallo studio è l'adozione di un approccio customer-centric, nel quale ogni punto di contatto viene ottimizzato per garantire al consumatore un'esperienza uniforme e positiva. Ogni interazione deve essere coerente e allineata con le aspettative e le preferenze del cliente. Il concetto di centralità del cliente implica, infatti, una trasformazione della cultura aziendale, che consenta all'azienda di allineare e integrare tutte le proprie funzioni, con l'obiettivo di creare maggiore customer value (Shah et al., 2006).

Un esempio di brand che ha adottato una visione customer-centric è Adidas; il Marchio tedesco genera una serie di interazioni incentrate sul cliente, volte a creare un rapporto di fiducia reciproca a lungo termine (offre la possibilità di personalizzare il design dei propri acquisti, organizza give-away per i propri followers sui social media ecc.) (Melero, Sese, Verhoef, 2016).

Altro fattore di fondamentale importanza nella creazione di una strategia omni-channel è la necessità di coordinare tutti i touchpoints attraverso l'analisi dei dati riferiti alle abitudini e ai comportamenti dei clienti. In questo modo, per l'azienda sarà possibile valutare l'effettiva efficacia di ogni singolo touchpoint e, di conseguenza, intervenire sui punti di interazione meno profittevoli. Sarà inoltre possibile offrire esperienze personalizzate, entrando in contatto con un determinato cliente attraverso il canale da lui preferito (Melero, Sese, Verhoef, 2016).

La ricerca di Melero et al. (2016) si sofferma inoltre sull'importanza del ruolo del negozio fisico. Nonostante l'aumento del numero dei canali di vendita, infatti, gli store fisici continuano ad avere un ruolo cruciale all'interno delle strategie omni-channel; essi presentano aspetti unici rispetto agli altri touchpoints, che giocano un ruolo fondamentale nelle scelte dei consumatori (Avery et al., 2012).

Nei negozi fisici, i clienti possono tastare o provare il prodotto, chiedere informazioni al personale di vendita ecc. Si tratta di aspetti che non possiamo trovare in altre tipologie di touchpoints, in grado di ridurre fortemente l'incertezza legata a un acquisto. Nel caso del personale di vendita, si tratta persino di un elemento in grado di generare engagement (Forrester, 2014). Non a caso, aziende tradizionalmente legate al mondo dell'online hanno nel tempo introdotto canali fisici (e.g. apertura della libreria Amazon a Seattle) (Melero, Sese, Verhoef, 2016).

Infine, lo studio evidenzia l'importanza di integrare i canali mobile all'interno delle strategie omni-channel. Secondo analisi recenti, una consistente porzione di consumatori controlla la disponibilità di un prodotto dal cellulare prima di recarsi allo store fisico, o addirittura cerca informazioni sul prodotto mentre si trova nel negozio. Questi comportamenti da parte del cliente dimostrano quanto sia importante integrare efficaci canali mobile, che -tuttavia- devono essere inseriti in modo coerente e sinergico con il resto dei touchpoints (Melero, Sese, Verhoef, 2016).

### 2.3. CLASSIFICAZIONE DEI TOUCHPOINTS

Prima di analizzare nel dettaglio alcune tecniche di misurazione dell'efficacia dei touchpoints, è necessario valutare quali punti di interazione vengono individuati dalla letteratura e come questi vengono classificati in diverse categorie.

Nei paragrafi precedenti abbiamo incontrato una prima tipologia di classificazione dei touchpoints; si tratta della distinzione proposta da Lemon e Verhoef (2016), nella quale i punti di contatto vengono divisi in quattro categorie principali:

- Touchpoints di proprietà del brand: progettati e gestiti dall'azienda (come la pubblicità, i siti web ecc.).
- Touchpoints di proprietà del partner: gestiti in collaborazione con partner esterni (come le agenzie di marketing).

- Touchpoints di proprietà del cliente: interazioni che il cliente compie autonomamente (come, ad esempio, la scelta del metodo di pagamento).
- Touchpoints sociali/esterni: interazioni che avvengono attraverso influenze esterne (come le recensioni dei clienti, ad esempio).

Questa classificazione propone ai brand un framework utile per individuare i touchpoints che essi sono in grado di gestire e sui quali possono fare leva. Come spiegato in precedenza, infatti, le aziende hanno influenza sui touchpoints Brand owned e Partner owned, mentre i touchpoints Customer owned e Social/external non risultano sotto il loro controllo (Lemon e Verhoef, 2016).

Tale distinzione è maggiormente dettagliata rispetto a quella proposta da Anderl et al. (2016), che categorizza i touchpoints in firm-initiated e customer-initiated, facendo soltanto una distinzione tra punti di contatto attivati dall'azienda e punti di contatto attivati dal cliente (Anderl, Schumann e Kunz, 2016).

Un'altra classificazione proposta frequentemente nella letteratura è quella che distingue tra punti di interazione paid, owned e earned. Questa distinzione è evidenziata nella Tabella 3, contenuta nello studio di Stephen e Galak (2012):

Type	Definition	Offline Examples	Online Examples
Paid	Media activity related to a company or brand that is generated by the company or its agents	<ul style="list-style-type: none"> <li>•Traditional advertising (e.g., television, radio, print, outdoor)</li> <li>•Sponsorships</li> <li>•Direct mail</li> </ul>	<ul style="list-style-type: none"> <li>•Display/banner advertising</li> <li>•Search advertising (e.g., Google AdWords)</li> <li>•Social network advertising (e.g., Facebook ads)</li> <li>•Electronic direct mail (e.g., e-mail advertisements)</li> </ul>
Owned	Media activity related to a company or brand that is generated by the company or its agents in channels it controls	<ul style="list-style-type: none"> <li>•Retail in-store visual merchandising or displays</li> <li>•Brochures</li> <li>•Company press releases</li> </ul>	<ul style="list-style-type: none"> <li>•Company/brand website</li> <li>•Company/brand blog</li> <li>•Company-owned pages/accounts in online social networks (e.g., Twitter account, Facebook brand page)</li> </ul>
Earned	Media activity related to a company or brand that is not directly generated by the company or its agents but rather by other entities such as customers or journalists	<ul style="list-style-type: none"> <li>•Traditional publicity mentions in professional media outlets</li> <li>•Ratings and reviews in TMOs (e.g., movie reviews)</li> <li>•Consumer-to-consumer WOM conversations about products, including advice and referrals</li> <li>•Consumers showing or demonstrating products to each other</li> </ul>	<ul style="list-style-type: none"> <li>•Traditional publicity mentions in digital media outlets (e.g., professional blogs)</li> <li>•Online WOM referrals (e.g., invitations to join a website)</li> <li>•Posts in online communities or social networks (e.g., status updates, tweets)</li> <li>•Online ratings and reviews (e.g., Yelp.com for restaurants, Amazon.com for products)</li> </ul>

Tabella 3. "Paid, owned, and earned media". Fonte: Stephen, A. T., & Galak, J. (2012). Pag. 3.

- Paid media (media pagati): parliamo dei touchpoints per cui l'azienda paga, con l'obiettivo di venire promossa; includono la pubblicità tradizionale in TV, la pubblicità online attraverso banner, le ads sui social network ecc. Questi punti di contatto hanno la peculiarità di generare immediata visibilità e impattare direttamente sulle vendite (Stephen e Galak, 2012).

- Owned media (media posseduti): si tratta di touchpoints che l'azienda controlla direttamente, come il sito web aziendale, i profili aziendali sui social media, i display negli store fisici ecc. Questi punti di interazione permettono alle aziende di costruire e curare direttamente la propria immagine, senza doversi servire di intermediari a pagamento. Inoltre, giocano un ruolo cruciale nella creazione delle relazioni a lungo termine (Stephen e Galak, 2012).
- Earned media (media guadagnati): sono il risultato dell'interazione tra i consumatori, o individui terzi (come i bloggers, ad esempio), e il brand. Questi touchpoints non vengono pagati né controllati direttamente dall'azienda. In questa categoria troviamo le menzioni sui media tradizionali, le recensioni online, i commenti su forum e social media ecc. Sono punti di interazione preziosi per il loro impatto sulla credibilità del marchio, poiché vengono percepiti come meno manipolabili dall'azienda (Stephen e Galak, 2012).

La distinzione tra paid, owned e earned media è spesso utilizzata in letteratura per studiare l'efficacia dei punti di interazione. Nel prossimo paragrafo, approfondiremo alcune tecniche di misurazione dell'efficacia dei touchpoints, iniziando dallo studio di Zhao et al. (2020), che si pone l'obiettivo di analizzare l'efficacia dei punti di contatto paid, owned e earned, e le possibili interdipendenze tra di loro (Zhao, Goh e Hou, 2020).

## 2.4. TECNICHE DI MISURAZIONE DELL'EFFICACIA DEI TOUCHPOINTS

Come evidenziato nel paragrafo precedente, non esiste una classificazione universale dei punti di interazione. Allo stesso modo, non esiste nemmeno un approccio universale per l'analisi della loro efficacia. La letteratura presenta tipologie di analisi molto diverse tra loro, che adottano approcci differenti, fin dalla logica con la quale i touchpoint vengono distinti. Inizieremo a esaminare le ricerche che fanno riferimento alla distinzione tra touchpoints paid, owned e earned.

### 2.4.1. METODO DI ZHAO ET AL.

Il primo studio che prendiamo in analisi appartiene a Zhao et al. (2020). La ricerca si pone l'obiettivo di valutare l'efficacia e le possibili interdipendenze tra touchpoints paid, owned e earned, all'interno di un contesto omnichannel.

I dati utilizzati provengono da un rivenditore internazionale che vende prodotti cosmetici e di moda in Cina attraverso canali online e mobile. Il dataset comprende informazioni

sull'esposizione ai touchpoints, sulla sequenza di click e sulla cronologia degli acquisti online dei consumatori (Zhao et al. 2020).

Lo studio adotta un modello di attribuzione che conferisce influenza sulla decisione di consumo a tutti i touchpoints con i quali il consumatore è entrato in contatto durante il suo percorso verso l'acquisto (Li e Kannan, 2014).

I modelli di attribuzione last-click e first-click vengono scartati, in virtù della teoria secondo la quale le decisioni di conversione sono il risultato di un insieme di interazioni touchpoint-cliente (Li e Kannan, 2014). Secondo questa logica, ogni punto di contatto contribuisce alla decisione di acquisto, a differenza di quanto sostenuto dalle logiche last-click (che attribuiscono tutto il merito della conversione all'ultimo touchpoint con cui il cliente viene in contatto) e first-click (che attribuiscono tutto il merito della conversione al primo touchpoint con cui il cliente entra in contatto).

La ricerca adotta un approccio quantitativo, basato sull'analisi simultanea di tre modelli utili a spiegare le seguenti tre variabili dipendenti: scelta di acquisto (dicotomica sì/no), quantità acquistata e spesa sostenuta dai clienti. Tutte e tre le variabili sono riferite a uno specifico prodotto  $\alpha$  venduto dall'azienda (Zhao et al. 2020).

Le variabili indipendenti prese in considerazione sono:

- Esposizione ai touchpoints paid del prodotto  $\alpha$ .
- Esposizione ai touchpoints owned del prodotto  $\alpha$ .
- Esposizione ai touchpoints earned del prodotto  $\alpha$ .
- Esposizione ai touchpoints paid di un prodotto rivale di  $\alpha$ .
- Esposizione ai touchpoints owned di un prodotto rivale di  $\alpha$ .
- Esposizione ai touchpoints earned di un prodotto rivale di  $\alpha$ .

Vengono inoltre prese in analisi ulteriori variabili indipendenti che però risultano essere meno rilevanti ai fini dei risultati, quali: un insieme di attributi riferiti al prodotto, un insieme di caratteristiche demografiche riferite al consumatore, una dummy riferita alla categoria del prodotto  $\alpha$  (Zhao et al. 2020).

VARIABLES	(1) SUR Choice Probit	(2) SUR ln(Expend) Regression	(3) SUR ln(Qty) Regression	(4) Heckman ln(Expend) Regression	(5) Heckman Qty Poisson
Own	0.416*** (0.0136)	0.638*** (0.0185)	0.0872*** (0.00252)	0.173*** (0.0437)	0.386*** (0.137)
Paid	0.273*** (0.0186)	0.375*** (0.0251)	0.0530*** (0.00342)	0.119*** (0.0296)	0.269*** (0.0920)
Earn	0.0495 (0.133)	0.0330 (0.142)	0.000450 (0.0193)	-0.0191 (0.0617)	-0.0153 (0.249)
Own*Paid	-0.169*** (0.0200)	-0.245*** (0.0274)	-0.0339*** (0.00373)	-0.0639*** (0.0189)	-0.136** (0.0594)
Own*Earn	0.200 (0.293)	0.171 (0.373)	0.0152 (0.0509)	0.0725 (0.105)	0.157 (0.413)
Paid*Earn	-0.107 (0.380)	-0.162 (0.462)	-0.0135 (0.0631)	-0.0595 (0.127)	-0.126 (0.517)
OwnRival	-0.109*** (0.0137)	-0.0997*** (0.0121)	-0.0123*** (0.00164)	-0.0384*** (0.0138)	-0.0895** (0.0452)
PaidRival	-0.177*** (0.0234)	-0.0946*** (0.0153)	-0.0112*** (0.00208)	-0.0538** (0.0232)	-0.119 (0.0767)
EarnRival	-0.294*** (0.0900)	-0.211*** (0.0703)	-0.0224** (0.00959)	-0.133** (0.0534)	-0.298 (0.199)
InverseMillsRatio				0.509*** (0.142)	1.150** (0.456)
Constant <sup>1</sup>	-0.252** (0.118)			-0.0738 (0.144)	-0.468 (0.475)
R <sup>2</sup>		0.046	0.062	0.0896	
log-likelihood	-20129.552				-8196.9097
Observations	54,038	7,381	7,381	7,381	7,381

Note: Robust standard errors in parentheses: \*\*\* p<0.01, \*\* p<0.05, \* p<0.1. Customer demographics, product attributes, category and time dummies are included but suppressed due to page limitations.  
1. Intercepts in column 2 and 3 are insignificant so their results are automatically omitted by STATA.

Tabella 4. "Preliminary estimation results". Fonte: Zhao, Y., Goh, K.-Y., e Hou, L. (2020). Pag. 8-9.

I valori delle stime, riportati nella Tabella 4, evidenziano un impatto significativo e positivo dell'esposizione a touchpoint paid e owned sulla scelta di acquisto, sulla quantità acquistata e sulla spesa sostenuta dai clienti. Più nello specifico, gli owned media sembrano essere maggiormente efficaci rispetto ai paid media; questo effetto potrebbe essere dovuto alla maggiore attendibilità percepita dei media posseduti, oppure alla possibilità per le aziende di creare relazioni a lungo termine con il cliente attraverso gli owned media. L'esposizione agli earned media, invece, non sembra avere impatto significativo sulle variabili dipendenti (Zhao et al. 2020).

Per quanto riguarda le interdipendenze tra touchpoints, viene evidenziato solamente un effetto di sostituzione tra paid e owned media (valore della stima dell'interazione significativo e negativo). Un aumento dell'esposizione ai touchpoint paid può diminuire l'efficacia dell'esposizione ai touchpoint owned, o viceversa. Questi risultati suggeriscono la necessità per le aziende di bilanciare efficacemente i loro investimenti tra le diverse tipologie di touchpoints (Zhao et al. 2020).

Infine, anche l'esposizione ai touchpoints dei prodotti rivali ha un effetto negativo su scelta di acquisto, quantità e spesa. Ciò significa che i clienti potrebbero acquistare il

prodotto competitor al posto del prodotto  $\alpha$ , spinti dalla maggiore conoscenza del rivale oppure semplicemente dalla ricerca di novità (Lopez et al., 2015).

Complessivamente, lo studio di Zhao et al. (2020) contribuisce alla letteratura sullo studio dell'efficacia dei touchpoints offrendo un approccio data-driven basato sui modelli di regressione. La ricerca si fonda sulla logica di classificazione in punti di contatto owned, paid e earned. Sarà interessante valutare la metodologia proposta da studi che utilizzano approcci e logiche differenti.

#### 2.4.2. METODO DI ZIMMERMANN ET AL.

Passiamo ora all'analisi dello studio di Zimmermann, Weitzl e Auinger (2022), che si pone l'obiettivo di identificare i touchpoints che influenzano maggiormente le decisioni di acquisto dei clienti. La ricerca utilizza un approccio differente rispetto a quelli analizzati nei paragrafi precedenti. Attraverso un approccio multi-metodo, infatti, gli autori propongono prima un modello per identificare e raggruppare i touchpoints sia dal punto di vista aziendale che da quello dei clienti, e in seguito una tecnica per valutare l'efficacia delle diverse tipologie di punti di interazione individuate.

In questo caso, quindi, gli autori non utilizzano una delle classificazioni suggerite dalla letteratura, bensì progettano una tecnica di individuazione dei touchpoints propria. Questo metodo si divide in due fasi:

1. Corporate Touchpoint Identification Workshop: si tratta di un workshop volto a identificare i punti di contatto direttamente controllati dall'azienda. I ricercatori hanno coinvolto i dipendenti, inclusi i manager, della filiale austriaca di un rivenditore internazionale di attrezzature e abbigliamento sportivo, con l'obiettivo di mappare i touchpoints rilevanti.

Alla fine del workshop, sono stati individuati 145 touchpoints, raggruppati in 12 categorie principali: "Eventi", "Media Classici", "Cooperazioni", "Pubblicità Online", "Fuori Di Casa", "Relazioni Pubbliche", "Pubblicità Stampata", "Social Media", "Servizi", "Customer Relationship Management", "Sito Web" e "Punto Vendita" (Zimmermann et al., 2022).

2. Survey sui clienti: successivamente, è stata condotta un'indagine online rivolta ai clienti dell'azienda oggetto dell'analisi. Il sondaggio ha raccolto 1.487 risposte, tuttavia, l'analisi si è concentrata sui 243 partecipanti che avevano effettuato un acquisto nei tre mesi precedenti, riducendo così il rischio di bias. Ai clienti è stato

chiesto di valutare, su una scala Likert a 5 punti, la frequenza con cui erano stati esposti ai vari touchpoints identificati nel workshop (Zimmermann et al., 2022).

Raccolte le risposte di dipendenti e clienti, queste sono state confrontate tramite confirmatory factor analysis. L'analisi ha evidenziato una divergenza tra la percezione dei touchpoints da parte dell'azienda e quella dei clienti. Mentre i dipendenti hanno classificato i punti di interazione in 12 categorie, l'analisi dei clienti ha mostrato che essi li raggruppano in sette cluster principali: “Punto Vendita” (POS), “Cooperazioni” (CP), “Servizi” (SV), “Sito Web” (WEB), “Media Classici” (CM), “Social Media” (SOM) e “Customer Relationship Management” (CRM). La Tabella 5 mostra i principali touchpoints individuati dai clienti e le categorie nelle quali sono stati raggruppati (Zimmermann et al., 2022).

<b>Factors</b>	<b>Standardized Loading</b>
<b>Point of Sale (POS) <math>\alpha = 0.924</math>, CR = 0.858, AVE = 0.668</b>	
Retail Assortment	0.899
Retail Sales personnel	0.861
Retail Payment options	0.804
Retail Receipts	0.802
Retail Store	0.846
<b>Cooperation (CP) <math>\alpha = 0.758</math>, CR = 0.781, AVE = 0.421</b>	
Club offers	0.756
Cooperations with retailer	0.734
Presentations from retailer	0.647
Google maps entries	0.556
Give away	0.516
<b>Service (SV) <math>\alpha = 0.847</math>, CR = 0.853, AVE = 0.539</b>	
Product testing	0.790
Bike measurement	0.780
Running analysis	0.670
Rental stations	0.652
Bike workshop	0.766
<b>Website (WEB) <math>\alpha = 0.901</math>, CR = 0.886, AVE = 0.666</b>	
Website assortment	0.899
Website payment options	0.923
Search function on website	0.833
Product descriptions on website	0.558
<b>Classic Media (CM) <math>\alpha = 0.753</math>, CR = 0.757, AVE = 0.388</b>	
TV Spots	0.494
Advertisements in Magazines	0.741
Advertisements in newspapers	0.582
Advertisements in catalogues	0.675
Advertisements on posters	0.593
<b>Social Media (SOM) <math>\alpha = 0.868</math>, CR = 0.875, AVE = 0.587</b>	
Facebook	0.883
Videos on social media	0.794
Offers on social media	0.835
Instagram	0.620
Social Media competitions	0.666
<b>Customer Relationship Management (CRM) <math>\alpha = 0.816</math>, CR = 0.827, AVE = 0.618</b>	
Loyalty card	0.846
E-mail newsletter	0.643
Post newsletter	0.852
Note: $\alpha$ : Cronbach's alpha, CR: Composite reliability, AVE: Average variance extracted.	
All loadings are significant at $p < 0.001$ .	

Tabella 5. "Measurement descriptives". Fonte: Zimmermann, R., Weitzl, W., e Auinger, A. (2022). Pag. 5.

Lo studio in questione utilizza una classificazione maggiormente articolata rispetto a quelle esplorate negli scorsi paragrafi, focalizzandosi, tuttavia, sui touchpoints sotto il controllo dell'azienda, a discapito degli earned-media.

Una volta classificati i touchpoints, i ricercatori hanno utilizzato la Regressione Multipla Bayesiana per determinare l'influenza di ciascun punto di contatto sul valore della spesa dei clienti. I modelli individuati (Tabella 6) hanno identificato touchpoints con impatto

positivo, probabilmente positivo, neutro, negativo o probabilmente negativo sulle vendite (Zimmermann et al., 2022).

No.	Model with touchpoints	P(M data)	BF M	BF 10	R <sup>2</sup>
0	Null model	6.277e-8	0.033	1.000	0.000
1	Cooperation with retailer + Cooperation with partner store + Search engine advertising + Digital signage outdoor + Parking spots + POS TV + Warranty services	6.741e-4	353.684	10,739	0.162
2	Cooperation with retailer + Cooperation with partner store + Search engine advertising + Digital signage outdoor + Parking spots + Warranty services	6.068e-4	318.349	9,667	0.151
3	Cooperation with retailer + Cooperation with partner store + Search engine advertising + Digital signage outdoor + POS Assortment + Warranty services	3.162e-4	165.821	5,036	0.146
4	Cooperation with retailer + Cooperation with partner store + Search engine advertising + Digital signage outdoor + Warranty services	3.014e-4	158.072	4,801	0.135

Note: Table displays the four best models and the Null model. P(M) is uniform at 1.907e-6

Tabella 6. “Model comparison”. Fonte: Zimmermann, R., Weitzl, W., e Auinger, A. (2022). Pag. 6.

La Tabella 7 mostra nel dettaglio l’effetto dell’esposizione a un determinato touchpoint sul valore della spesa (“Posterior Mean”). Ad esempio, notiamo che un aumento di 1 punto in scala Likert dell’esposizione ai servizi di garanzia (“Warranty services”) comporta un aumento in media di 47,40€ della spesa del cliente. Al contrario, un aumento di 1 punto in scala Likert dell’esposizione alla cartellonistica digitale posizionata all'esterno di un punto vendita (“Digital signage outdoor”) comporta una diminuzione in media di 36,95€ della spesa del cliente (Zimmermann et al., 2022).

Inoltre, la voce “BF inclusion” indica l’incremento della probabilità che un modello avrebbe di prevedere il valore della spesa, nel caso in cui contenesse un determinato touchpoint. Ad esempio, un modello contenente la variabile “Cooperation with partner store” ha l’1,15% di possibilità in più di prevedere la spesa del cliente (Zimmermann et al., 2022).

Touchpoints	BF inclusion	Posterior Mean	SD	95% Credible Interval		Influence on Sales Value	
				Lower	Upper		
Warranty services	403.940	47.401	13.238	22.116	73.796	Positive	
Parking spots	1.103	1.782	6.103	0.000	19.883	Probably positive	
POS Assortment	0.771	1.356	5.578	0.000	18.219		
POS Receipts	0.492	0.580	3.530	0.000	6.110		
Employees	0.494	0.532	3.233	0.000	0.869		
Company vehicles	0.601	-1.513	7.499	0.000	1.173		
Cooperation with partner store	1.150	4.556	14.955	-0.189	54.978	Probably negative	
Cooperation with fitness studios	0.593	2.108	10.888	-2.991	21.476		
Post newsletter	0.645	0.952	4.730	-4.216	4.020		No effect
Banner advertising	0.492	-0.762	4.450	-5.600	0.000		Probably negative
Google maps entry	0.573	-1.227	6.543	-6.401	0.000		
Cinema advertisement	0.588	-2.946	14.442	-8.070	0.628		
Tablet assisted sales	0.623	-1.702	7.868	-18.636	0.000		
POS TV	0.845	-2.092	7.894	-24.994	1.540		
Exclusive webstore brands	1.176	-3.537	9.551	-33.274	0.000	Probably negative	
Search engine advertising	1.582	-5.281	11.726	-35.983	0.000		
Cooperation with retailer	2.110	-13.546	21.759	-65.342	1.150		
Digital signage outdoor	24.194	-36.945	14.559	-67.511	-8.175	Negative	

Note: Touchpoints with a credibility interval of 0.00 (lower) - 0.00 (upper) are not displayed.

Tabella 7. “Posterior summary”. Fonte: Zimmermann, R., Weitzl, W., e Auinger, A. (2022). Pag. 6.

Per quanto riguarda le categorie di touchpoints, l'unica a fare registrare influenza significativamente negativa sul valore della spesa è "Cooperation". Questo risultato, tuttavia, non si deve tradurre per l'azienda in una totale astensione dalle forme di cooperazione. È opportuno ricordare che l'importanza di un touchpoint non si misura solamente in termini di conversione all'acquisto; bensì, possiamo pensare a quanto possa essere importante una cooperazione in termini di immagine per un brand.

Più in generale, in un contesto omnichannel, ogni touchpoint ha la propria importanza, specialmente nel caso in cui questo agisca in modo sinergico rispetto agli altri punti di contatto. Per questo motivo, è opportuno pensare a cosa possa essere fatto per migliorare la percezione che il cliente ha di tale touchpoint (Zimmermann et al., 2022).

La metodologia di classificazione dei touchpoints adottata dall'analisi di Zimmermann et al. (2022) pone i riflettori sul tema dell'importanza dell'adozione di una visione customer-centric per le aziende (Melero, Sese, Verhoef, 2016). Come dimostrato dalle differenze nell'individuazione dei touchpoints, azienda e clienti possono avere percezioni differenti. Nel contesto attuale, è importante per i brand saper entrare in sintonia con la visione del cliente, adottando un approccio sempre più customer-oriented.

#### 2.4.3. METODO DI CAMBRA-FIERRO ET AL.

Nel presente paragrafo, analizzeremo l'articolo di Cambra-Fierro et al. (2021), che esamina come i diversi touchpoints controllati dalle aziende influenzano le percezioni dei clienti nel breve e lungo periodo.

Lo studio utilizza un approccio differente rispetto a quelli precedentemente visionati, in quanto distingue tra effetti di breve e lungo termine. Inoltre, esso valuta l'efficacia dei touchpoints sotto tre aspetti chiave dell'esperienza del cliente, che non venivano menzionati dagli articoli analizzati in precedenza: la competenza aziendale, l'affidabilità del servizio e l'eccellenza del servizio (Cambra-Fierro et al., 2021).

In aggiunta, l'analisi utilizza un'ulteriore categorizzazione per i touchpoints; vengono, infatti, individuate sei tipologie di punti di interazione: forza vendita, prodotto, consulenza, comunicazione, aspetti tangibili e contatti standardizzati (Cambra-Fierro et al., 2021).

Il campione utilizzato nella ricerca è stato ottenuto da un'azienda assicurativa globale. I dati sono stati raccolti lungo un periodo di cinque anni, attraverso un questionario annuale che utilizzava una scala di valutazione da 0 a 10 per valutare l'esperienza con i touchpoint aziendali (Cambra-Fierro et al., 2021).

Gli autori hanno utilizzato la seemingly unrelated regression (SUR) per stimare le relazioni tra i touchpoints e le percezioni dei clienti. La regressione è stata applicata una prima volta per valutare gli effetti a breve termine, e una seconda volta per analizzare gli effetti a lungo termine (Cambra-Fierro et al., 2021).

#### Estimation results.

Independent variables	Dependent variables		
	Firm expertise	Service reliability	Service excellence
<b>Short-term effects</b>			
Intercept	0.1924**	0.2467**	0.2585**
Sales force	0.1468**	0.2391**	0.1488**
Product	0.2867*	0.2993**	0.1715*
Consulting	0.5521**	0.2138**	0.5420**
Communication	0.0447	0.2894**	0.1569**
Tangibles	0.3005**	0.5729**	0.7245**
Standardized contacts	0.0290	0.0755	0.0673
<b>Long-term effects</b>			
Intercept	0.1833**	0.2134**	0.1271**
Sales force	0.2561**	0.3468**	0.2756**
Product	0.1512*	0.1246*	0.1178*
Consulting	0.1986	0.0347	0.0111
Communication	0.1239	0.3024*	0.3194*
Tangibles	0.0999	0.0257	0.9924
Standardized contacts	-0.1644*	-0.1115	-0.0722

Note: \*\* $p < .01$ , \* $p < .05$ .

Tabella 8. "Estimation results". Fonte: Cambra-Fierro, J., Polo-Redondo, Y., e Trifu, A. (2020). Pag.6.

La Tabella 8 mostra nel dettaglio gli effetti che ogni categoria di touchpoints ha sulla valutazione dei clienti di "competenza aziendale", "affidabilità del servizio" ed "eccellenza del servizio", sia nel breve che nel lungo periodo.

L'analisi evidenzia risultati differenti per ogni tipologia di touchpoint individuata:

1. Forza vendita: la forza vendita ha avuto un impatto positivo, sia nel breve che nel lungo termine, su tutte le percezioni dei clienti. Ciò indica che l'influenza della forza vendita diventa più forte nel lungo periodo; con il tempo, infatti, la familiarità con i rappresentanti di vendita rafforza il legame con il cliente, migliorando la percezione che questo ha dell'azienda.
2. Prodotto: l'interazione con il prodotto ha mostrato effetti significativi e positivi nel breve e lungo periodo. Tuttavia, la rilevanza del prodotto è maggiore nel breve periodo, mentre nel lungo termine tende a diminuire.
3. Consulenza: l'interazione con i servizi di consulenza ha avuto effetti significativi solo nel breve periodo. Ciò suggerisce che questa tipologia di touchpoint ha un impatto immediato, ma tale effetto tende a diminuire nel tempo.
4. Comunicazione: gli effetti della comunicazione sono stati positivi sia nel breve che nel lungo periodo. Tuttavia, non sono stati rilevati effetti significativi sulla percezione della competenza aziendale.
5. Aspetti tangibili: i touchpoints tangibili hanno avuto l'effetto più significativo su tutte le percezioni dei clienti nel breve termine. A lungo termine, invece, questo effetto tende a scomparire, poiché i clienti sviluppano familiarità con il fornitore e non necessitano più di stimoli fisici.
6. Contatti standardizzati: i contatti standardizzati non hanno mostrato effetti positivi né a breve né a lungo termine. Anzi, i dati mostrano che un aumento dell'esposizione a questa tipologia di touchpoint può avere un impatto negativo sulla percezione della competenza aziendale, nel lungo periodo. Questo risultato dimostra, ancora una volta, l'importanza per le aziende di adottare strategie di marketing personalizzate in relazione al cliente (Cambra-Fierro et al., 2021).

La ricerca di Cambra-Fierro et al. (2021) contribuisce alla letteratura riguardante il tema dell'efficacia dei touchpoints in quanto indaga le differenze tra effetti di breve e lungo termine che i punti di contatto generano sui clienti.

I risultati dello studio forniscono indicazioni preziose per le aziende su come gestire efficacemente i punti di contatto, concentrandosi sui touchpoints che hanno un impatto duraturo sulle percezioni dei clienti e riducendo quelli che possono risultare dannosi nel lungo periodo (Cambra-Fierro et al., 2021). In un contesto omni-channel in cui il consumatore entra in contatto ripetutamente con una moltitudine di punti di interazione,

è opportuno conoscere le peculiarità di ogni touchpoint, e saperle sfruttare in modo efficiente.

#### 2.4.4. METODO DI ZHANG ET AL.

L'articolo di Zhang, Lin e Goh (2018) affronta un tema più specifico rispetto alle ricerche analizzate nei paragrafi precedenti: l'impatto delle sponsorizzazioni da parte degli influencer online sulle vendite di prodotti.

Lo studio consiste in una ricerca empirica basata sui i dati di vendita su Taobao e Tmall, due tra i principali siti di e-commerce in Cina. La ricerca fa riferimento a sei categorie di influencers: alimentazione, bellezza, make-up, celebrità, atleti e sport. Per ogni post finalizzato alla sponsorizzazione di un prodotto, sono stati raccolti i dati relativi alle vendite di quel prodotto. Per ogni prodotto sponsorizzato, veniva selezionato un prodotto simile, che non fosse oggetto di endorsement, per servire come gruppo di controllo (Zhang et al., 2018).

Per valutare l'efficacia delle sponsorizzazioni è stata utilizzata la tecnica Difference-Difference (DID), basata sul confronto delle vendite prima e dopo l'attività promozionale. Sono stati applicati alcuni modelli di regressione che hanno incluso diverse variabili, come il numero di follower degli influencer, la frequenza delle sponsorizzazioni, il prezzo del prodotto, le recensioni dei clienti ecc. (Zhang et al., 2018).

L'analisi ha mostrato che le sponsorizzazioni degli influencers hanno un impatto positivo e significativo sulle vendite dei prodotti. Anche il numero di followers degli influencers ha influenza positiva sulle vendite del prodotto promosso. Tuttavia, una frequenza elevata nella promozione di post sponsorizzati comporta una riduzione dell'efficacia dell'azione promozionale. Questo effetto potrebbe essere dovuto alla perdita di credibilità agli occhi dei followers degli influencers che creano post sponsorizzati troppo frequentemente (Zhang et al., 2018).

I risultati dello studio confermano, ancora una volta, quanto sia importante per le aziende allocare efficacemente i propri punti di contatto con il cliente. Nello specifico, la ricerca dimostra che un utilizzo eccessivo delle sponsorizzazioni può portare all'inefficienza della campagna promozionale; tuttavia, esse rimangono uno strumento importante per le strategie omni-channel moderne.

#### 2.4.5. EFFICACIA DEI TOUCHPOINTS DIGITALI

In questo paragrafo presenteremo due riflessioni sul tema dell'efficacia dei touchpoints digitali, la cui integrazione all'interno delle strategie omni-channel risulta essere di fondamentale importanza.

La ricerca di Hallikainen et al. (2019) evidenzia come l'efficacia delle varie tipologie di touchpoints digitali vari in base alla predisposizione alla tecnologia dei consumatori. Lo studio giunge a una segmentazione dei consumatori in quattro gruppi distinti:

- Gli “Anti-digital” (11%): consumatori che evitano tutti i touchpoint digitali.
- Gli “Anti-social media” (17%): favorevoli ai touchpoints funzionali (email, motori di ricerca, siti web) ma non ai social media.
- La “Maggioranza” dei consumatori (53%): questi consumatori hanno atteggiamento moderato verso tutti i touchpoints.
- I “Digital channel enthusiasts” (19%): entusiasti di tutti i touchpoints digitali (Hallikainen et al., 2019).

Lo studio di Juaneda-Ayensa et al. (2016) arricchisce questa logica identificando, oltre alla predisposizione alla tecnologia, altri due fattori che influenzano l'intenzione di acquisto attraverso nuove tecnologie in un contesto omnicanale. Complessivamente, i fattori individuati dalla ricerca sono:

- Innovatività personale (predittore più forte): i consumatori innovativi sono più propensi a provare nuove tecnologie e ad utilizzare diversi canali durante il processo di acquisto.
- Aspettativa di prestazione: i consumatori percepiscono benefici significativi dall'uso di tecnologie multiple che facilitano e velocizzano l'acquisto.
- Aspettativa di sforzo: la percezione che l'uso di più canali richieda un basso sforzo aumenta l'intenzione di acquisto (Juaneda-Ayensa et al., 2016).

I risultati dei due studi suggeriscono che i rivenditori omnicanale dovrebbero focalizzarsi sull'integrazione delle nuove tecnologie, facilitando il loro utilizzo per attrarre nuovi consumatori e trattenere quelli già convertiti.

### 3. ANALISI EMPIRICA

Il presente capitolo si propone di svolgere un'analisi empirica con l'obiettivo di indagare la relazione tra touchpoints e scelte di consumo. A tale proposito, si è deciso di utilizzare un metodo riscontrato frequentemente nell'analisi della letteratura sullo studio dell'efficacia dei touchpoints: l'analisi delle risposte a un questionario somministrato a un campione di consumatori.

Al fine della progettazione del questionario, è stato necessario individuare un mercato di riferimento. Era opportuno selezionare un mercato conosciuto dalla maggior parte del campione, i cui prodotti potessero essere acquistati frequentemente in qualsiasi periodo dell'anno. Di conseguenza, si è deciso di focalizzare lo studio sul mercato del vestiario.

Alla scelta della metodologia e delle variabili prese in analisi, hanno contribuito le indicazioni offerte dagli studi di Zimmermann et al. (2022) e Zhao et al. (2020). In particolare, la ricerca di Zimmermann et al. (2022), anche per la tipologia di mercato preso in analisi (lo studio di Zimmermann et al. si basa sui dati di un retailer di abbigliamento sportivo), è stata ritenuta la più appropriata per eventuali confronti metodologici.

Attraverso l'uso di tecniche di analisi dei dati e modelli statistici, questo studio intende indagare le relazioni tra:

- Esposizione ai touchpoints, influenza dei touchpoints percepita dai clienti, caratteristiche socio-demografiche dei clienti (variabili indipendenti) e spesa sostenuta dai clienti (variabile dipendente).
- Esposizione ai touchpoints, influenza dei touchpoints percepita dai clienti, caratteristiche socio-demografiche dei clienti (variabili indipendenti) e scelta di acquisto nei negozi fisici (variabile dipendente).

#### 3.1. METODOLOGIA

Questo paragrafo dettaglia il design dello studio e le tecniche di raccolta e analisi dei dati utilizzate, evidenziando le logiche che hanno guidato la scelta della metodologia di studio adoperata.

La partecipazione al questionario è stata volontaria e previo consenso scritto. I partecipanti sono stati informati che i loro dati sarebbero stati utilizzati esclusivamente a

fini didattici e di ricerca. Per partecipare al questionario, inoltre, i soggetti hanno dovuto dichiarare di essere maggiorenni.

Il questionario è stato generato tramite Google Forms. I dati raccolti sono stati scaricati e riordinati attraverso Excel. Per l'analisi dei dati ci si è serviti del programma R e della sua estensione R Commander.

La survey è stata fatta circolare tramite piattaforme social e forum dedicati alla compilazione di questionari. Il questionario è stato a disposizione degli intervistati dal 18/09/2024 al 01/10/2024.

### 3.1.1. STRUTTURA DEL QUESTIONARIO

Il questionario è stato progettato con l'obiettivo di raccogliere informazioni su diverse tipologie di variabili relativamente ai consumatori e alle loro interazioni con i touchpoints del mondo del vestiario.

La struttura della survey è suddivisa in diverse sezioni, ognuna delle quali mirava a raccogliere dati utili alla creazione di variabili dipendenti e indipendenti, che verranno analizzate nei prossimi paragrafi.

La prima sezione del questionario include una breve introduzione volta a spiegare agli intervistati lo scopo dell'indagine, garantendo al contempo l'anonimato delle risposte e fornendo le istruzioni necessarie per completare il questionario. In particolare, viene spiegato che per “vestiario” si intende l'insieme dei capi di abbigliamento esclusi pelletteria, orologi e gioielli. È opportuno specificare questo concetto per evitare che i dati raccolti vengano distorti dalla presenza di acquisti particolarmente onerosi.

Prendendo spunto dalle ricerche presentate nel capitolo dedicato all'analisi della letteratura (e.g. Zimmermann et al., 2022), si è deciso di trattare la spesa dei consumatori come variabile dipendente. In particolare, è stato chiesto ai rispondenti di indicare il valore in euro della spesa sostenuta per articoli di vestiario negli ultimi 3 mesi (Fig. 2). Trattandosi di una scelta ricorrente in letteratura (e.g. Ieva e Ziliani, 2018), ogni domanda del questionario presenta il termine di tempo di tre mesi. Questa scelta serve a ridurre eventuali bias di memoria, che potrebbero influire sulle risposte degli intervistati se si scegliesse un lasso di tempo maggiore. Attraverso le risposte raccolte, è stata costruita la variabile “Spesa”, che verrà utilizzata come variabile dipendente all'interno del modello presentato nei prossimi paragrafi.

Negli ultimi 3 mesi, quale credi sia stata indicativamente la tua **spesa** (in euro) in articoli di **vestiario**? (si intendono capi di abbigliamento, **esclusi** pelletteria, orologi, gioielli)

Testo risposta breve

---

Figura 2. “Domanda sulla spesa”. Fonte: elaborazione propria tramite Google Forms.

Per quanto riguarda le variabili indipendenti, si è deciso di indagare due percezioni dei consumatori relative alle loro interazioni con i touchpoints. La prima è la frequenza di esposizione a una determinata categoria di punti di contatto; si tratta di un indicatore frequentemente utilizzato in letteratura (e.g. Ieva e Ziliani, 2018). A tal fine, si è deciso di domandare ai consumatori la frequenza con la quale fossero entrati in contatto con una determinata categoria di touchpoints negli ultimi 3 mesi. Come suggerito da Zimmermann et al. (2022), la risposta a questa domanda doveva corrispondere a un punteggio in scala Likert da 1 (poco frequentemente) a 5 (molto frequentemente).

Lo stesso tipo di domanda è stato posto per la seconda percezione che i clienti hanno rispetto ai punti di interazione, ovvero l’influenza che questi hanno sulle loro scelte di acquisto. Si è quindi deciso di chiedere ai consumatori di indicare quanto si fossero sentiti influenzati da una determinata categoria di touchpoints nelle proprie scelte d’acquisto degli ultimi 3 mesi. Anche in questo caso, la risposta doveva corrispondere a un punteggio in scala Likert, come mostrato dalla Figura 3.

Pensa ai tuoi **acquisti in capi di vestiario** negli ultimi 3 mesi. In una scala da 1 (poco) a 5 (molto), **quanto** credi abbiano **influito** sulle tue scelte di acquisto **i punti vendita fisici**? (Non è necessario tu abbia acquistato all'interno dei punti vendita fisici) \*

	1	2	3	4	5	
Poco	<input type="radio"/>	Molto				

Figura 3. “Domanda sulla percezione dell’influenza dei POS”. Fonte: elaborazione propria tramite Google Forms.

Le due domande su esposizione e influenza sono state ripetute per tutte le categorie di touchpoints individuate. Per l’individuazione di queste ultime, si è deciso di fare riferimento allo studio di Zimmermann et al. (2022), che propone la classificazione più ampia tra quelle analizzate nel capitolo precedente. Sono state utilizzate le seguenti categorie in comune: “Punti Vendita”, “Cooperazioni”, “Siti Web”, “Media Classici”, “Social Media”, “CRM” e “Online Advertising”. Non è stata presa in considerazione la

categoria “Service” in quanto, nella ricerca di Zimmermann et al. (2022), era stata inserita per far riferimento a servizi specifici del settore delle attrezzature sportive.

Per ogni categoria di touchpoints, oltre alle domande su esposizione e influenza, è stato chiesto ai consumatori di indicare quale elemento caratteristico di tale categoria reputassero influenzare maggiormente le loro scelte di acquisto (Fig. 4). Questa domanda ha l’obiettivo di fornire una visione maggiormente dettagliata delle diverse classi di touchpoints; queste ultime, infatti, comprendono differenti tipologie di punti di contatto, che necessitano una valutazione individuale. Come suggerito dalla letteratura, l’ordine delle opzioni è stato randomizzato per ogni rispondente, in modo da eliminare possibili bias derivanti dal posizionamento delle risposte.

Nella Figura 4, ad esempio, sono state proposte diverse alternative di touchpoints con il quale uno “user” può venire in contatto sui social. In particolare, ci soffermiamo sulla scelta che ha portato alla distinzione tra micro-influencer e macro-influencer. Date le marcate differenze tra queste due tipologie di influencer, si è deciso di trattarle come touchpoints separati, utilizzando la distinzione basata sul numero di followers fornita da Chen et al. (2024); tale ricerca categorizza come micro-influencer gli user con numero di followers tra i mille e i centomila, mentre individua come macro-influencer gli utenti con oltre 1 milione di followers (Chen et al., 2024).

In riferimento al settore del **vestiario**, consideriamo soltanto i **social media**. Quale / Quali tra i seguenti elementi reputi **influenzare maggiormente** le tue scelte di acquisto? (Puoi non indicare elementi se non li ritieni rilevanti)

- Pagine dei Brand
- Pubblicità sponsorizzate dei Brand (c.d "sponsorizzate")
- Micro-influencer (1K-100K followers circa)
- Macro-influencer (100K-1Milione followers circa)
- Instagram
- Facebook
- Recensioni online

Figura 4. “Domanda sui touchpoints caratteristici dei social media”. Fonte: elaborazione propria tramite Google Forms.

Per quanto riguarda la seconda variabile dipendente selezionata, è stata ideata la domanda in Figura 5. L'obiettivo della domanda è quello di indagare quanto l'acquisto nei POS sia frequente in una società sempre più legata al digitale. Attraverso le risposte raccolte, è stata costruita la variabile dicotomica "Acquisto", che verrà utilizzata come variabile dipendente all'interno del modello logit presentato nei prossimi paragrafi.

Negli ultimi 3 mesi, hai effettuato almeno 1 acquisto in **punti vendita fisici di vestiario**? \*

Sì

No

*Figura 5. "Domanda sulla scelta di acquisto nei POS". Fonte: elaborazione propria tramite Google Forms.*

L'ultima sezione era dedicata alla raccolta dei dati socio-demografici dei rispondenti. Questi dovevano includere informazioni quali età, genere, area di provenienza e reddito.

Al fine di raccogliere informazioni sul reddito dei rispondenti, si è ritenuto opportuno inserire la domanda sul tenore di vita (indicato con punteggio in scala Likert 1 - 5). Questo perché un'eventuale domanda sul reddito avrebbe potuto raccogliere un tasso di risposta piuttosto basso, o addirittura indurre gli intervistati a non completare il questionario. Le risposte a questa domanda saranno trattate come approssimazione del reddito dei rispondenti.

### 3.1.2. TECNICHE DI ANALISI DEI DATI

L'analisi dei dati raccolti attraverso il questionario è stata condotta utilizzando una serie di tecniche volte a rispondere agli obiettivi di ricerca. Attraverso l'esplorazione delle relazioni tra variabili, si è cercato di arrivare alla stima di modelli in grado di spiegare efficacemente le variabili dipendenti scelte. Di seguito, sono descritte le principali tecniche adottate nel processo di analisi.

1. Nella fase preliminare, è stata necessaria una prima pulizia dei dati, orientata alla correzione del dataset. Sono stati eliminati i dati non coerenti con le domande somministrate. Ad esempio, alla domanda aperta che chiedeva di indicare l'importo della spesa per abbigliamento in euro, un individuo ha risposto "meno di 100". Questa risposta non ha un'interpretazione precisa, in quanto il rispondente potrebbe aver speso qualsiasi cifra inferiore a 100€; inoltre, non sarebbe stato rigoroso dare un'interpretazione soggettiva della risposta.

2. Questa fase dell'analisi ha previsto l'utilizzo della statistica descrittiva per fornire una panoramica generale del campione e delle variabili in esame. Questa tecnica ha permesso di dare una prima interpretazione dei risultati derivanti dalle risposte al questionario. Inoltre, è stato possibile sintetizzare le informazioni attraverso l'uso di misure come medie, distribuzioni di frequenze ecc.
3. In seguito, sono state adottate tecniche di analisi bivariata. Attraverso l'osservazione di grafici, è stato possibile avere una prima visione delle possibili correlazioni tra variabili.
4. Per comprendere meglio le relazioni tra le variabili, sono stati applicati due modelli. Il primo è un modello di regressione multipla utile a spiegare la spesa in vestiario dei rispondenti. Il secondo è un modello logit utile a spiegare la scelta di acquisto nei negozi fisici degli intervistati. Attraverso la tecnica Stepwise backward basata sul criterio AIC, per entrambi i modelli è stato individuato il sottoinsieme ottimale di variabili predittive, eliminando quelle che hanno scarso impatto. Dopodiché, stimati i modelli includendo le sole variabili individuate tramite Stepwise, si è andati a valutare il possibile inserimento di trasformazioni e interazioni che potessero migliorarli. Così facendo, sono stati individuati i modelli ottimali.
5. Nell'ultima fase, sono stati applicati test diagnostici per valutare la presenza di HLP cattivi, ed eventualmente rimuoverli. Dopodiché, si è deciso di valutare la bontà della previsione del modello, utilizzando la funzione predict. I risultati sono stati interpretati attraverso vari strumenti, come la matrice di confusione, l'accuracy, il misclassification error, il MAE e l'RMSE. Al fine di paragonare diversi modelli in termini di qualità, si è calcolato l'AIC. Infine, attraverso il calcolo del VIF, si è indagata la possibile presenza di multicollinearità, che potrebbe compromettere la stabilità delle stime dei coefficienti di regressione.

L'adozione di queste tecniche di analisi dei dati ha permesso di esplorare in modo approfondito i comportamenti dei consumatori in relazione alle diverse categorie di touchpoints, fornendo indicazioni utili a fini manageriali.

Nel prossimo paragrafo andremo a dettagliare l'analisi svolta.

### 3.2. ANALISI DESCRITTIVA: DATI QUALITATIVI

La presente analisi si fonda su un campione di numerosità pari a 107 individui. Nei prossimi paragrafi andremo a commentare i dati qualitativi riferiti al campione, che si è ritenuto opportuno studiare.

#### 3.2.1. VARIABILE GENERE

Il campione è equilibrato in termini di genere, con una leggera prevalenza femminile. Nello specifico, è composto da 57 donne (che rappresentano il 53,3% del campione) e 49 uomini (che rappresentano il 45,8% del campione). Un individuo ha optato per non specificare il proprio genere, rispondendo con l'opzione "Preferisco non dirlo". Questa diversità di genere aiuta a garantire che le analisi siano rappresentative di diverse prospettive di consumo. La distribuzione è rappresentata dal grafico a torta raffigurato nella Figura 6.

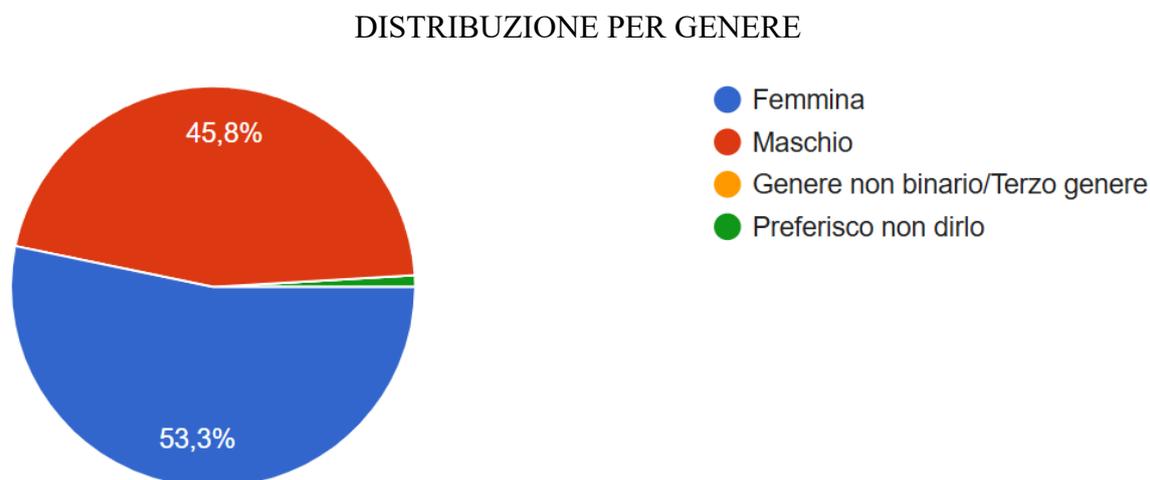


Figura 6. "Distribuzione per genere". Fonte: elaborazione automatica di Google Forms.

Dai dati riferiti al genere dei rispondenti, ricaviamo la variabile qualitativa "Genere". Al fine di indagare le possibili interrelazioni tra tale variabile e le altre analizzate, è opportuno costruire la dummy "Fem". Questa variabile assume valore 1 quando l'individuo dichiara di appartenere alla classe femminile, 0 altrimenti.

#### 3.2.2. VARIABILE ETÀ

Al questionario hanno potuto rispondere solamente individui maggiorenni, In particolare, il range di età dei rispondenti va dai 20 ai 65 anni. Per quanto concerne l'età dei partecipanti, il campione è sbilanciato, con una forte prevalenza di individui tra i 20 e i 26 anni di età. La fascia di età 50-60 anni è discretamente rappresentata, mentre la fascia

30-50 anni è scarsamente rappresentata. Non sono presenti rispondenti over 65. La Figura 7 fornisce indicazione dettagliata dell'età dei rispondenti.

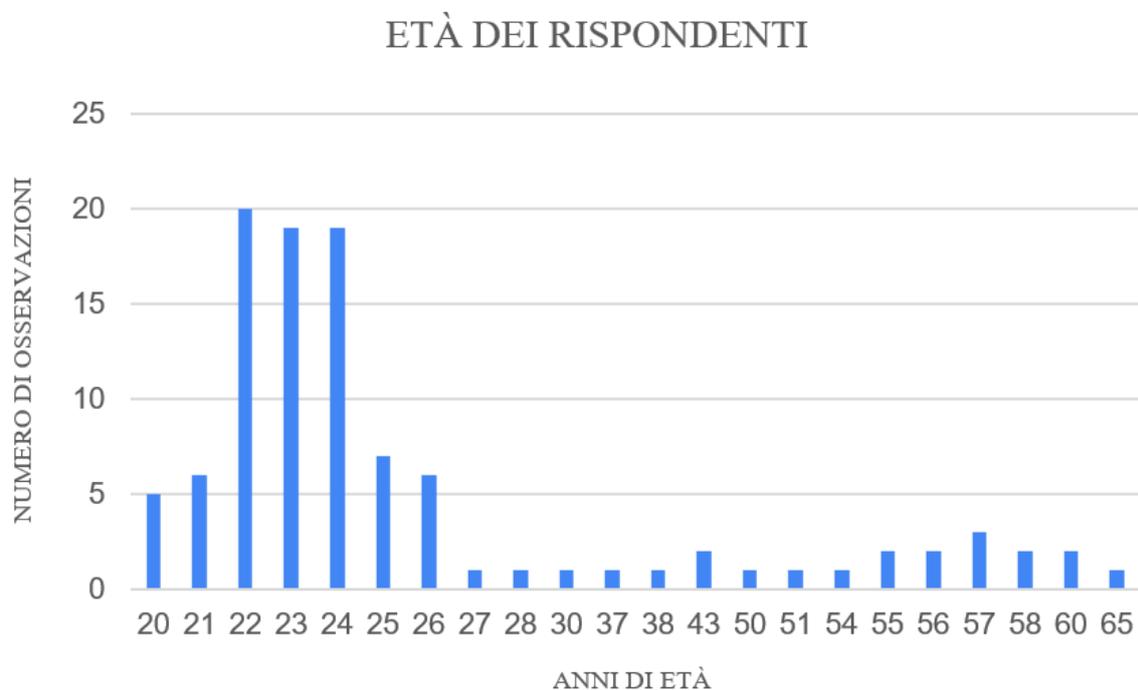


Figura 7. "Età dei rispondenti". Fonte: elaborazione propria.

La prevalenza di individui di giovane età implica una differenza sostanziale tra il campione oggetto di analisi e l'intera popolazione. La bassa rappresentatività degli individui "Over 30" potrebbe incidere sui risultati dello studio; questo perché generazioni diverse possono avere abitudini di acquisto differenti, oppure possono essere esposte a touchpoints differenti. La Figura 8 mostra la distribuzione per età del campione, mettendo in evidenza anche le fasce d'età non rappresentate. Un campione equilibrato restituirebbe un grafico senza picchi evidenti in positivo o in negativo. Di conseguenza, i risultati dello studio saranno influenzati dalla maggiore presenza di individui con età compresa tra i 20 e i 26 anni.

## DISTRIBUZIONE PER ETÀ

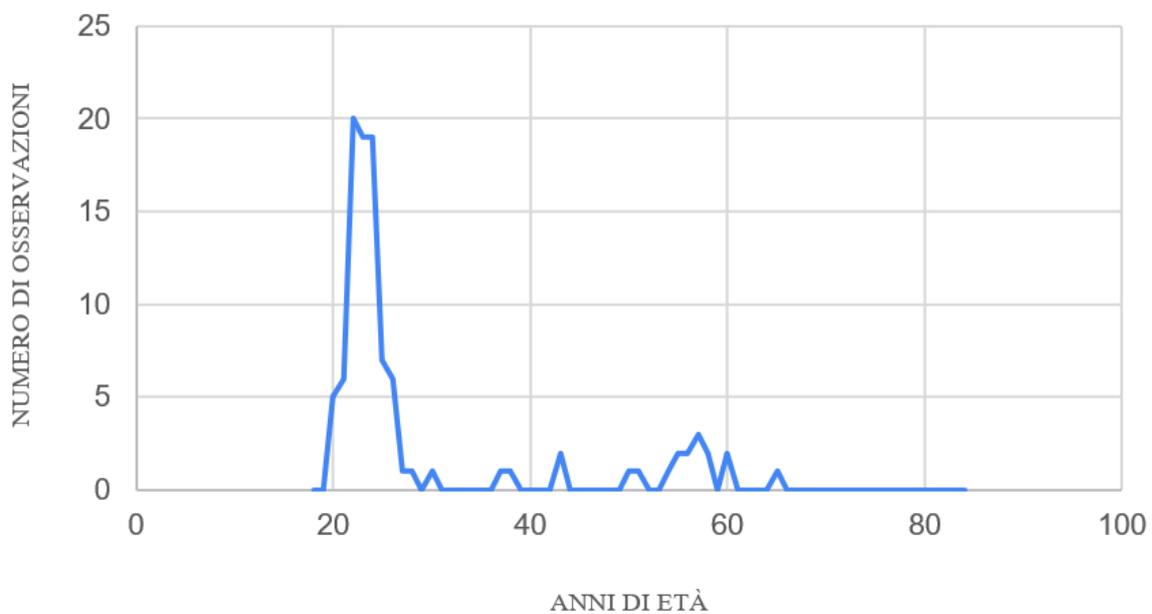


Figura 8. “Distribuzione per età”. Fonte: elaborazione propria.

Al fine di indagare le possibili relazioni tra l’età dei rispondenti e le loro decisioni di acquisto, si è deciso di creare la variabile qualitativa dicotomica “Età”. Tale variabile presenta due classi, che distinguono la Generazione Z dal resto dei partecipanti. Gli studi della Stanford University (2022) includono nel concetto di Gen Z tutti gli individui nati tra la metà degli anni ‘90 e gli anni intorno al 2010. Si tratta di quella parte di popolazione che ha da sempre avuto a disposizione strumenti digitali. La loro abitudine verso il mondo del digitale potrebbe influenzare le loro abitudini di acquisto; di conseguenza, risulta interessante valutare se la sopracitata divisione per classi di età possa aiutare a spiegare le relazioni tra touchpoints e scelte di acquisto.

Dovendo includere nella classe “Gen Z” tutti gli individui nati dalla metà degli anni ‘90 in poi (avendo soltanto rispondenti maggiorenni, il limite superiore non si pone), escludiamo da questa classe tutti gli individui oltre i 30 anni, inserendoli nella classe “Over 30”. La Figura 9 mostra nel dettaglio la distribuzione di frequenza per le due classi.

## DISTRIBUZIONE PER CLASSI DI ETÀ

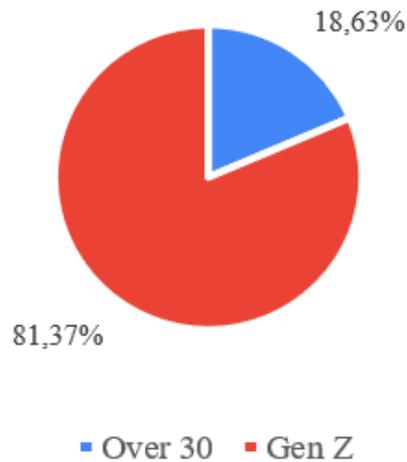


Figura 9. “Distribuzione per classi di età”. Fonte: elaborazione propria.

La divisione in classi applicata potrebbe, inoltre, consentire di cogliere l’effetto del reddito sulle abitudini di spesa. Questo perché gli individui over 30 hanno reddito mediamente superiore rispetto agli under 30, essendo in piena attività lavorativa, e di conseguenza potrebbero avere abitudini di acquisto differenti.

Al fine di indagare le possibili interrelazioni tra tale variabile Età e le altre analizzate, è opportuno costruire la dummy “Over”. Questa variabile assume valore 1 quando l’individuo appartiene alla classe Over 30, mentre assume valore 0 quando l’individuo appartiene alla classe Gen Z.

### 3.2.3. VARIABILE RESIDENZA

Ai partecipanti è stato chiesto di indicare la tipologia di comune in cui vivono, in modo da valutare se le caratteristiche dell’area di provenienza possano influire sulle risposte. Questa informazione è particolarmente rilevante, in quanto le abitudini di acquisto e l’esposizione a un certo tipo di touchpoints possono differire notevolmente tra aree urbane, suburbane e rurali.

Gli intervistati provengono da diverse tipologie di comuni, come illustrato dalla Figura 10. La distribuzione differisce rispetto a quella suggerita dai dati Eurostat (2022) sulla popolazione europea, che indicano le aree urbane come quelle di maggiore provenienza (41%), seguite dalle aree suburbane (32%) e dalle aree rurali (27%). Il campione analizzato, invece, proviene prevalentemente da aree suburbane (66,4%); seguono, in ordine, la porzione di campione proveniente da aree urbane (25,2%) e quella proveniente

da aree rurali (8,4%). La prevalenza di individui provenienti da aree suburbane implica una differenza sostanziale tra il campione oggetto di analisi e l'intera popolazione.

#### DISTRIBUZIONE PER AREA DI PROVENIENZA



Figura 10. "Distribuzione per area di provenienza". Fonte: elaborazione automatica di Google Forms.

Dai dati riferiti all'area di provenienza dei rispondenti, ricaviamo la variabile qualitativa "Residenza". Al fine di indagare le possibili interrelazioni tra tale variabile e le altre analizzate, è opportuno costruire due dummy "Cit" e "Sub". La dummy "Cit" assume valore 1 quando l'individuo appartiene alla porzione di campione che vive in città, 0 altrimenti. La dummy "Sub" assume valore 1 quando l'individuo appartiene alla porzione di campione che vive in aree suburbane, 0 altrimenti.

Nello stimare un modello, quindi, la porzione di campione che vive in aree rurali sarebbe rappresentata dal caso base, ovvero il caso in cui entrambe le dummy "Cit" e "Sub" assumono valore pari a 0.

#### 3.2.4. VARIABILE ACQUISTO

Ai partecipanti è stato chiesto di indicare se negli ultimi 3 mesi abbiano effettuato almeno 1 acquisto in negozi fisici. Questa domanda può fornire informazioni di vario genere sulle abitudini dei consumatori.

In primo luogo, è utile indagare quanto l'acquisto nei POS sia frequente in una società sempre più legata al digitale (data anche l'elevata numerosità di individui appartenenti alla Gen Z all'interno del campione in analisi). L'acquisto nei negozi fisici, infatti, non è più così scontato, anche a causa dello sviluppo di fenomeni come lo showrooming (Brynjolfsson, Hu e Rahman, 2013).

In aggiunta, è interessante valutare se le altre variabili studiate possano influenzare la decisione di acquistare nei negozi fisici. Per esempio, si potrebbe valutare se il fatto di

appartenere alla classe Gen Z possa aumentare la probabilità di non aver effettuato acquisti presso POS negli ultimi 3 mesi.

Infine, è possibile indagare se ci siano differenze in termini di spesa complessiva tra la porzione di campione che acquista frequentemente nei POS, e quella che predilige gli acquisti online. Al giorno d'oggi, infatti, acquistare online comporta la possibilità di confrontare siti di diversi venditori in tempi ridotti, andando a selezionare l'offerta economicamente più vantaggiosa. Questo potrebbe riflettersi sulla variabile spesa, che potrebbe essere soggetta a differenza per le due diverse porzioni di campione.

#### DISTRIBUZIONE VARIABILE ACQUISTO

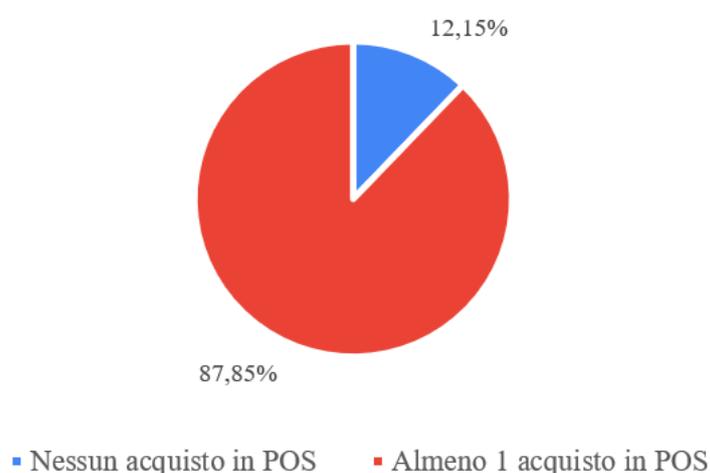


Figura 11. "Distribuzione variabile Acquisto". Fonte: elaborazione propria.

Dalla sopracitata domanda, ricaviamo la variabile qualitativa dicotomica "Acquisto". La variabile presenta due classi. Una classe comprende gli individui che hanno effettuato almeno 1 acquisto in POS di vestiario negli ultimi 3 mesi; l'altra classe comprende gli individui che non ne hanno effettuati. La Figura 11 mostra nel dettaglio la distribuzione di frequenza per le due classi.

Costruiamo la dummy "Pur", che assume valore 1 nel caso in cui l'individuo abbia effettuato almeno 1 acquisto in POS di vestiario negli ultimi 3 mesi, 0 altrimenti.

#### 3.2.5. I TOUCHPOINTS

Come illustrato nel capitolo precedente, al fine di studiare le varie tipologie di touchpoints utilizzati dai brand nel settore del vestiario, si è deciso di crearne sette categorie, prendendo spunto dalla classificazione offerta da Zimmermann et al. (2022).

Per ogni categoria, è stato domandato quali siano gli elementi caratteristici di tale categoria che influenzano maggiormente le scelte di acquisto. Ogni rispondente ha avuto la possibilità di indicare una, nessuna o più di una opzione tra quelle proposte. Di seguito andremo ad analizzare le risposte a questa domanda per ogni tipologia di touchpoint.

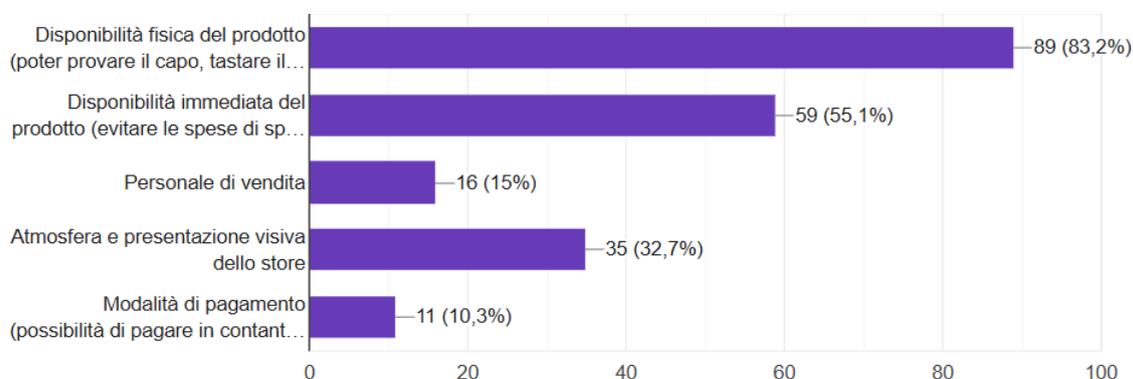


Figura 12. "Elementi dei negozi fisici che più influenzano le scelte di acquisto". Fonte: elaborazione automatica di Google Forms.

Per quanto riguarda gli store fisici (Figura 12), l'elemento che più influenza le scelte di consumo del campione è rappresentato dalla disponibilità fisica del prodotto; questa opzione, infatti, selezionata da una porzione di intervistati pari all'83,2%. Tale dato conferma quanto, in un mondo sempre più digitalizzato, rimanga importante per il consumatore poter visionare i prodotti di persona, tanto più per i capi di abbigliamento, che è opportuno provare indosso prima di acquistare.

Più della metà del campione (55,1%) reputa importante la disponibilità immediata del prodotto; questo elemento diventa fondamentale nei casi in cui non sia possibile sostenere le tempistiche legate alla spedizione.

Seguono, in ordine di frequenza di scelta, l'atmosfera e la presentazione visiva dello store (32,7%), il personale di vendita che, a differenza di quanto sostenuto da Forrester (2014), è reputato importante soltanto da una ridotta porzione di campione (15%), e infine le modalità di pagamento (10,3%), a dimostrazione della diffusione delle modalità di pagamento digitalizzato.

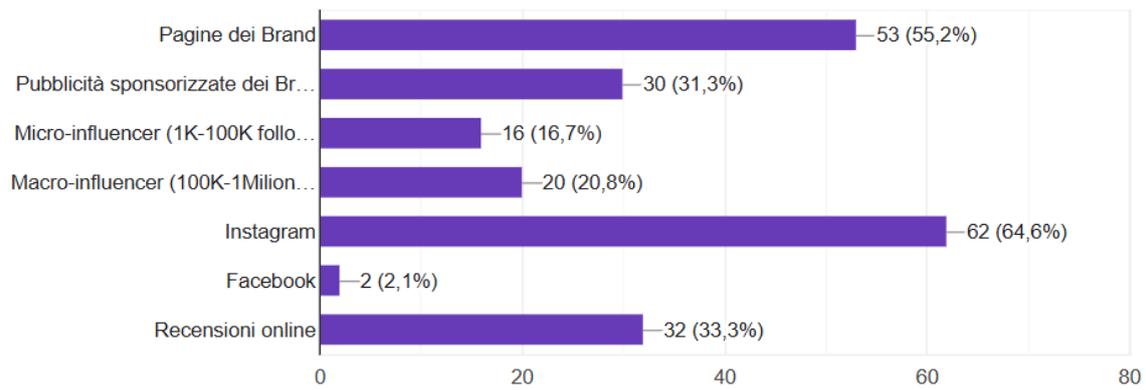


Figura 13. “Elementi dei social media che più influenzano le scelte di acquisto”. Fonte: elaborazione automatica di Google Forms.

Per quanto riguarda i social media (Figura 13), l’elemento maggiormente selezionato (64,6%) è Instagram. Osserviamo invece il dato relativo al social proposto come alternativa a Instagram, ovvero Facebook; l’opzione corrispondente ha raccolto soltanto il 2,1% delle scelte.

Questo dimostra quanto Instagram sia efficace per campagne marketing nel settore del vestiario sul campione oggetto di analisi. Tuttavia, andando ad analizzare le frequenze della scelta “Instagram” (tutte le risposte in cui compare la scelta Instagram, anche se associata a ulteriori scelte) condizionate alla condizione Over/Under 30, notiamo quanto questo risultato sia influenzato dall’età dei rispondenti. Gli Under 30 ad aver selezionato l’opzione Instagram corrispondono al 72,2% del totale degli Under 30. Questo dato crolla se calcolato in relazione agli Over 30: solo il 21,1% degli individui Over 30 ha scelto l’opzione Instagram.

Belanche et al. (2019) forniscono un altro tipo di lettura riguardo al tema dell’efficacia delle due piattaforme Instagram e Facebook: i ricercatori sostengono che l’efficacia di una ad dipenda maggiormente dal format con la quale viene presentata. Formati più dinamici, come le storie Instagram, influenzano maggiormente le scelte dei consumatori rispetto a format statici, come Instagram e Facebook Wall. Questo effetto è legato al diverso atteggiamento con il quale gli users si avvicinano ai due format: un individuo che si avvicina a vedere una storia Instagram è, generalmente, più favorevole a ricevere un contenuto promozionale rispetto a un individuo che scorre il “feed”. (Belanche et al., 2019).

In merito alle tipologie di contenuti con cui è possibile venire a contatto sui social, le più influenti risultano essere le pagine dei brand (55,2%), seguite dalle recensioni online

(33,3%), dalle sponsorizzate dei brand (31,3%), dai contenuti macro-influencer (20,8%), e infine dai contenuti dei micro-influencer (16,7%). Questi dati dimostrano come i brand-owned touchpoints (Lemon e Verhoef, 2016) siano più efficaci rispetto ai punti di interazione paid o earned (Stephen e Galak, 2012).

Per quanto riguarda macro e micro influencer, notiamo come entrambi influenzino una discreta porzione di campione. Questi risultati sono in linea con la ricerca di Rios Marques et al. (2020), la quale sostiene l'efficacia di entrambi i profili. Tale studio, tuttavia, sostiene che i macro-influencer attraggano un maggior numero di followers, mentre i micro-influencer siano più efficaci nel generare interazioni come visite al profilo, likes e commenti (Rios Marques et al., 2020).

Il dato sulla pubblicità sponsorizzata si trova parzialmente in disaccordo con la ricerca di Jarrar et al. (2020); questa sostiene che l'influencer marketing abbia maggiore efficacia sulle vendite rispetto ai contenuti sponsorizzati sui social, in virtù della maggiore credibilità legata agli influencers, che tende a migliorare anche la percezione del brand promosso. Tuttavia, lo studio sostiene che la pubblicità sponsorizzata generi un maggiore engagement, grazie al target più specifico e ampio che la contraddistingue (gli influencers condividono contenuti solo con i propri followers). Questo effetto è confermato anche dalla maggiore frequenza con la quale i post sponsorizzati vengono salvati rispetto ai contenuti degli influencers.

Dalle risposte ottenute, deduciamo che, nell'ambito del campione, la strategia più efficace, per un'azienda che vuole convertire leads, sia quella di generare contenuti tramite la propria pagina Instagram.

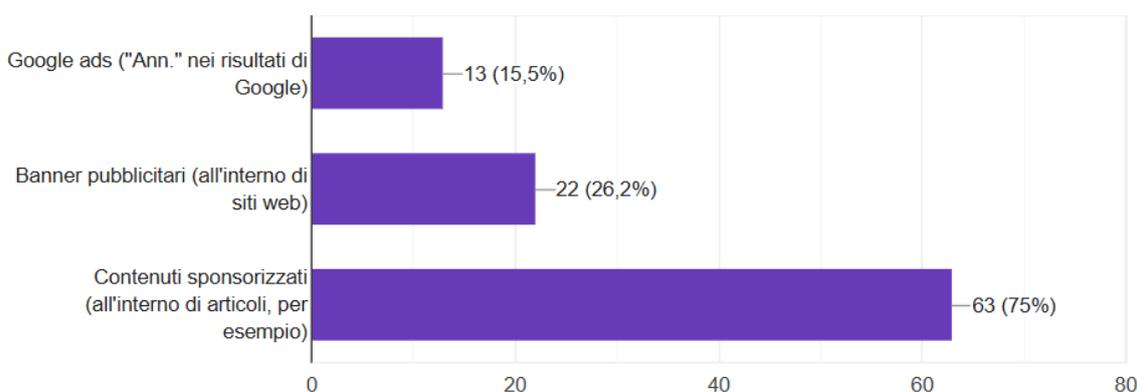


Figura 14. "Elementi della pubblicità online che più influenzano le scelte di acquisto". Fonte: elaborazione automatica di Google Forms.

Analizziamo ora la categoria dell'online advertising (Figura 14), tenendo presente che la pubblicità via social è stata studiata al paragrafo precedente. L'elemento che più influenza le scelte di consumo del campione è rappresentato dai contenuti sponsorizzati, essendo stato selezionato da tre intervistati su quattro. Seguono, in ordine di frequenza di scelta, i banner pubblicitari (26,2%) e le Google ads (15,5%).

Questi risultati potrebbero essere legati al maggiore livello di attendibilità percepita dei contenuti sponsorizzati, rispetto a quello di banner e Google ads.

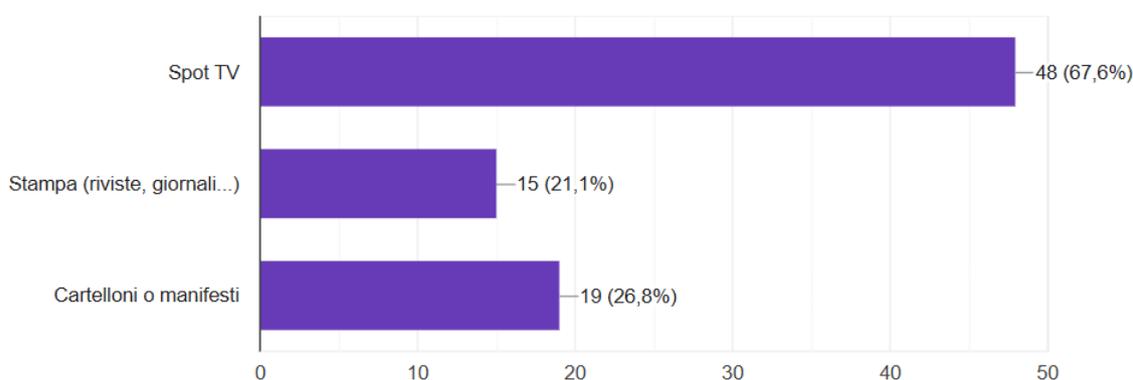


Figura 15. "Elementi dei media classici che più influenzano le scelte di acquisto". Fonte: elaborazione automatica di Google Forms.

In merito ai media classici (Figura 15), l'elemento che più influenza le scelte di consumo del campione è rappresentato dagli spot TV; questa opzione ha fatto registrare frequenza (67,6%) significativamente superiore rispetto a cartelloni o manifesti (26,8%) e alla stampa (21,1%).

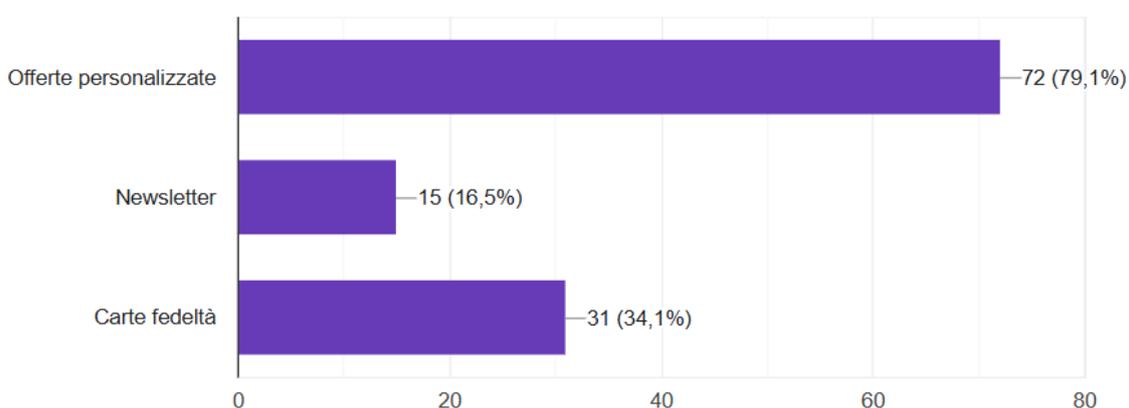


Figura 16. "Elementi del CRM che più influenzano le scelte di acquisto". Fonte: elaborazione automatica di Google Forms.

Per quanto riguarda il customer relationship management (Figura 16), l'elemento maggiormente selezionato (79,1%) è rappresentato dalle offerte personalizzate. Questo touchpoint ha la peculiarità di essere personalizzabile in base alle caratteristiche e alle

abitudini del cliente; per questo motivo, generalmente, è più efficace rispetto alla newsletter (16,5%), che risulta standardizzata per ogni consumatore.

Un altro touchpoint che ha la proprietà di adattarsi alle abitudini di acquisto del cliente è la carta fedeltà, ritenuta influente dal 34,1% del campione.

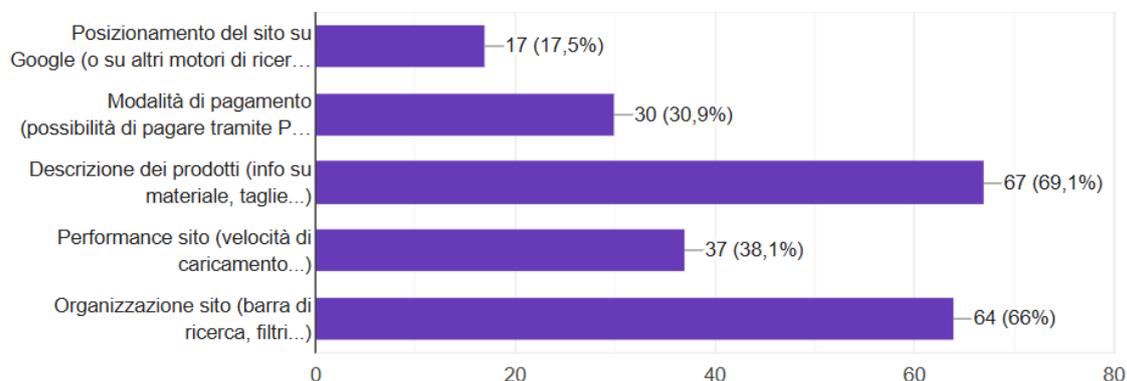


Figura 17. "Elementi dei siti web che più influenzano le scelte di acquisto". Fonte: elaborazione automatica di Google Forms.

Tra gli elementi dei siti web (Figura 17), quelli maggiormente influenti sulle scelte di consumo risultano essere l'organizzazione del sito (66%) e la descrizione dei prodotti (69,1%).

Le descrizioni hanno l'obiettivo di abbassare il livello di incertezza che un acquisto online comporta. L'organizzazione del sito fa invece parte degli elementi che condizionano la user experience, così come la performance del sito (38,1%) e le modalità di pagamento accettate (30,9%).

Il posizionamento del sito sui motori di ricerca, invece, risulta essere l'elemento con minore frequenza di scelta (17,5%).

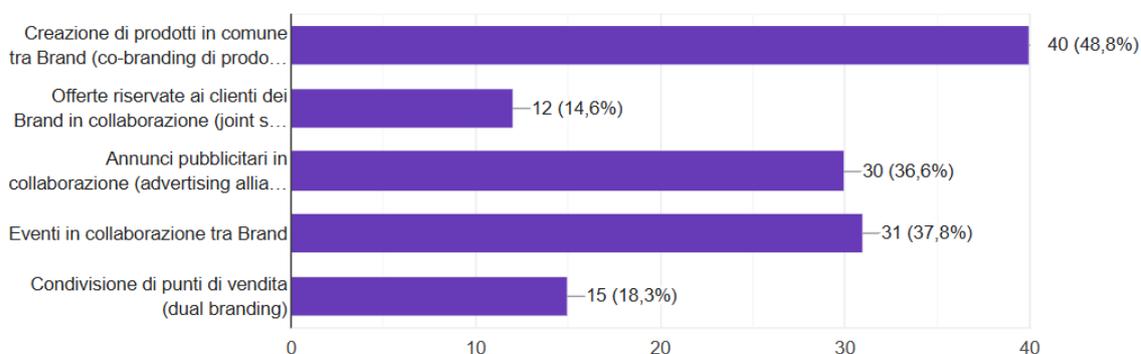


Figura 18. "Elementi delle cooperazioni che più influenzano le scelte di acquisto". Fonte: elaborazione automatica di Google Forms.

Per quanto riguarda le cooperazioni (Figura 18), l'elemento che più influenza le scelte di consumo del campione è rappresentato dalla creazione di prodotti in comune tra due o più brand (48,8%).

Risultano ampiamente scelti anche eventi (37,8%) e annunci pubblicitari (36,6%) in collaborazione tra brand.

La condivisione di punti vendita risulta meno frequente tra le scelte (18,3%), così come le offerte riservate ai clienti dei brand coinvolti nella cooperazione (14,6%).

### 3.3. ANALISI DESCRITTIVA: DATI QUANTITATIVI

Nei prossimi paragrafi andremo a commentare i dati quantitativi che si è ritenuto opportuno raccogliere, e le variabili quantitative che ne derivano.

#### 3.3.1. VARIABILE SPESA

Ai partecipanti è stato chiesto di indicare il valore in euro della loro spesa in vestiario negli ultimi tre mesi. Il lasso di tempo di tre mesi è stato scelto in modo da ridurre eventuali bias, come suggerito frequentemente nella letteratura (e.g. Zimmermann et al., 2022).

Dalla domanda in analisi, ricaviamo la variabile quantitativa continua "Spesa", rinominata per una maggiore comodità nelle analisi "EXP". Uno degli obiettivi della ricerca sarà quello di studiare come la variabile Spesa venga influenzata dalle altre variabili analizzate.

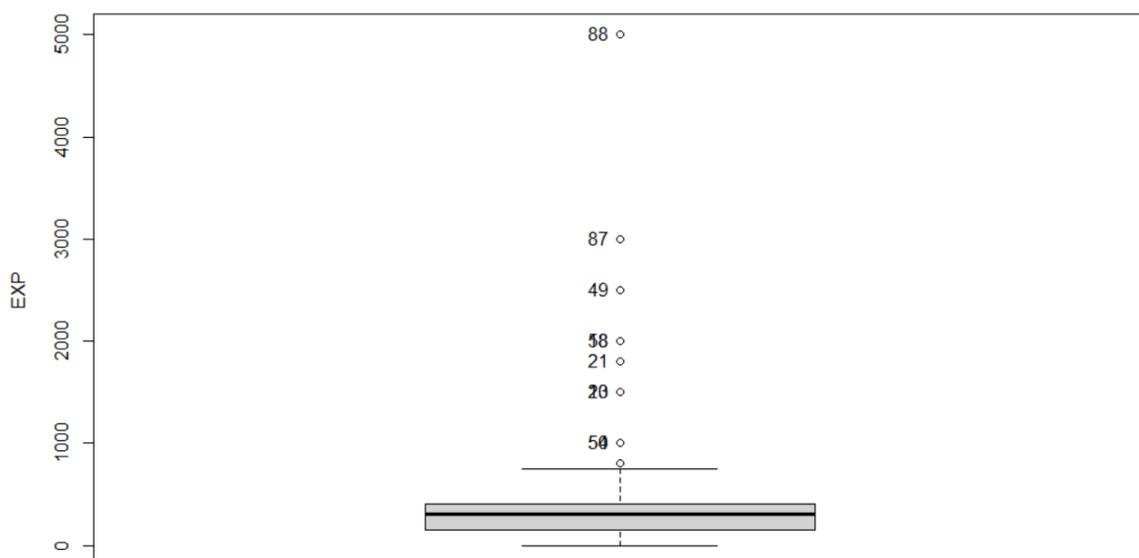


Figura 19. "Box plot variabile Spesa". Fonte: elaborazione propria.

La Figura 19 riporta il box-plot della variabile EXP. Questa tipologia di grafico viene utilizzata per visualizzare la distribuzione dei dati attraverso i loro quartili e per identificare eventuali valori anomali o outliers (ovvero punti che si discostano significativamente dalla maggior parte delle altre misurazioni). Come evidenziato dal grafico, sono presenti diversi outliers che, se considerati nel dataset, influirebbero fortemente sui risultati dell'analisi.

Per esempio, andando a calcolare la media di EXP, riferita al campione comprensivo degli outliers, troviamo un valore pari a 452,95€. Andando invece a escludere dal dataset gli outliers evidenziati dal box-plot, quindi tutte le osservazioni con spesa uguale o superiore a 1.000€, troviamo media di EXP pari a 266,78€.

Nel prossimo capitolo, prima di procedere con la stima del modello che possa spiegare EXP, sarà opportuno escludere gli outliers dal dataset.

### 3.3.2. VARIABILE REDDITO

Come spiegato precedentemente, la domanda “Come definiresti il tuo tenore di vita? Assegna un punteggio in scala da 1 (semplice) a 5 (elevato)” è stata pensata per raccogliere indicazioni sul reddito dei rispondenti. Pertanto, interpretiamo i punteggi assegnati come approssimazione (proxy) del reddito.

Una porzione consistente degli intervistati, pari al 65,4%, ha assegnato il livello intermedio al proprio tenore di vita. Il 18,7% del campione reputa il proprio tenore di vita di livello medio-alto, mentre il 14% ha selezionato il livello medio-basso. Le frequenze delle scelte dei rispondenti sono raffigurate in modo dettagliato nella Fig. 20.

## DISTRIBUZIONE PER TENORE DI VITA

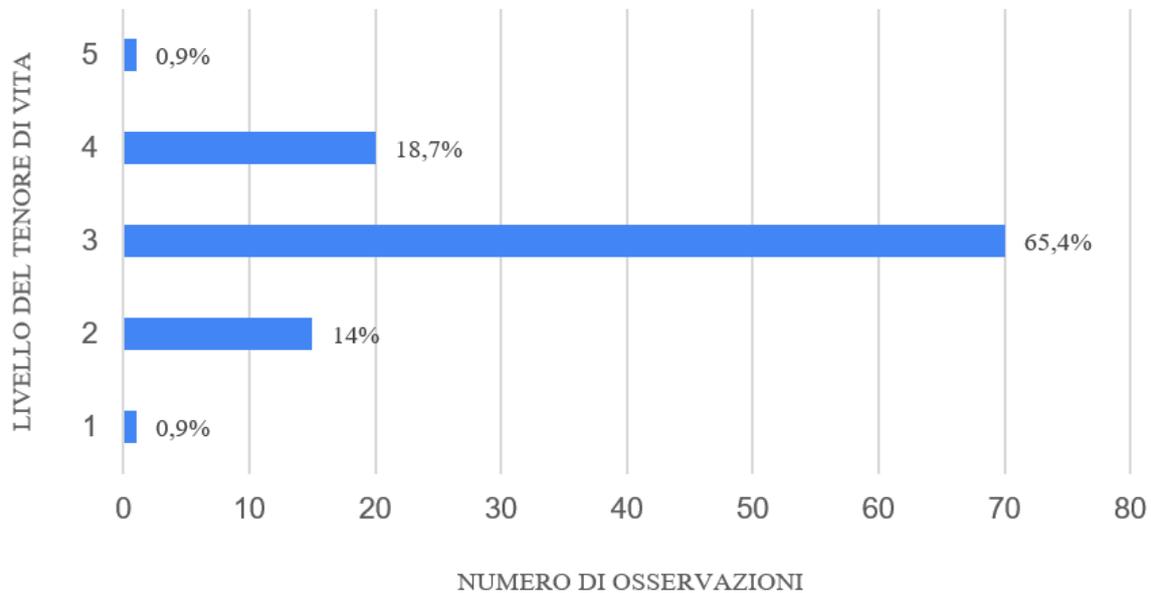


Figura 20. "Distribuzione per tenore di vita". Fonte: elaborazione propria.

Tenendo presente di stare analizzando una proxy, dai dati riferiti al tenore di vita dei rispondenti, ricaviamo la variabile quantitativa discreta "Reddito", rinominata per una maggiore comodità nelle analisi "Inc".

La media della variabile Inc è pari a 3,05. Pur trattandosi di un'approssimazione, possiamo comunque ipotizzare che la maggior parte degli intervistati abbia un livello di reddito medio. Sarà interessante valutare se questa variabile possa influire sulla variabile Spesa, che fa riferimento al valore della spesa in vestiario sostenuta dai rispondenti negli ultimi 3 mesi.

### 3.3.3. LE VARIABILI ESPOSIZIONE

Andremo ora ad analizzare due tipologie di domande, poste in modo speculare per ogni categoria di touchpoints individuata:

- è stato chiesto ai partecipanti di indicare il loro livello di esposizione a una determinata tipologia di touchpoints del settore dell'abbigliamento, negli ultimi tre mesi (punteggio in scala Likert).
- è stato chiesto ai partecipanti di indicare il livello di influenza di una specifica tipologia di touchpoints sui loro acquisti di vestiario, negli ultimi tre mesi (punteggio in scala Likert).

Dalle risposte alle sopracitate domande, derivano due variabili per ogni diversa categoria di punti di contatto, per un totale di 14 variabili.

Nel presente paragrafo, analizziamo le variabili relative all'esposizione ai touchpoints. Queste variabili sono state rinominate come evidenziato nella Tabella 9.

Esposizione ai POS	Epos
Esposizione ai social media	Esm
Esposizione alla pubblicità online	Eoa
Esposizione ai media classici	Ecm
Esposizione al CRM	Ecrm
Esposizione ai siti web	Ews
Esposizione alle cooperazioni	Ec

Tabella 9. "Variabili esposizione". Fonte: elaborazione propria.

Sarà interessante studiare come la spesa in vestiario possa variare all'aumento del livello di esposizione alle diverse categorie di touchpoints. Se i punti di interazione fossero efficaci ai fini della conversione all'acquisto, ci aspetteremmo che la spesa aumenti all'aumentare dell'esposizione.

Le seguenti figure mostrano il dettaglio delle risposte alle domande sul livello di esposizione ai punti di contatto.

#### DISTRIBUZIONE DI FREQUENZE VARIABILE EPOS

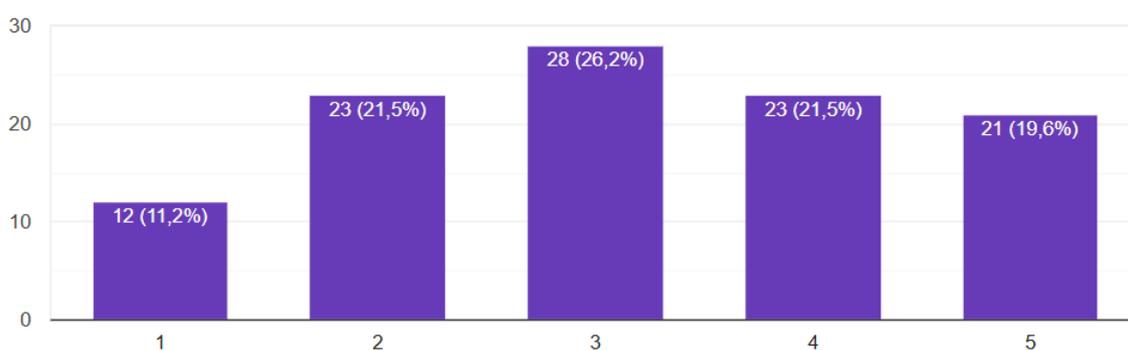


Figura 21. "Distribuzione di frequenze variabile Epos". Fonte: elaborazione automatica di Google Forms.

Figura 21: la media del livello di esposizione ai negozi fisici è pari a 3,17. La distribuzione delle scelte è piuttosto equilibrata tra le cinque opzioni, con prevalenza per i punteggi centrali. Complessivamente, il livello di esposizione ai touchpoints della categoria POS è intermedio per quanto riguarda il campione analizzato.

### DISTRIBUZIONE DI FREQUENZE VARIABILE ESM

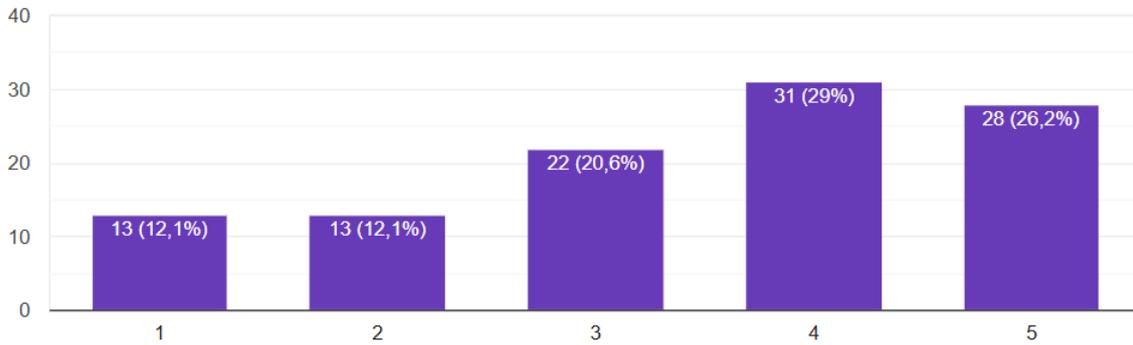


Figura 22. "Distribuzione di frequenze variabile Esm". Fonte: elaborazione automatica di Google Forms.

Figura 22: la media del livello di esposizione ai social media è pari a 3,45. La distribuzione delle scelte tende maggiormente verso i punteggi medio-alti. Tuttavia, il campione è visibilmente spartito tra le diverse opzioni di scelta; ciò comporta un valore elevato per la varianza, pari a 1,76. Questo potrebbe essere dovuto alle differenze nell'utilizzo dei social media tra la Gen Z e il resto del campione.

Complessivamente, il livello di esposizione ai touchpoints della categoria social media è piuttosto elevato per quanto riguarda il campione analizzato.

### DISTRIBUZIONE DI FREQUENZE VARIABILE EOA

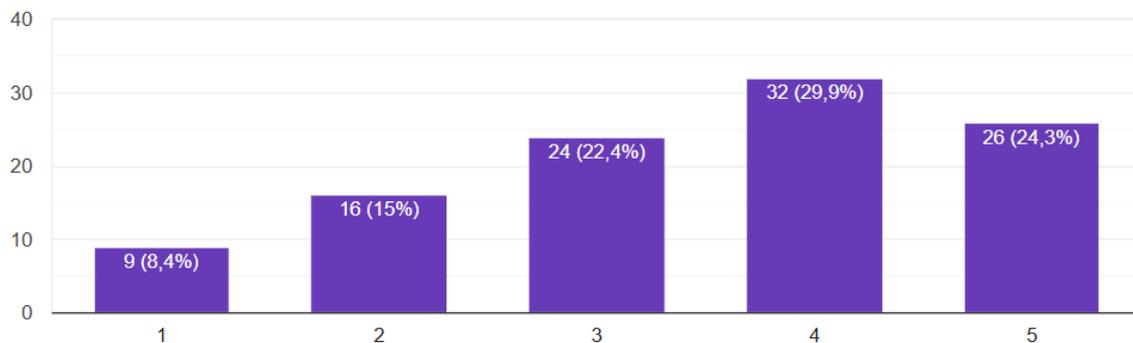


Figura 23. "Distribuzione di frequenze variabile Eoa". Fonte: elaborazione automatica di Google Forms.

Figura 23: il livello di esposizione alla pubblicità online presenta media pari a 3,47. La distribuzione delle scelte tende verso i punteggi medio-alti. Complessivamente, il livello di esposizione ai touchpoints della categoria online advertising è piuttosto elevato per quanto riguarda il campione analizzato.

### DISTRIBUZIONE DI FREQUENZE VARIABILE ECM

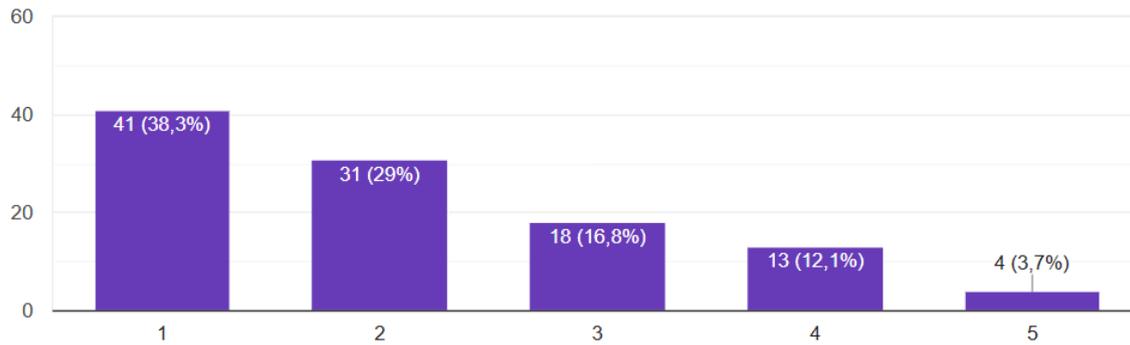


Figura 24. “Distribuzione di frequenze variabile Ecm”. Fonte: elaborazione automatica di Google Forms.

Figura 24: la media del livello di esposizione ai media classici è pari a 2,14. La distribuzione delle scelte tende fortemente verso i punteggi bassi. Complessivamente, il livello di esposizione ai touchpoints della categoria classical media è scarso per quanto riguarda il campione analizzato.

### DISTRIBUZIONE DI FREQUENZA VARIABILE ECRM

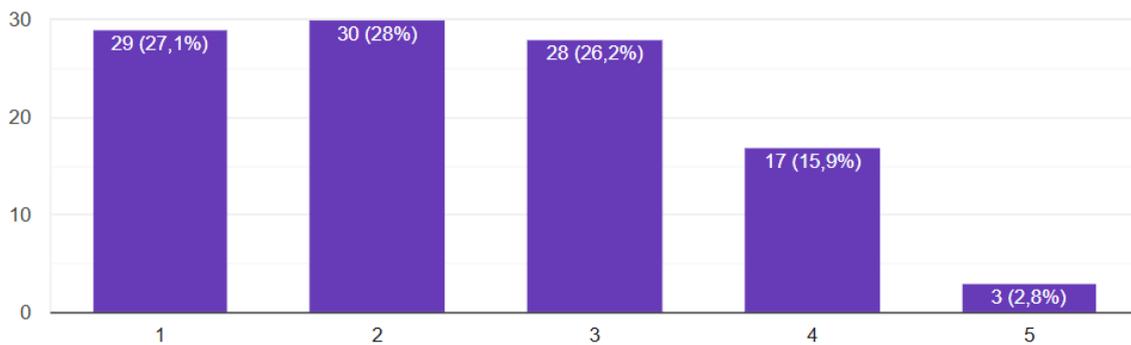


Figura 25. “Distribuzione di frequenze variabile Ecrm”. Fonte: elaborazione automatica di Google Forms.

Figura 25: il livello di esposizione al customer relationship management presenta media pari a 2,39. La distribuzione delle scelte tende verso i punteggi medio-bassi. Il campione sembra piuttosto concordante su questa scelta; ciò comporta un valore ridotto per la varianza, pari a 1,28.

Complessivamente, il livello di esposizione ai touchpoints della categoria CRM è piuttosto limitato per quanto riguarda il campione analizzato.

### DISTRIBUZIONE DI FREQUENZE VARIABILE EWS

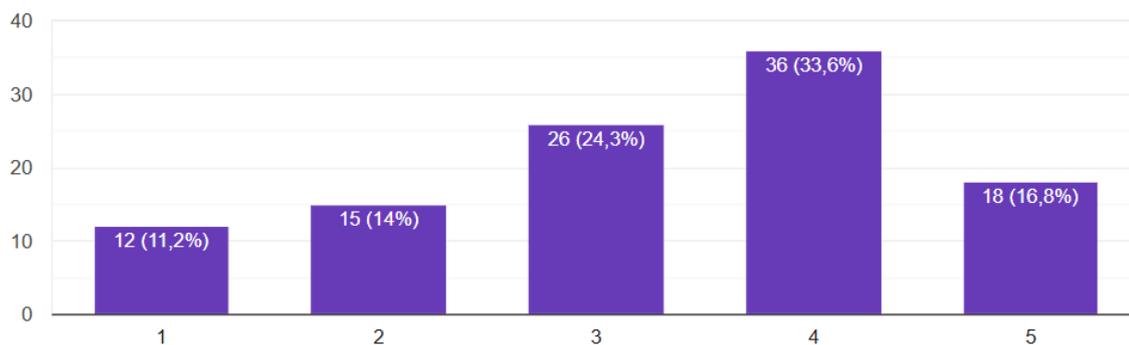


Figura 26. "Distribuzione di frequenze variabile Ews". Fonte: elaborazione automatica di Google Forms.

Figura 26: la media del livello di esposizione ai siti web è pari a 3,31. Complessivamente, il livello di esposizione ai touchpoints della categoria website è piuttosto elevato per quanto riguarda il campione analizzato.

Dobbiamo tenere conto del fatto che, per qualsiasi acquisto online, i consumatori devono entrare in contatto con i siti web, anche nel caso in cui siano venuti a conoscenza di un prodotto tramite altri touchpoints. Di conseguenza, era naturale aspettarsi un valore medio elevato per Ews.

### DISTRIBUZIONE DI FREQUENZE VARIABILE EC

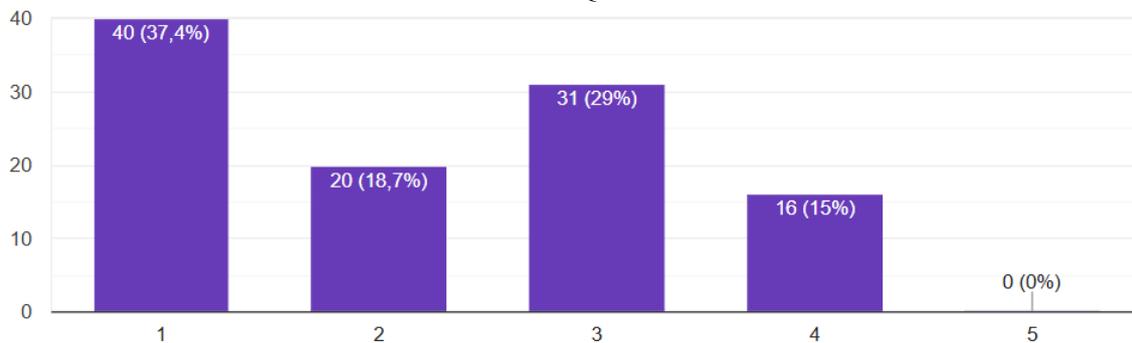


Figura 27. "Distribuzione di frequenze variabile Ec". Fonte: elaborazione automatica di Google Forms.

Figura 27: il livello di esposizione alle cooperazioni presenta media pari a 2,22. La distribuzione delle scelte tende verso i punteggi medio-bassi. Gran parte del campione ha selezionato un punteggio tra 1 e 3, riducendo la varianza a 1,23.

Complessivamente, il livello di esposizione ai touchpoints della categoria cooperations è piuttosto limitato per quanto riguarda il campione analizzato.

### 3.3.4. LE VARIABILI INFLUENZA

Come illustrato nel paragrafo precedente, sono state individuate sette variabili relative all'influenza delle diverse categorie di touchpoints analizzate. Queste variabili sono state rinominate come evidenziato nella Tabella 10.

Influenza dei POS	Ipos
Influenza dei social media	Ism
Influenza della pubblicità online	Ioa
Influenza dei media classici	Icm
Influenza del CRM	Icrm
Influenza dei siti web	Iws
Influenza delle cooperazioni	Ic

Tabella 10. "Variabili influenza". Fonte: elaborazione propria.

Sarà interessante studiare come la spesa in vestiario possa variare all'aumento del livello di influenza delle diverse categorie di touchpoints. In linea generale, ci aspettiamo che la spesa aumenti all'aumentare dell'influenza.

Le seguenti figure mostrano il dettaglio delle risposte alle domande sul livello di influenza dei punti di contatto.

#### DISTRIBUZIONE DI FREQUENZE VARIABILE IPOS

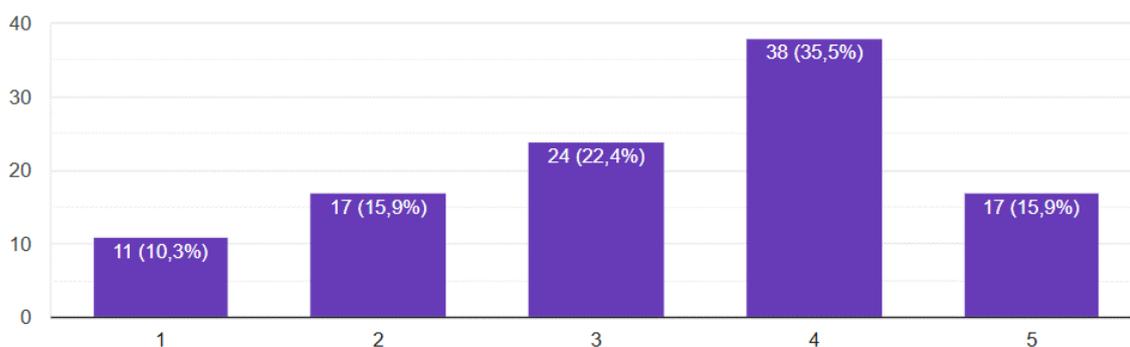


Figura 28. "Distribuzione di frequenze variabile Ipos". Fonte: elaborazione automatica di Google Forms.

Figura 28: la media del livello di influenza dei negozi fisici è pari a 3,31. Complessivamente, il livello di influenza dei touchpoints della categoria POS risulta elevato per quanto riguarda il campione analizzato.

Confrontando questi dati con quelli relativi all'esposizione (Fig. 21), notiamo che i point of sale sembrano essere touchpoints efficaci, poiché fanno registrare valori elevati sia per il livello di esposizione, che per il livello di influenza. Dunque, possedere uno store fisico

potrebbe permettere a un brand di entrare in contatto frequentemente con i consumatori e, soprattutto, di farlo in modo efficace in termini di conversione all'acquisto.

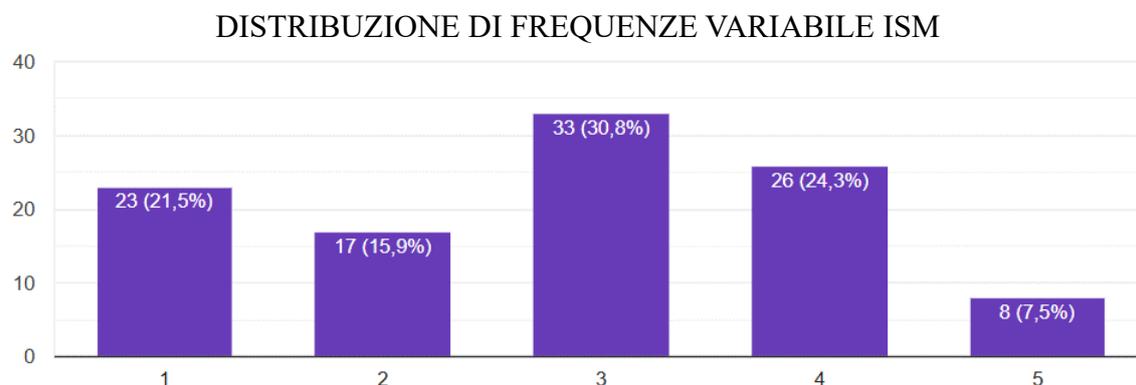


Figura 29. "Distribuzione di frequenze variabile Ism". Fonte: elaborazione automatica di Google Forms.

Figura 29: la media del livello di influenza dei social media è pari a 2,80. Il campione è visibilmente spartito tra le diverse opzioni di scelta, di conseguenza la varianza, pari a 1,54, è piuttosto consistente.

Per quanto riguarda i social media, il livello di influenza è moderatamente inferiore rispetto al livello di esposizione (Fig. 22). Ciò suggerisce che le campagne social, pur raggiungendo il consumatore con una certa facilità, non sempre sono efficaci in termini di conversione, o comunque lo sono in modo soggettivo (il 24,3% del campione assegna punteggio 4 alla loro influenza, ma il 21,5% assegna punteggio 1 su 5).

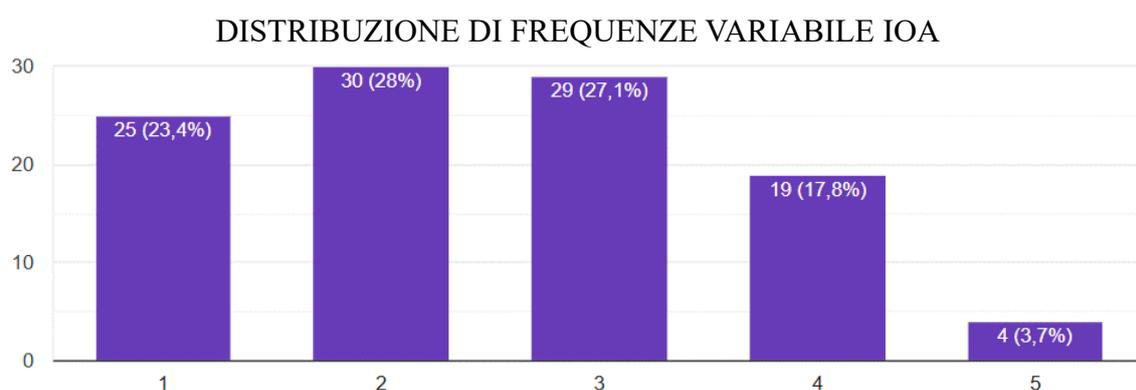


Figura 30. "Distribuzione di frequenze variabile loa". Fonte: elaborazione automatica di Google Forms.

Figura 30: il livello di influenza della pubblicità online presenta media pari a 2,51. La distribuzione delle scelte tende verso i punteggi medio-bassi. Questi dati si trovano in controtendenza rispetto a quelli raccolti per l'esposizione (Fig. 23), che invece fanno registrare una media piuttosto elevata. Ciò significa che la pubblicità online, pur raggiungendo frequentemente il consumatore, non sempre risulta efficace in termini di conversione all'acquisto.

### DISTRIBUZIONE DI FREQUENZE VARIABILE ICM

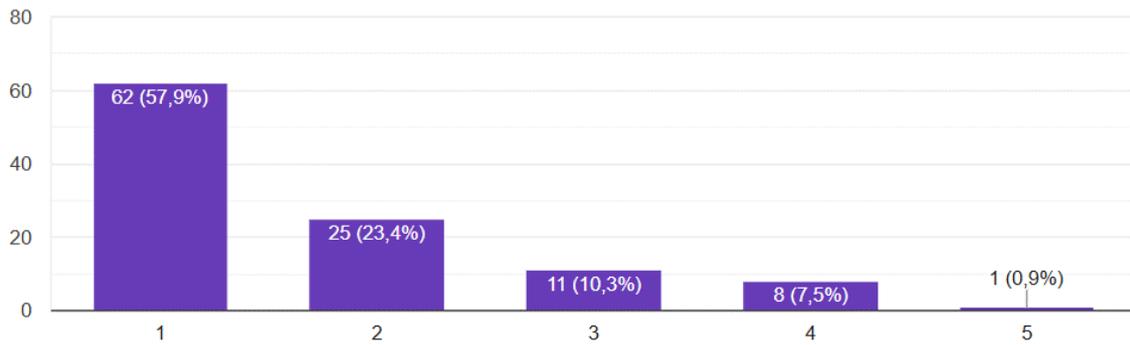


Figura 31. “Distribuzione di frequenze variabile Icm”. Fonte: elaborazione automatica di Google Forms.

Figura 31: la media del livello di influenza dei media classici è pari a 1,70. La distribuzione delle scelte tende fortemente verso i punteggi bassi, con limitata varianza, pari a 0,99.

Complessivamente, i media classici sembrano poco efficaci in termini di conversione all’acquisto. Inoltre, il basso livello di esposizione fatto registrare (Fig. 24) conferma che i CM non rappresentano un canale frequentemente utilizzato dalle campagne marketing legate al mondo del vestiario.

### DISTRIBUZIONE DI FREQUENZA VARIABILE ICRM

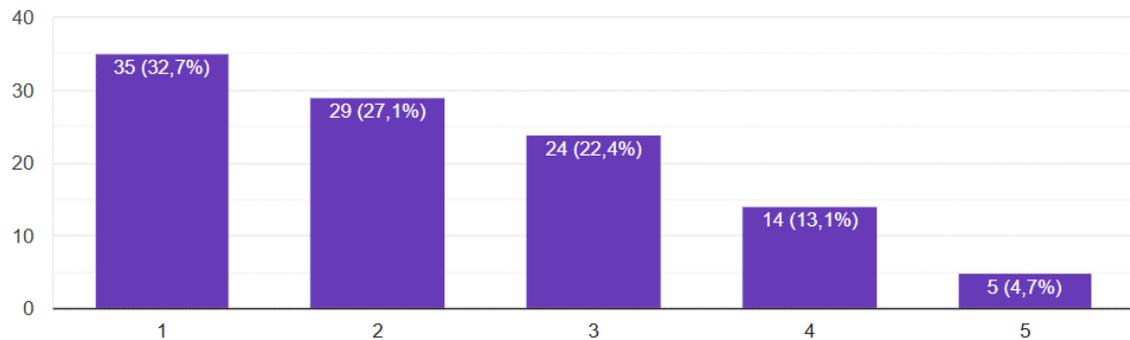


Figura 32. “Distribuzione di frequenze variabile Icrm”. Fonte: elaborazione automatica di Google Forms.

Figura 32: il livello di influenza del customer relationship management presenta media pari a 2,30. La distribuzione delle scelte tende verso i punteggi medio-bassi.

Contrariamente a quel che ci si possa aspettare, il livello di influenza del CRM è piuttosto limitato, per quanto riguarda il campione analizzato. La categoria CRM, infatti, comprende carte fedeltà e offerte personalizzate che, al contrario, dovrebbero stimolare l’acquisto da parte del cliente.

### DISTRIBUZIONE DI FREQUENZE VARIABILE IWS

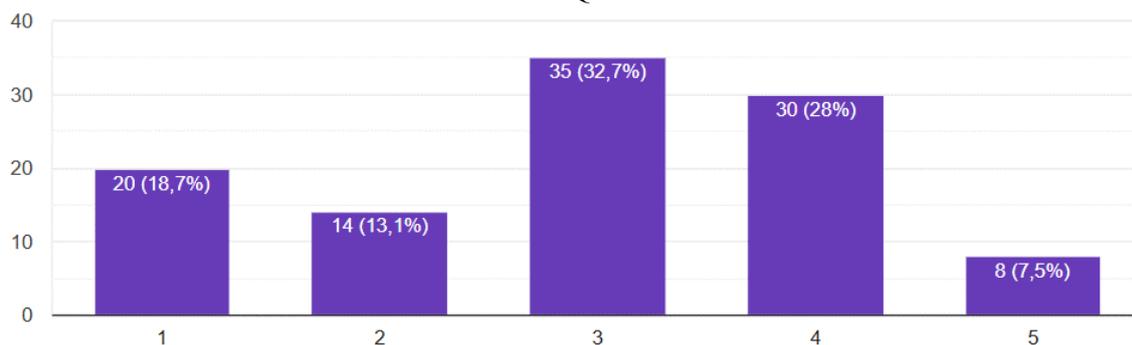


Figura 33. "Distribuzione di frequenze variabile Iws". Fonte: elaborazione automatica di Google Forms.

Figura 33: la media del livello di influenza dei siti web è pari a 2,93. Complessivamente, il livello di influenza dei siti web è intermedio per quanto riguarda il campione analizzato.

Come era lecito aspettarsi, il livello di influenza dei website risulta inferiore rispetto al livello di esposizione (Fig. 26); questo perché i consumatori entrano a contatto con un sito ogni qualvolta debbano concludere un acquisto online, che però non è detto sia stato indotto dal sito stesso.

### DISTRIBUZIONE DI FREQUENZE VARIABILE IC

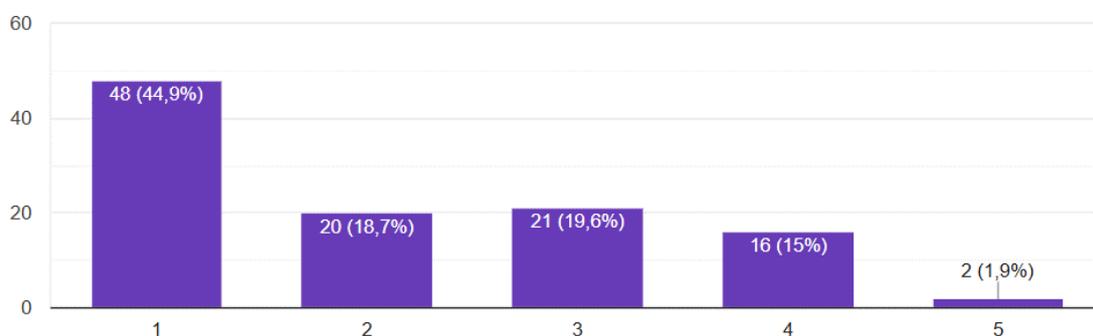


Figura 34. "Distribuzione di frequenze variabile Ic". Fonte: elaborazione automatica di Google Forms.

Figura 34: il livello di influenza delle cooperazioni tra brand presenta media pari a 2,10. La distribuzione delle scelte tende verso i punteggi bassi.

Complessivamente, sia il livello di influenza, che il livello di esposizione delle cooperazioni, risultano limitati per quanto riguarda il campione analizzato.

## 3.4. ANALISI MULTIVARIATA

In questo capitolo, ci addentreremo nelle analisi multivariate. Attraverso queste tecniche sarà possibile esaminare l'influenza delle diverse variabili indipendenti sulle variabili dipendenti di interesse. Inoltre, avremo l'obiettivo di identificare un modello che permetta di spiegare la spesa in capi di abbigliamento in funzione delle variabili esplicative

selezionate. Infine, tenteremo di individuare un modello in grado di spiegare le tendenze di acquisto negli store fisici.

Prima di procedere con l'analisi, dovendo trattare molteplici variabili contemporaneamente, è opportuno identificare ed escludere dal dataset quelle osservazioni che presentano dati mancanti. Per esempio, eliminiamo le osservazioni degli individui che non hanno specificato la propria età. Eseguita questa prima operazione di pulizia dei dati, il dataset risulta ora composto da 101 osservazioni utili, rispetto alle 107 di partenza.

### 3.4.1. ANALISI BIVARIATA: VARIABILE EXP

Di seguito ci dedicheremo all'esplorazione delle relazioni bivariate tra la variabile dipendente Spesa e le altre variabili individuate, al fine di comprendere le possibili interazioni e correlazioni. Inizieremo a valutare come si comporta EXP rispetto alle variabili qualitative individuate.

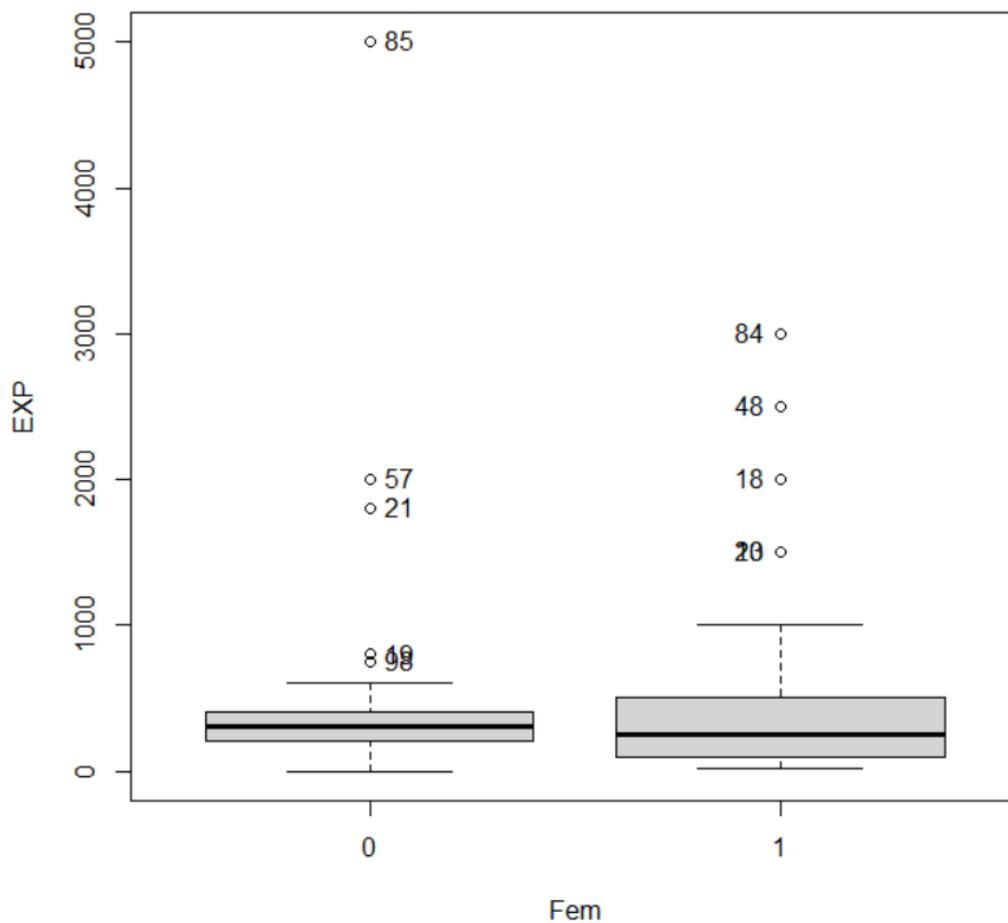


Figura 35. "Box-plot di EXP per gruppi di Genere". Fonte: elaborazione propria.

La Figura 35 ritrae i box-plot della variabile Spesa distinti in base alla dummy Fem; quest'ultima assume valore 1 nel caso in cui si consideri la parte di campione femminile (scatola a destra), 0 altrimenti (scatola a sinistra).

Notiamo come la scatola della distribuzione femminile sia più ampia, con le osservazioni più diradate intorno alla mediana. La porzione femminile presenta un IQR più ampio e, di conseguenza, una maggiore variabilità. Entrambi i gruppi presentano degli outliers. Il range di valori incerti tra le due scatole è piuttosto ampio.

La mediana del gruppo femminile è leggermente più bassa, così come la media: 453,15€ per la porzione di campione femminile, 464,68€ per il resto del campione. Otteniamo gli stessi risultati calcolando la media esclusi gli outliers evidenziati dal box-plot della variabile Spesa (Fig. 19): 238,48€ per le femmine, 296,36€ per il resto del campione.

Complessivamente la variabile Fem non sembra essere in grado di spiegare una parte rilevante della variabilità di EXP. Tuttavia, i grafici e gli indicatori calcolati suggeriscono una possibile correlazione tra queste due variabili.

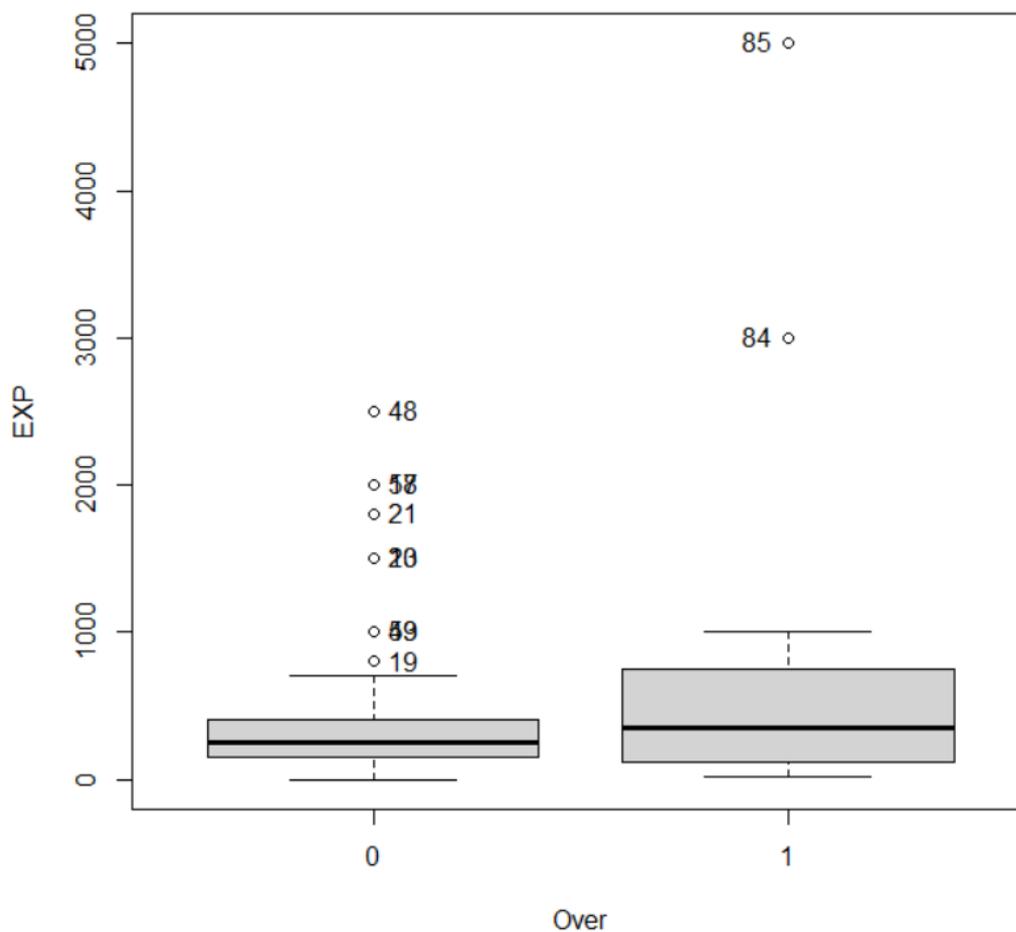


Figura 36. "Box-plot di EXP per gruppi di età". Fonte: elaborazione propria.

La Figura 36 ritrae i box-plot della variabile Spesa distinti in base alla dummy Over; quest'ultima assume valore 1 nel caso in cui si consideri la parte di campione Over 30 (scatola a destra), oppure valore 0 nel caso in cui si consideri la parte di campione Gen Z (scatola a sinistra).

Notiamo come la scatola della distribuzione Gen Z sia più ristretta, con le osservazioni più compatte intorno alla mediana. La porzione Over 30 presenta un IQR più ampio e, di conseguenza, una maggiore variabilità. Entrambi i gruppi presentano degli outliers; in particolare la porzione Over 30 presenta due outliers critici, che influenzeranno molto il valore della media. Il range di valori incerti tra le due scatole è piuttosto ampio.

La mediana del gruppo Gen Z è più bassa, così come la media: 388,86€ per la porzione di campione Gen Z, 779,72€ per quella Over 30. Otteniamo risultati più paragonabili calcolando la media esclusi gli outliers evidenziati dal box-plot della variabile Spesa (Fig. 19): 253,00€ per i Gen Z, 335,67€ per gli Over 30.

Complessivamente la variabile Over non sembra essere in grado di spiegare una parte rilevante della variabilità di EXP. Tuttavia, i grafici e gli indicatori calcolati suggeriscono una possibile correlazione tra queste due variabili.

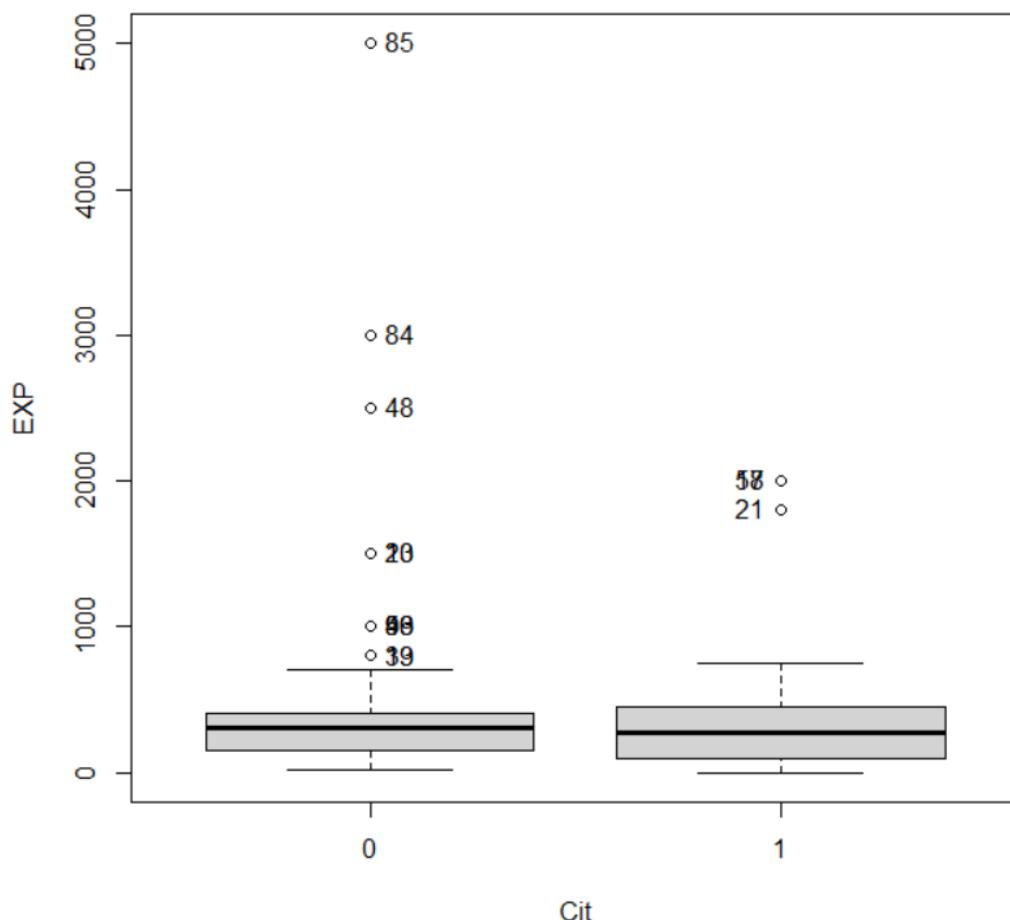


Figura 37. "Box-plot di EXP per la dummy Cit". Fonte: elaborazione propria.

La Figura 37 ritrae i box-plot della variabile Spesa distinti in base alla dummy Cit; quest'ultima assume valore 1 nel caso in cui si consideri la parte di campione che vive in città (scatola a destra), 0 in tutti gli altri casi (scatola a sinistra).

Notiamo come la scatola riferita agli individui che vivono in città sia più ampia, con IQR più esteso e, quindi, una maggiore variabilità. Presenta, inoltre, una minore quantità di outliers. Il range di valori incerti tra le due scatole è piuttosto ampio.

La distribuzione del gruppo proveniente dalla città presenta mediana leggermente inferiore. Le medie risultano molto simili: 456,67€ per gli individui provenienti dalla città, 459,09€ per il resto del campione. Escludendo gli outliers evidenziati dal box-plot della variabile Spesa (Fig. 19) invece, otteniamo medie maggiormente distanziate: 245,71€ per la porzione che vive in città, 273,19€ per il resto del campione.

Complessivamente la variabile Cit non sembra essere in grado di spiegare una parte rilevante della variabilità di EXP.

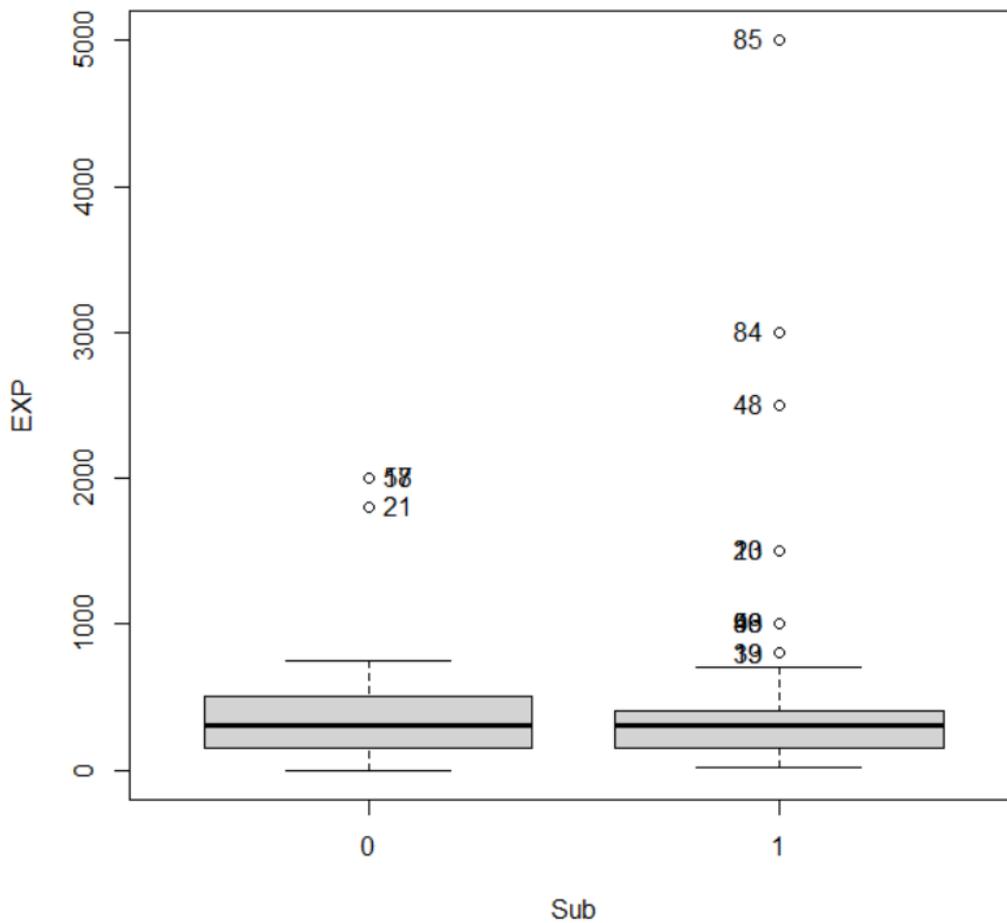


Figura 38. "Box-plot di EXP per la dummy Sub". Fonte: elaborazione propria.

La Figura 38 ritrae i box-plot della variabile Spesa distinti in base alla dummy Sub; quest'ultima assume valore 1 nel caso in cui si consideri la parte di campione che vive in aree suburbane (scatola a destra), 0 in tutti gli altri casi (scatola a sinistra).

Notiamo come la scatola riferita agli individui che vivono in aree suburbane sia più stretta, con IQR più breve e, quindi, una minore variabilità. Presenta, inoltre, una maggiore quantità di outliers. Il range di valori incerti tra le due scatole è piuttosto ampio.

La distribuzione del gruppo proveniente da aree suburbane presenta media superiore: 476,47€ per gli individui provenienti da aree suburbane, 421,52€ per il resto del campione. Escludendo gli outliers evidenziati dal box-plot della variabile Spesa (Fig. 19) invece, otteniamo medie meno distanziate: 259,89€ per la porzione che vive in aree suburbane, 241,43€ per il resto del campione.

Complessivamente la variabile Sub non sembra essere in grado di spiegare una parte rilevante della variabilità di EXP

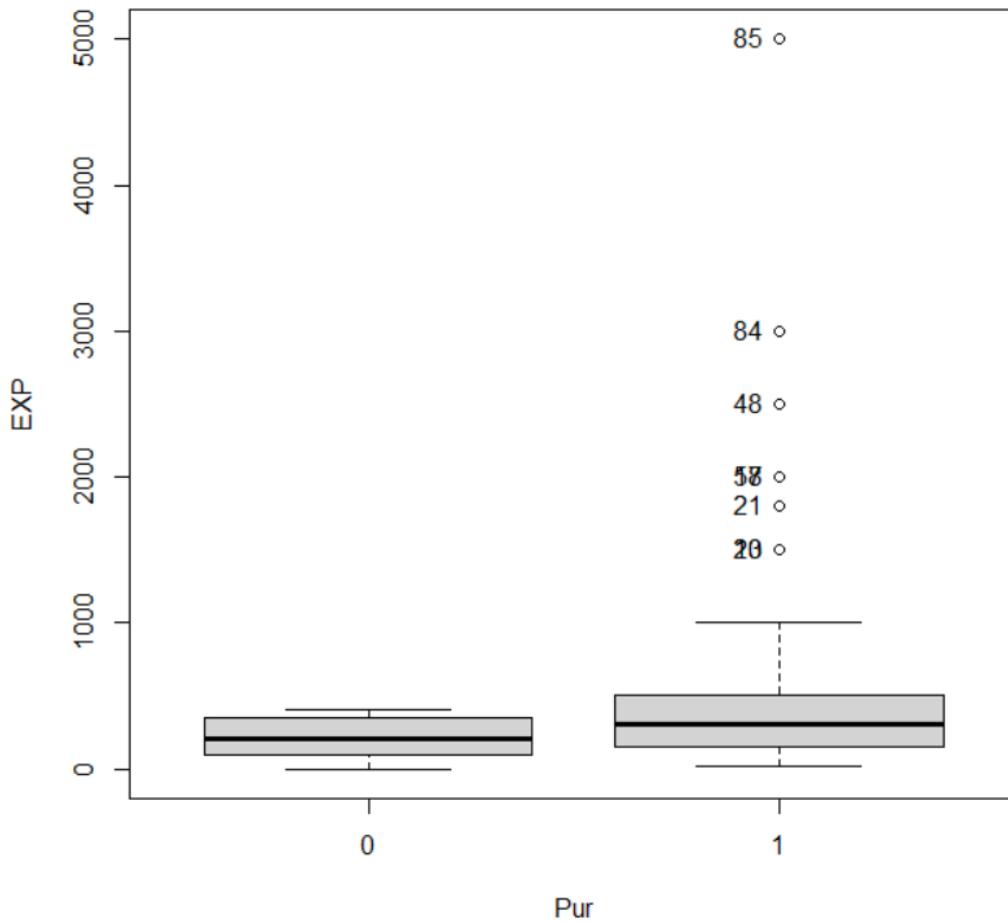


Figura 39. "Box-plot di EXP per la dummy Pur". Fonte: elaborazione propria.

La Figura 39 ritrae i box-plot della variabile Spesa distinti in base alla dummy Pur; quest'ultima assume valore 1 nel caso in cui si consideri la parte di campione che ha effettuato almeno 1 acquisto in POS negli ultimi 3 mesi (scatola a destra), 0 altrimenti (scatola a sinistra).

Notiamo come la scatola di sinistra sia più ristretta, con IQR più breve e minore variabilità. Solo la distribuzione di destra presenta outliers. Il range di valori incerti tra le due scatole è piuttosto ampio.

Complessivamente la variabile Pur non sembra essere in grado di spiegare una parte rilevante della variabilità di EXP. Tuttavia, i grafici e gli indicatori calcolati suggeriscono una possibile correlazione tra queste due variabili.

Per quanto riguarda le variabili qualitative, solamente Fem, Over e Pur sembra possano contribuire a spiegare la Spesa.

Passeremo ora ad analizzare il comportamento di EXP in relazione alle variabili quantitative individuate. Per fare ciò, è opportuno utilizzare una tipologia di grafico differente rispetto a quelli utilizzati in precedenza. Ci serviremo dello scatterplot (o grafico a dispersione), utile a individuare eventuali pattern, correlazioni o tendenze tra due variabili quantitative.

Siccome gli scatterplot risentono della presenza di valori anomali, prima di visualizzare questi grafici, è opportuno escludere definitivamente dal dataset gli outliers della variabile dipendente EXP, onde evitare che questi compromettano i grafici stessi.

Come evidenziato dal box-plot della variabile Spesa, alla Figura 19, sono considerabili outliers tutte le osservazioni che fanno registrare valori per EXP uguali o superiori a 1.000€. Una volta esclusi i valori anomali, il dataset risulta essere composto da 90 osservazioni utili.

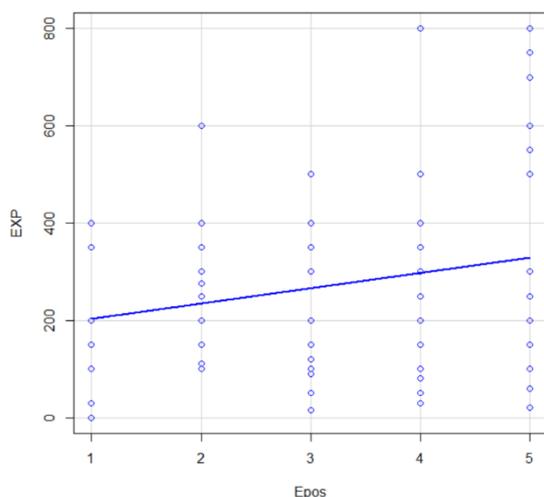


Figura 40. "Scatterplot di EXP in funzione di Epos".  
Fonte: elaborazione propria.

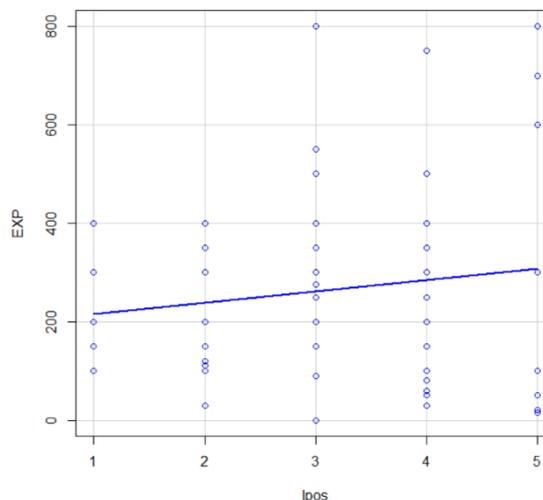


Figura 41. "Scatterplot di EXP in funzione di Ipos".  
Fonte: elaborazione propria.

Per quanto riguarda i negozi fisici, sia la variabile Epos (Esposizione ai POS) che la variabile Ipos (Influenza dei POS) sembra possano essere correlate a EXP. In entrambi i casi, la linea dei minimi quadrati evidenzia una possibile correlazione positiva tra le variabili (Fig. 40) (Fig. 41).

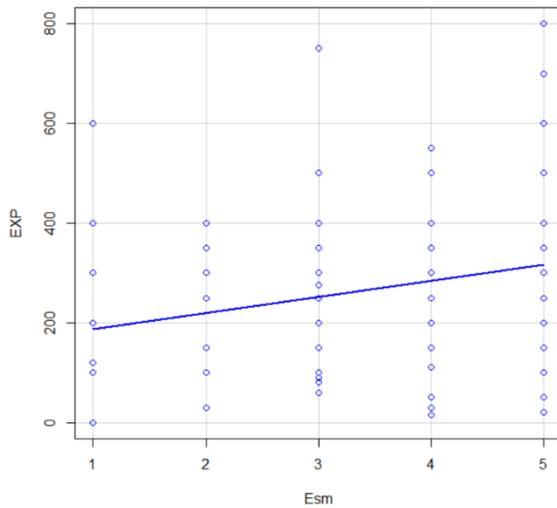


Figura 42. "Scatterplot di EXP in funzione di Esm".  
Fonte: elaborazione propria.

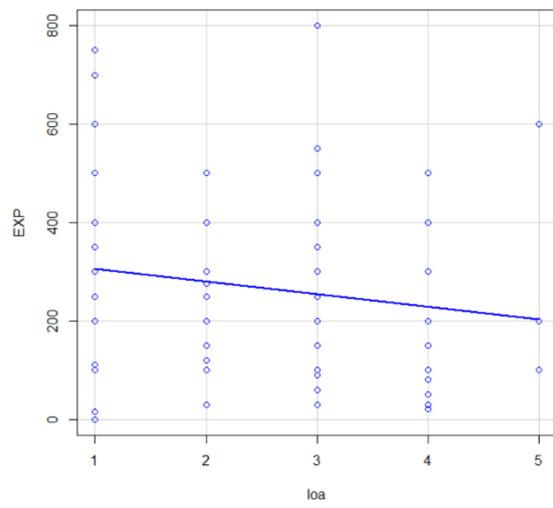


Figura 43. "Scatterplot di EXP in funzione di Ism".  
Fonte: elaborazione propria.

Per quanto riguarda i Social Media, sia la variabile Esm (Esposizione ai Social) che la variabile Ism (Influenza dei Social) sembra possano essere correlate a EXP. Nel caso di Esm, la linea dei minimi quadrati evidenzia una possibile correlazione positiva tra le variabili. Nel caso di Ipos, invece, la linea dei minimi quadrati evidenzia una possibile correlazione negativa (Fig. 42) (Fig. 43).

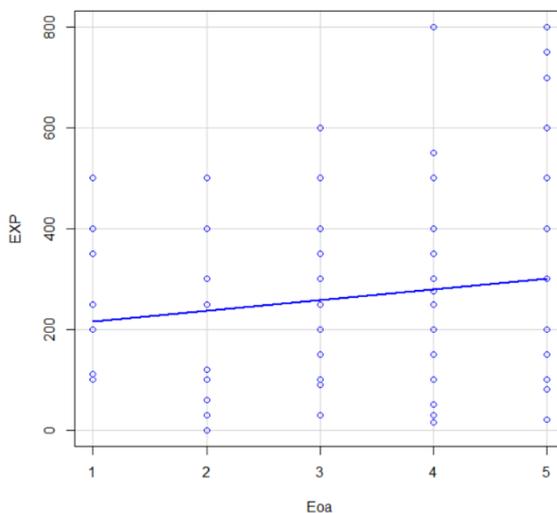


Figura 44. "Scatterplot di EXP in funzione di Eoa".  
Fonte: elaborazione propria.

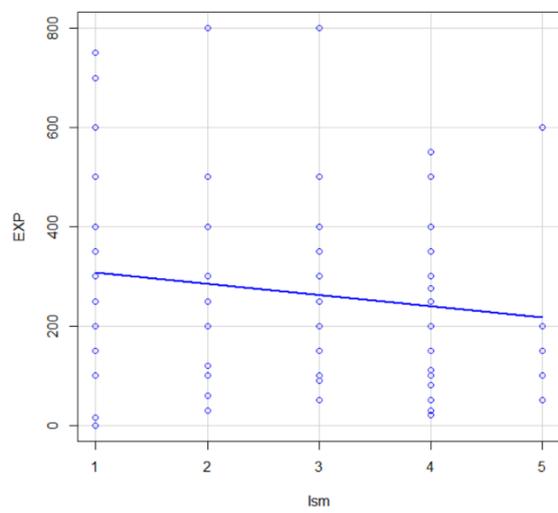


Figura 45. "Scatterplot di EXP in funzione di Ioa".  
Fonte: elaborazione propria.

Per quanto riguarda la pubblicità online, sia la variabile Eoa (Esposizione all'Online Advertising) che la variabile Ipos (Influenza dell'Online Advertising) sembra possano essere correlate a EXP. Nel caso di Eoa, la linea dei minimi quadrati evidenzia una

possibile correlazione positiva tra le variabili. Nel caso di Ioa, invece, la linea dei minimi quadrati evidenzia una possibile correlazione negativa (Fig. 44) (Fig. 45).

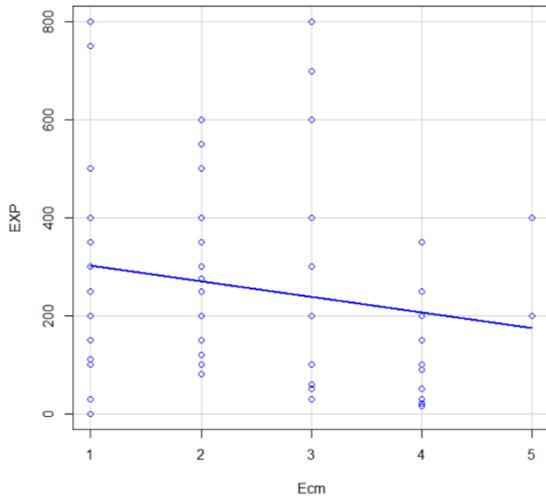


Figura 46. "Scatterplot di EXP in funzione di Ecm".  
Fonte: elaborazione propria.

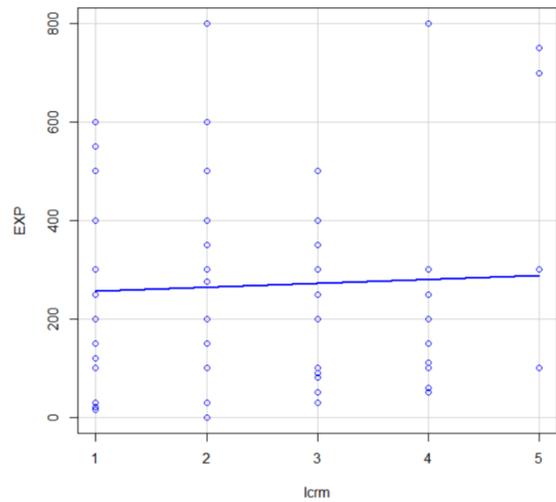


Figura 47. "Scatterplot di EXP in funzione di lcm".  
Fonte: elaborazione propria.

Per quanto riguarda i Media Classici, sia la variabile Ecm (Esposizione ai Classical Media) che la variabile Ipos (Influenza dei Classical Media) sembra possano essere correlate a EXP. In entrambi i casi, la linea dei minimi quadrati evidenzia una possibile correlazione negativa tra le variabili (Fig. 46) (Fig. 47).

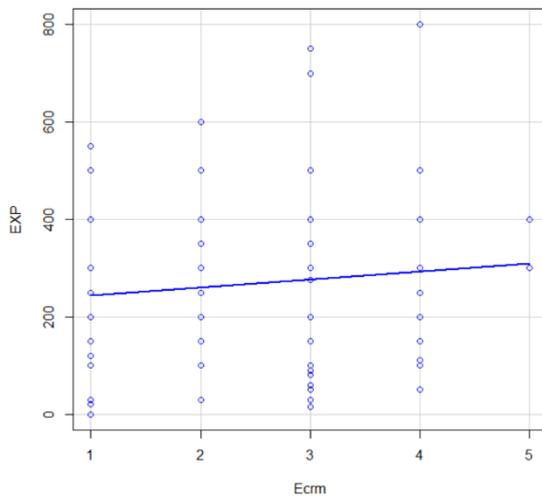


Figura 48. "Scatterplot di EXP in funzione di Ecrm".  
Fonte: elaborazione propria.

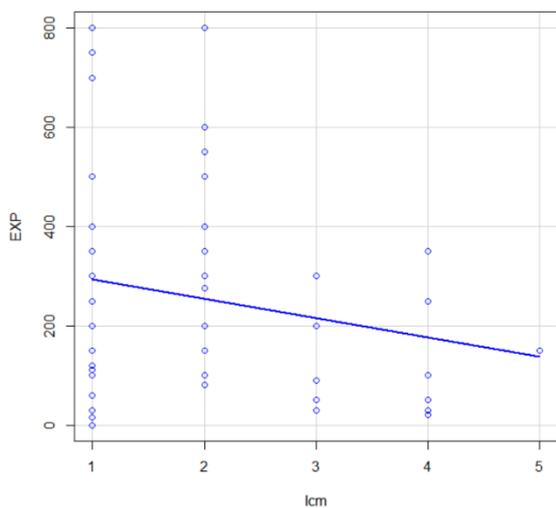


Figura 49. "Scatterplot di EXP in funzione di lcrm".  
Fonte: elaborazione propria.

Per quanto riguarda il Customer Relationship Management, i grafici delle variabili Ecrm (Esposizione al CRM) e lcrm (Influenza del CRM) non evidenziano trend spiccati tra le

variabili. Nel caso di Ecrm, la linea dei minimi quadrati evidenzia una possibile debole correlazione positiva. Nel caso di Icrm, invece, la linea dei minimi quadrati ha inclinazione pressoché impercettibile; ciò rende complicato ipotizzare una correlazione tra le variabili (Fig. 48) (Fig. 49).

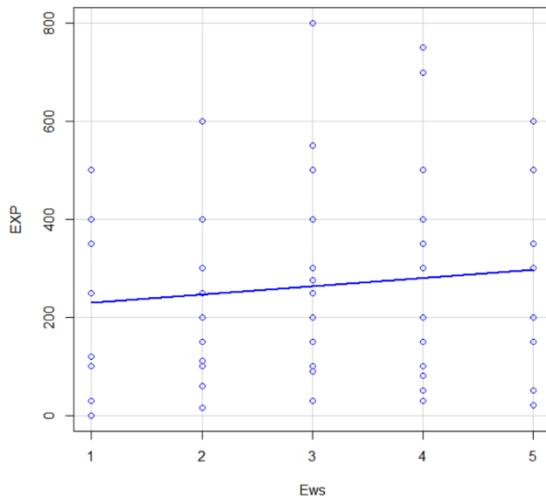


Figura 50. "Scatterplot di EXP in funzione di Ews".  
Fonte: elaborazione propria.

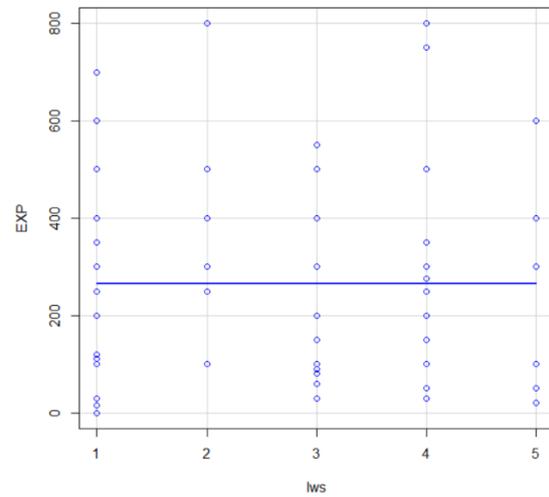


Figura 51. "Scatterplot di EXP in funzione di Iws".  
Fonte: elaborazione propria.

Per quanto riguarda i Siti Web, la variabile Ews (Esposizione ai Web Site) sembra possa essere correlate a EXP; la linea dei minimi quadrati evidenzia una possibile correlazione positiva tra le variabili (Fig. 50). Nel caso di Iws (Influenza dei Web Site), invece, la linea dei minimi quadrati non sembra evidenziare alcun tipo di correlazione con EXP (Fig. 51).

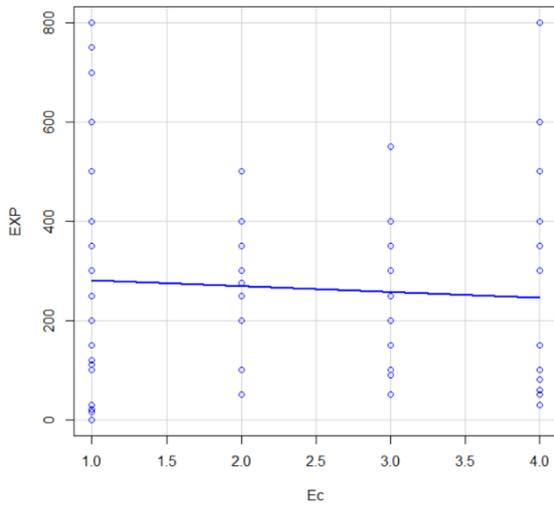


Figura 52. "Scatterplot di EXP in funzione di Ec".  
Fonte: elaborazione propria.

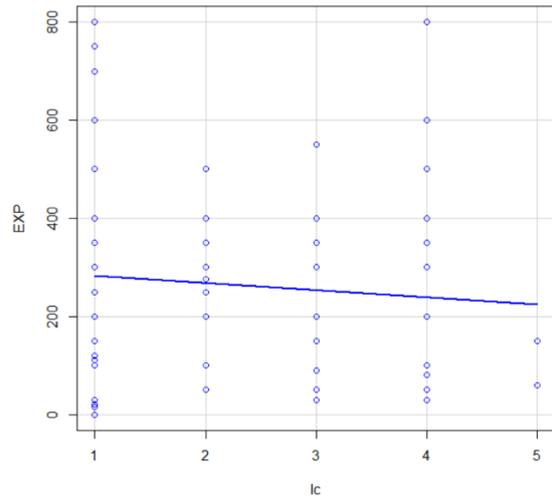


Figura 53. "Scatterplot di EXP in funzione di Ic".  
Fonte: elaborazione propria.

Per quanto riguarda le Cooperazioni, i grafici delle variabili Ec (Esposizione alle Cooperazioni) e Ic (Influenza alle Cooperazioni) non evidenziano trend spiccati tra le variabili. Nel caso di Ec, la linea dei minimi quadrati ha inclinazione pressoché impercettibile; ciò rende complicato ipotizzare una correlazione tra le variabili (Fig. 52). Nel caso di Ic, la linea dei minimi quadrati evidenzia una possibile debole correlazione negativa (Fig. 53).

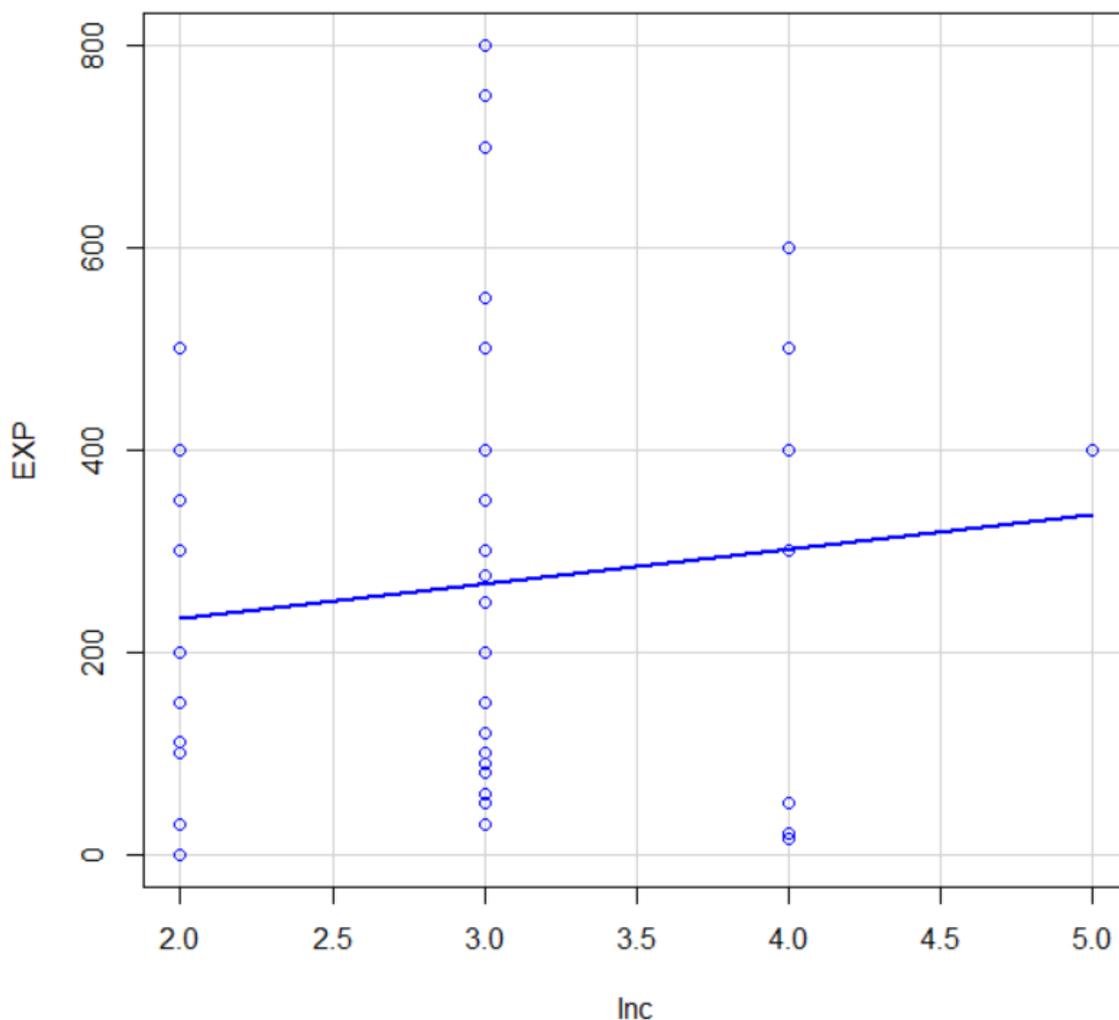


Figura 54. "Scatterplot di EXP in funzione di Inc". Fonte: elaborazione propria.

La variabile Inc (variabile Reddito) sembra possa essere correlate a EXP; la linea dei minimi quadrati evidenzia una possibile correlazione positiva tra le variabili (Fig. 54).

### 3.4.2. APPLICAZIONE DI UN MODELLO STATISTICO: VARIABILE EXP

Nel presente paragrafo, esamineremo l'applicabilità di un modello che possa spiegare la variabile dipendente Spesa.

Essendo una scelta ricorrente in letteratura (e.g. Zimmermann et al., 2022), si è deciso di applicare la regressione lineare. Come prima cosa, si è stimato il modello contenente tutte le variabili esplicative individuate nei paragrafi precedenti, in modo da avere una panoramica generale della situazione (Fig. 55).

```
Call:
lm(formula = EXP ~ Cit + Ec + Ecm + Ecrm + Eoa + Epos + Esm +
    Ews + Fem + Ic + Icm + Icrm + Inc + Ioa + Ipos + Ism + Iws +
    Over + Pur + Sub, data = TOUCHPOINTS)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-421.20 -101.84  -10.69   86.03  410.18
```

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   -4.279     131.552  -0.033  0.97415
Cit[T.1]     -88.669     72.671  -1.220  0.22657
Ec           -30.720     38.964  -0.788  0.43315
Ecm          -35.349     22.539  -1.568  0.12138
Ecrm         19.465     30.795   0.632  0.52942
Eoa          18.675     19.937   0.937  0.35216
Epos         21.576     21.426   1.007  0.31744
Esm          57.110     21.109   2.705  0.00859 **
Ews          24.971     30.933   0.807  0.42229
Fem[T.1]    -118.044     41.752  -2.827  0.00614 **
Ic           23.283     33.933   0.686  0.49492
Icm           4.228     29.091   0.145  0.88486
Icrm         -7.281     27.584  -0.264  0.79261
Inc          35.221     33.082   1.065  0.29074
Ioa         -10.509     22.764  -0.462  0.64580
Ipos         7.740     21.832   0.355  0.72403
Ism         -26.163     21.848  -1.198  0.23520
Iws         -14.743     30.667  -0.481  0.63221
Over[T.1]   129.254     62.183   2.079  0.04137 *
Pur[T.1]    37.508     60.252   0.623  0.53565
Sub[T.1]   -60.729     68.630  -0.885  0.37929
```

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 157.9 on 69 degrees of freedom
Multiple R-squared:  0.4015,    Adjusted R-squared:  0.228
F-statistic: 2.314 on 20 and 69 DF,  p-value: 0.005398
```

Figura 55. “Stima del modello lineare comprensivo di tutte le variabili”. Fonte: elaborazione propria.

Figura 55: la stima evidenzia un elevato numero di variabili non significative, ovvero variabili alle quali è associato p-value superiore alla soglia del 5%. Le uniche variabili significative sembrano essere Esm, Fem e Over. Tuttavia, i valori relativi alla Statistica F e alla sua significatività indicano che almeno uno dei regressori è sicuramente significativo.

Per quanto riguarda l’interpretazione dei coefficienti, per esempio, possiamo affermare che un aumento di 1 punto in scala Likert dell’Esposizione ai Social Media comporta un aumento in media di 57,11€ della Spesa in vestiario, ferme restando le altre variabili.

Il valore di  $R^2$  testimonia un buon livello di goodness of fit, e indica che il modello usato spiega il 40,15% della variabilità della variabile risposta. Tuttavia, il valore di R-Adjusted, decisamente inferiore a quello di  $R^2$ , suggerisce che il modello possa essere migliorato in termini di capacità predittiva.

Al fine di individuare il sottoinsieme ottimale di variabili predittive, si è deciso di applicare al modello la procedura Stepwise backward basata sul criterio AIC. In questo modo, è stato possibile eliminare le variabili con scarso impatto sulla variabile EXP, migliorando l'accuratezza e l'efficienza del modello.

```
Step: AIC=910.42
EXP ~ Ecm + Eoa + Epos + Esm + Fem + Inc + Ism + Over
```

	Df	Sum of Sq	RSS	AIC
<none>			1822348	910.42
- Inc	1	54630	1876978	911.08
- Eoa	1	55007	1877354	911.10
- Epos	1	68286	1890634	911.74
- Ism	1	88522	1910870	912.69
- Ecm	1	142500	1964847	915.20
- Over	1	213861	2036209	918.41
- Fem	1	214690	2037038	918.45
- Esm	1	268342	2090690	920.79

```
Call:
lm(formula = EXP ~ Ecm + Eoa + Epos + Esm + Fem + Inc + Ism +
    Over, data = TOUCHPOINTS)
```

Coefficients:

(Intercept)	Ecm	Eoa	Epos	Esm	Fem[T.1]
1]	-34.19	-37.62	24.91	24.83	60.44
8					-109.9
	Inc	Ism	Over[T.1]		
	44.67	-32.89	152.24		

Figura 56. "Ultimo step dell'Analisi Stepwise del modello lineare". Fonte: elaborazione propria.

La Figura 56 raffigura l'ultimo step dell'Analisi Stepwise, nel quale vengono evidenziate le variabili maggiormente significative. Si è proceduto, quindi, alla stima della regressione utilizzando soltanto le variabili individuate dalla Stepwise (Fig. 57).

```

Call:
lm(formula = EXP ~ Epos + Eoa + Inc + Ecm + Esm + Ism + Over +
    Fem, data = TOUCHPOINTS)

Residuals:
    Min       1Q   Median       3Q      Max
-404.27 -106.47   -5.02    87.91   410.55

Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   -34.19     101.53  -0.337  0.737163
Epos            24.83      14.25   1.742  0.085273 .
Eoa             24.91      15.93   1.564  0.121803
Inc             44.67      28.67   1.558  0.123069
Ecm            -37.62      14.95  -2.517  0.013819 *
Esm             60.44      17.50   3.454  0.000883 ***
Ism            -32.89      16.58  -1.984  0.050689 .
Over[T.1]     152.24      49.38   3.083  0.002800 **
Fem[T.1]     -109.98      35.60  -3.089  0.002750 **
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

```

Residual standard error: 150 on 81 degrees of freedom
Multiple R-squared:  0.3663,    Adjusted R-squared:  0.3037
F-statistic: 5.853 on 8 and 81 DF,  p-value: 0.000006759

```

Figura 57. “Stima del modello lineare derivante dall’Analisi Stepwise”. Fonte: elaborazione propria.

Figura 57: rispetto alla stima precedente (Fig. 55), notiamo un numero di variabili esplicative molto inferiore; questo ha comportato una inevitabile diminuzione del valore di  $R^2$ , ma anche un miglioramento del valore di R-Adjusted.

Il valore di  $R^2$  rappresenta indica che il modello spiega il 36,63% della variabilità della variabile risposta. Mentre il miglioramento di R-Adjusted dimostra quanto il modello sia migliorato in termini di capacità predittiva. Il trade-off tra  $R^2$  e R-Adjusted in questo caso è giustificato, in quanto è risultato opportuno eliminare l’elevato numero di variabili non significative, riducendo la complessità del modello.

I valori relativi alla Statistica F e alla sua significatività sono nettamente migliorati, con il p-value che tende a zero. Questo indica che almeno uno dei regressori è sicuramente significativo.

Complessivamente, soltanto due variabili sembrano non significative, Eoa e Inc, che tuttavia hanno p-value di poco superiore rispetto alla soglia del 10%.

Per quanto riguarda l'interpretazione numerica dei coefficienti, per esempio, possiamo affermare che appartenere alla categoria Over 30 comporta un aumento in media di 152,24€ della Spesa in vestiario, ferme restando le altre variabili.

Il modello, rinominato "Modello 1", sembra essere di buona qualità. Tuttavia, al fine di indagare possibili miglioramenti, si è deciso di valutare l'inserimento di alcune trasformazioni all'interno del modello.

```
Call:
lm(formula = LogEXP ~ Inc + Eoa + Epos + Esm + Ecm + Ism + Over +
    Fem, data = TOUCHPOINTS)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-1.16636 -0.14227  0.04278  0.19301  0.51191
```

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  2.17704    0.23791   9.151 4.44e-14 ***
Inc           0.03832    0.06452   0.594 0.55422
Eoa           0.03381    0.03545   0.954 0.34319
Epos          0.01736    0.03183   0.545 0.58699
Esm           0.07801    0.03924   1.988 0.05023 .
Ecm          -0.09764    0.03327  -2.935 0.00436 **
Ism          -0.04864    0.03710  -1.311 0.19362
Over[T.1]    0.14196    0.11152   1.273 0.20671
Fem[T.1]    -0.18998    0.07923  -2.398 0.01882 *
```

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 0.3338 on 80 degrees of freedom
Multiple R-squared:  0.225,    Adjusted R-squared:  0.1475
F-statistic: 2.903 on 8 and 80 DF,  p-value: 0.006803
```

Figura 58. "Stima del modello con EXP logaritmica". Fonte: elaborazione propria.

Figura 58: essendo la Spesa una variabile positiva per 89 osservazioni su 90 (si è persa l'osservazione con spesa pari a zero), si è indagato come il modello reagisse a una trasformazione logaritmica di EXP. Tuttavia, la stima del modello restituisce risultati peggiori sotto qualsiasi aspetto: R<sup>2</sup>, R-Adjusted, Statistica F e significatività delle variabili sono peggiorati.

In seguito, si è ritenuto opportuno inserire nel modello l'interazione tra Esm e Ism; si è sospettato che queste variabili potessero avere un effetto combinato, essendo entrambe percezioni che il cliente ha relativamente ai social media.

```
Call:
lm(formula = EXP ~ Epos + Eoa + Inc + Ecm + Esm + Ism + Over +
    Fem + IntSm, data = TOUCHPOINTS)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-436.87 -105.18   -1.36    85.14   405.87
```

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  -180.30     141.01  -1.279  0.20472
Epos           26.09      14.17   1.840  0.06943 .
Eoa            21.17      16.02   1.322  0.19003
Inc            50.19      28.70   1.749  0.08415 .
Ecm           -36.57      14.86  -2.461  0.01599 *
Esm            100.27      32.01   3.133  0.00242 **
Ism            26.84      43.54   0.616  0.53939
Over[T.1]     170.37      50.52   3.372  0.00115 **
Fem[T.1]     -120.27      36.02  -3.339  0.00128 **
IntSm         -15.82      10.68  -1.482  0.14237
```

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 148.9 on 80 degrees of freedom
Multiple R-squared:  0.3832,    Adjusted R-squared:  0.3138
F-statistic: 5.523 on 9 and 80 DF,  p-value: 0.000006804
```

Figura 59. “Stima del modello con interazione tra Esm e Ism”. Fonte: elaborazione propria.

La Figura 59 mostra la stima del modello comprensivo di interazione tra Esm e Ism. Tuttavia, l’interazione (IntSm) risulta non significativa, avendo p-value pari a 0,14 e quindi superiore alla soglia di 0,05.

Constatato che l’introduzione di trasformazioni e interazioni non fosse utile al fine di migliorare il modello, si è deciso di valutare la bontà della previsione del Modello 1 (Fig. 57).

È stata utilizzata la funzione predict() di R, che ha fornito le stime predette per le osservazioni presenti nel campione (Fig. 60).

```
Rcmdr> predict(LinearModel.15)
      1      2      3      4      5      6      7
419.270151 377.248967 304.847924 192.371394  2.620138 261.346984 357.149838
      8      9     10     11     12     13     14
349.980908 462.054463 243.746054 151.550593 248.600686 354.633500 353.596825
      15     16     17     18     19     20     21
329.679739 259.454624 389.452815 374.347825 281.568060 396.461261 504.628149
      22     23     24     25     26     27     28
147.280265 371.448086 242.739094 198.854784 345.730872 161.699355 188.243306
      29     30     31     32     33     34     35
589.587692 113.667770 309.642564 464.772841 333.748027 311.191973 361.378312
      36     37     38     39     40     41     42
171.264918 251.319064  71.235025 342.005534  88.171559 216.982206 233.878320
      43     44     45     46     47     48     49
171.306772 394.991944 301.969361 303.378221 193.197026 379.423460 256.393296
      50     51     52     53     54     55     56
219.700583 184.939905 119.730073  73.913729 256.534206 138.943802 211.725209
      57     58     59     60     61     62     63
212.047480 271.801563 206.400647 184.094924 198.937058 188.867283 289.495442
      64     65     66     67     68     69     70
272.015024 238.872459 328.604825 309.038160 166.493995 202.300557 236.637117
      71     72     73     74     75     76     77
108.935084 280.138057 295.797637 261.802159 162.960556 285.978194 460.967410
      78     79     80     81     82     83     84
174.166061 186.148906 189.551780 335.813131 221.109908 188.523754 258.508094
      85     86     87     88     89     90
277.499772 161.236998 611.579182 247.061262 341.392977 319.622491
```

Figura 60. "Stime predette sulla base del Modello 1". Fonte: elaborazione propria.

Ottenute le previsioni, è stato possibile calcolare il Mean Absolute Error (MAE) e il Root Mean Squared Error (RMSE) riferiti al Modello 1, due metriche chiave per valutare la bontà della previsione. Il MAE esprime in termini assoluti quanto i valori predetti si discostano dai valori osservati. Un MAE più basso indica un modello che, in media, commette errori di previsione più piccoli (Fig. 61).

```
Rcmdr> MAE <- mean(abs(TOUCHPOINTS$EXP - yprevisto))

Rcmdr> print(MAE)
[1] 113.5996
```

Figura 61. "MAE del Modello 1". Fonte: elaborazione propria.

RMSE, invece, considera l'impatto degli errori al quadrato, dando maggiore peso agli errori più grandi. Anche in questo caso, un RMSE più basso indica un modello più preciso (Fig. 62).

```
Rcmdr> RMSE <- sqrt(mean((TOUCHPOINTS$EXP - yprevisto)^2))

Rcmdr> print(RMSE)
[1] 142.2966
```

Figura 62. "RMSE del Modello 1". Fonte: elaborazione propria.

Questi dati indicano che il modello commette in media errori piuttosto consistenti; interpretando il MAE, ad esempio, notiamo che i valori predetti si discostano in media di 113,60 € dai valori osservati. Paragonati alla media della Spesa, che è pari a 266,80 €, gli errori risultano piuttosto significativi.

Di conseguenza, si è deciso di indagare la presenza di HLP (Punti di Leva) cattivi all'interno del dataset, che potessero compromettere il funzionamento del modello. Ci si è serviti di alcuni test diagnostici, tra cui la visualizzazione dell'Influence Plot (Fig. 63). Questo grafico raffigura le osservazioni con circonferenze di dimensione e colore differenti. Le osservazioni rappresentano criticità quando sono posizionate eccessivamente in alto, in basso o a destra nel grafico; in tal caso, si parla di punti di leva cattivi, ed è opportuno eliminarli dal dataset.

Come evidenziato dalla Figura 63, l'osservazione numero 1 rappresenta un punto di leva cattivo; di conseguenza, tale osservazione è stata eliminata dal dataset.

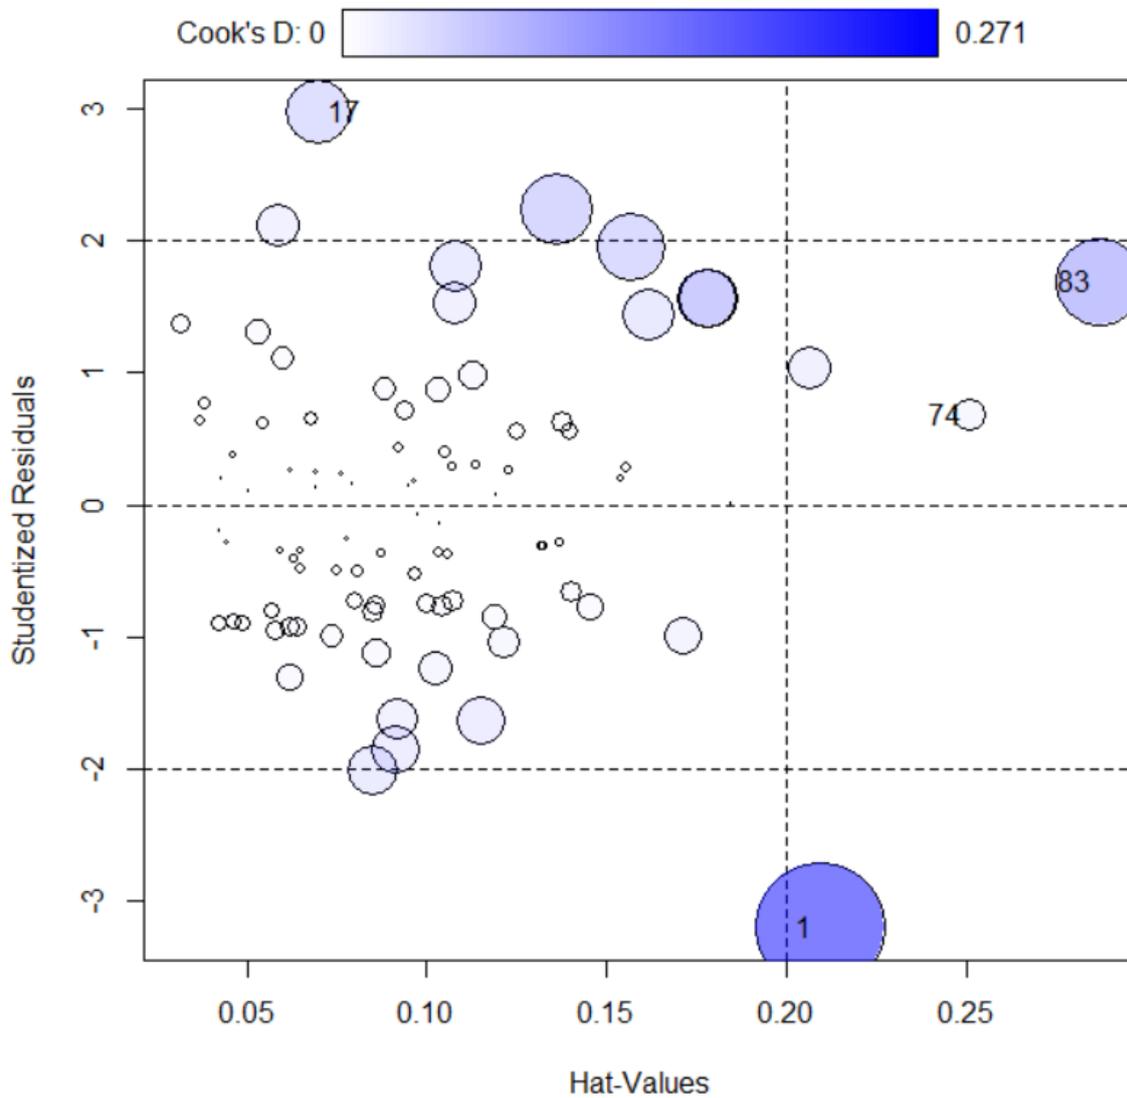


Figura 63. "Influence Plot n.1". Fonte: elaborazione propria.

Eliminata la leva cattiva, si è andato a ripetere il procedimento altre due volte, in quanto le osservazioni numero 82 e 16 (che nella Figura 63 erano la 83 e la 17) continuavano a risultare HLP cattivi (Fig. 64) (Fig. 65).

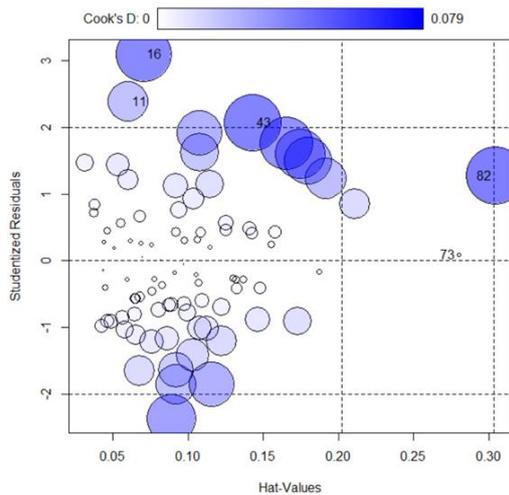


Figura 64. "Influence Plot n.2". Fonte: elaborazione propria.

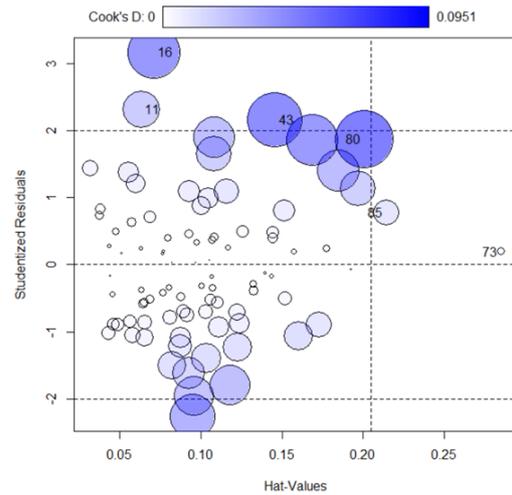


Figura 65. "Influence Plot n.3". Fonte: elaborazione propria.

Eliminate le leve cattive dal dataset, si è stimato nuovamente il modello (Fig. 66), per valutare se restituisse risultati migliori rispetto a quelli ottenuti dalla stima precedente (Fig. 57). Effettivamente, i risultati sono migliori sotto ogni punto di vista:

- $R^2$  è aumentato; ora il modello spiega una porzione pari al 44,07% della variabilità della variabile risposta.
- R-Adjusted è aumentato, dimostrando quanto la capacità predittiva sia migliorata.
- Il valore della Statistica F è aumentato, mentre il relativo p-value è ulteriormente diminuito; questo conferma la presenza di almeno un regressore significativo.
- La significatività delle singole variabili è migliorata, tranne nel caso di Epos.

```
Call:
lm(formula = EXP ~ Epos + Esm + Ecm + Ism + Over + Fem + Inc +
    Eoa, data = Touchpoint)
```

```
Residuals:
    Min       1Q   Median       3Q      Max
-280.561  -92.277   -9.247   76.602  311.072
```

```
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)   -63.98      94.32  -0.678  0.499555
Epos           17.19      13.18   1.304  0.196098
Esm            63.27      16.15   3.917  0.000191 ***
Ecm           -41.23      14.30  -2.884  0.005073 **
Ism           -36.89      15.75  -2.343  0.021705 *
Over[T.1]     200.50      45.99   4.360  0.0000393 ***
Fem[T.1]     -79.14      32.54  -2.432  0.017296 *
Inc            50.25      28.40   1.769  0.080768 .
Eoa            30.57      14.45   2.116  0.037560 *
```

```
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
Residual standard error: 134.1 on 78 degrees of freedom
Multiple R-squared:  0.4407,    Adjusted R-squared:  0.3834
F-statistic: 7.683 on 8 and 78 DF,  p-value: 0.0000001554
```

Figura 66. “Stima del Modello 1 esclusi gli HLP cattivi”. Fonte: elaborazione propria.

Si è deciso di valutare la bontà della previsione anche in questo caso, utilizzando prima la funziona predict (Fig. 67) e in seguito il calcolo di MAE e RMSE.

```
Rcmdr> predict(LinearModel.18)
      1      2      3      4      5      6      7      8
339.89094 296.85402 183.18117 -36.32648 257.83795 327.04315 358.77868 446.44456
      9     10     11     12     13     14     15     16
216.07835 145.10511 238.92783 349.74024 374.48255 314.04296 281.19598 364.29696
      17     18     19     20     21     22     23     24
289.19409 372.29507 488.16867 126.38527 355.48228 231.59958 182.57292 346.13014
      25     26     27     28     29     30     31     32
135.56386 189.04097 648.26841 124.09457 308.36003 455.63539 300.87488 291.83969
      33     34     35     36     37     38     39     40
340.63424 159.66184 248.11867  65.14603 352.46053  89.39641 225.71614 233.11823
      41     42     43     44     45     46     47     48
164.79060 402.19499 260.90402 300.56118 189.53727 361.80042 278.84283 234.90697
      49     50     51     52     53     54     55     56
164.14439 100.00550  77.80556 240.11722 120.69009 228.58883 189.48707 270.97706
      57     58     59     60     61     62     63     64
258.62454 188.82947 204.54996 189.70192 317.17045 305.63871 250.46281 330.53444
      65     66     67     68     69     70     71     72
302.19428 147.06987 165.76524 259.15735 119.75343 298.17342 307.02736 320.91883
      73     74     75     76     77     78     79     80
189.00446 231.41944 448.58620 135.25582 180.51108 209.24725 366.31980 193.66357
      81     82     83     84     85     86     87
218.41925 302.36217 149.94256 637.75818 269.94143 354.57332 339.73753
```

Figura 67. “Stime predette esclusi gli HLP cattivi”. Fonte: elaborazione propria.

```
Rcmdr> MAE <- mean(abs(Touchpoint$EXP - yprevisto))
```

```
Rcmdr> print(MAE)
[1] 103.0782
```

Figura 68. "MAE del Modello 1 esclusi gli HLP cattivi". Fonte: elaborazione propria.

```
Rcmdr> RMSE <- sqrt(mean((Touchpoint$EXP - yprevisto)^2))
```

```
Rcmdr> print(RMSE)
[1] 126.9808
```

Figura 69. "RMSE del Modello 1 esclusi gli HLP cattivi". Fonte: elaborazione propria.

Notiamo che MAE (Fig. 68) e RMSE (Fig. 69) sono diminuiti, a conferma del miglioramento della capacità predittiva del modello. In questo caso, i valori predetti si discostano in media di 103,08 € dai valori osservati, rispetto ai 113,60€ precedentemente registrati.

Al fine di indagare l'eventuale miglioramento della qualità del modello, si è calcolato anche l'Akaike Information Criterion. Un AIC più basso indica un modello che si adatta meglio ai dati osservati, bilanciando la bontà dell'adattamento e la complessità del modello.

La Figura 70 mostra il valore di AIC per la stima iniziale, che comprendeva gli HLP cattivi.

```
Rcmdr> AIC(LinearModel.15)
[1] 1167.833
```

Figura 70. "AIC della stima inclusi gli HLP cattivi". Fonte: elaborazione propria.

La Figura 71 mostra il valore di AIC per la stima esclusi gli HLP cattivi. La diminuzione del valore di AIC dimostra il miglioramento della qualità del modello.

```
Rcmdr> AIC(LinearModel.18)
[1] 1109.758
```

Figura 71. "AIC della stima esclusi gli HLP cattivi". Fonte: elaborazione propria.

Infine, prima di procedere con l'interpretazione delle stime del modello, si è ritenuto opportuno indagare l'eventuale presenza di multicollinearità tra le variabili indipendenti del modello. Si è, quindi, calcolato il Variance Inflation Factor, che consente di misurare quanto una variabile sia correlata linearmente con le altre.

Valori di VIF elevati indicano una possibile multicollinearità, che potrebbe compromettere la stabilità delle stime dei coefficienti di regressione. Adottiamo come soglia utile a determinare la presenza di eccessiva multicollinearità un valore di VIF pari a 5. Come evidenziato dalla Figura 72, le variabili non presentano eccessiva multicollinearità; il modello potrà quindi essere accettato e interpretato.

```
Rcmdr> influencePlot(LinearModel.18, id=list(method="noteworthy", n=2))
      StudRes      Hat      CookD
11  2.4742573  0.0634033  0.043210108
42  2.4848342  0.1483461  0.112065028
72  0.2549268  0.2850853  0.002914383
79  1.9856760  0.2008834  0.106126499
84  0.9442157  0.2153760  0.027229521
```

```
Rcmdr> vif(LinearModel.18)
      Epos      Esm      Ecm      Ism      Over      Fem      Inc      Eoa
1.370330  2.055264  1.144389  1.731791  1.381297  1.278705  1.158172  1.548451
```

Figura 72. "VIF del Modello 1 esclusi gli HLP cattivi". Fonte: elaborazione propria.

### 3.4.3. INTERPRETAZIONE DEI RISULTATI: VARIABILE EXP

Il modello di regressione lineare proposto mira a spiegare la variabile Spesa, che rappresenta la spesa totale in euro sostenuta dai rispondenti negli ultimi tre mesi per l'acquisto di articoli di vestiario. Di seguito, analizziamo l'effetto di ciascuna variabile esplicativa sui comportamenti di EXP, interpretando il segno e la significatività dei relativi coefficienti. L'unico coefficiente che non interpreteremo è quello relativo all'intercetta. Oltre a non essere un valore statisticamente significativo, risulta anche di non agevole interpretazione. Infatti, esso esprime valore atteso della spesa nel caso in cui tutti i regressori assumano simultaneamente valore zero, che è un'eventualità che nel dataset non si realizza mai in quanto tutte le variabili in scala Likert presentano valore minimo pari ad 1.

#### 1) Esposizione ai POS

Il coefficiente associato all'esposizione ai negozi fisici non risulta essere significativo. In questo caso, quindi, non possiamo addentrarci in interpretazioni.

#### 2) Esposizione ai Social Media

La variabile relativa all'esposizione ai social media ha ottenuto un coefficiente positivo e significativo, suggerendo che a un aumento di 1 punto in scala Likert dell'esposizione a questo canale, è associato un aumento in media della spesa per abbigliamento pari a 63,27€. Questo risultato riflette l'importanza crescente dei social media come canale di

marketing, dove i consumatori non solo interagiscono con i brand, ma vengono influenzati da influencer, pubblicità mirata e UGC. I social media forniscono un'ampia gamma di stimoli visivi e promozionali che stimolano il desiderio di acquisto, favorendo l'aumento della spesa. L'effetto positivo dei social media sulla spesa è coerente con i risultati ottenuti da Zhang et al. (2018); in quel caso, i ricercatori avevano evidenziato la capacità dei social di aumentare le vendite dei prodotti e, di conseguenza, la spesa dei consumatori.

### 3) Esposizione ai Media Classici

L'esposizione ai media classici (TV, manifesti, stampa...) ha un coefficiente negativo e significativo, suggerendo che a un aumento di 1 punto in scala Likert dell'esposizione a questo canale, è associata una diminuzione in media della spesa per abbigliamento pari a 41,23€. Questo risultato può essere interpretato alla luce del fatto che i media tradizionali, pur essendo ancora rilevanti, potrebbero non avere la stessa efficacia persuasiva dei canali digitali. Nel caso della pubblicità televisiva, questa potrebbe addirittura risultare disturbante se visualizzata frequentemente, causando una riduzione della spesa. Inoltre, i media classici forniscono messaggi unidirezionali, senza possibilità di interazione immediata, limitando la capacità di stimolare immediatamente le decisioni di acquisto. Come visto nel capitolo di analisi della letteratura, effetti negativi dei media classici sulla spesa sono stati evidenziati anche da Zimmermann et al. (2022). Nello specifico, i ricercatori hanno dimostrato che l'aumento dell'esposizione alla cartellonistica, sia digitale che non digitale, è in grado di far diminuire la spesa da parte dei consumatori.

### 4) Dummy Over

La dummy che indica i rispondenti di età superiore ai 30 anni ha ottenuto un coefficiente positivo e significativo, suggerendo che gli intervistati Over 30 spendono in media 200,50€ in più rispetto ai rispondenti Gen Z. Questo può essere dovuto a diversi fattori: gli Over 30 potrebbero avere un reddito disponibile maggiore, un interesse verso l'abbigliamento di qualità superiore, oppure provvedere all'acquisto di vestiario per i propri familiari.

### 5) Esposizione alla Pubblicità Online

Il coefficiente positivo e significativo associato all'esposizione alla pubblicità online indica che a un aumento di 1 punto in scala Likert dell'esposizione a questo canale, è

associato un aumento in media della spesa per abbigliamento pari a 30,57€. Questo risultato riflette l'efficacia degli strumenti pubblicitari digitali, come banner, SEA e contenuti sponsorizzati, che consentono alle aziende di raggiungere il target in modo mirato e personalizzato. La pubblicità online è particolarmente efficace grazie all'utilizzo di tecnologie di retargeting, che consentono di riproporre annunci basati sulle preferenze e sui comportamenti passati dei consumatori, incrementando così le possibilità di acquisto e di spesa. Effetti positivi della pubblicità online sono stati dimostrati anche da Zhao et al. (2020); i ricercatori hanno evidenziato la capacità dei paid media di aumentare la spesa da parte dei consumatori.

#### 6) Reddito

Come atteso, il reddito dei rispondenti ha un coefficiente positivo e significativo, indicando che a un aumento di 1 punto in scala Likert della variabile Reddito, è associato un aumento in media della spesa per abbigliamento pari a 50,25€. Questo risultato è coerente con la teoria economica tradizionale, secondo la quale un aumento del reddito disponibile aumenta la propensione del consumatore a spendere, in particolare per i beni "normali" come l'abbigliamento. Dove per beni "normali" si intendono prodotti per i quali la domanda aumenta quando il reddito del consumatore aumenta.

#### 7) Dummy Fem

Il coefficiente negativo e significativo associato alla dummy che identifica i rispondenti di sesso femminile suggerisce che le donne, a parità di altre condizioni, tendono a spendere in media 79,14€ in meno rispetto agli uomini in articoli di abbigliamento. Non possiamo dare un'interpretazione precisa di questo effetto, tuttavia, potrebbe riflettere una maggiore propensione delle donne a ricercare sconti o modalità di acquisto più convenienti, a fronte di una spesa totale minore.

#### 8) Influenza dei Social Media

L'influenza dei social media, misurata attraverso la percezione dei consumatori riguardo l'effetto che questi canali hanno sulle loro decisioni, ha un coefficiente negativo e significativo. Questo risultato è interessante, poiché suggerisce che, nonostante l'esposizione ai social media favorisca un aumento della spesa (come evidenziato dal coefficiente positivo per l'esposizione ai social), la percezione di essere influenzati negativamente dai social media potrebbe indurre una reazione contraria. Potrebbe trattarsi

di un fenomeno di "resistenza psicologica": i consumatori, potrebbero percepire in modo negativo l'essere influenzati, e reagire riducendo la spesa. Tuttavia, non possiamo escludere che il risultato negativo associato a Ism sia influenzato dalla variabile Età. Infatti, dall'analisi dei dati emerge che i rispondenti appartenenti alla classe Gen Z presentano una media di Ism notevolmente superiore (3,71) rispetto a quella degli Over 30 (1,73). Questo dato suggerisce che i giovani, in particolare la Gen Z, siano più suscettibili all'influenza dei social media rispetto agli individui più maturi. Allo stesso tempo, ai rispondenti appartenenti alla Gen Z è associata una spesa media significativamente inferiore rispetto agli Over 30. Pertanto, non è possibile escludere che la riduzione complessiva della spesa stimata per gli individui più sensibili all'influenza dei social media possa anche dipendere da una parziale correlazione tra la variabile Ism e l'appartenenza alla Gen Z (che si dichiara appunto mediamente più influenzabile e tende a spendere di meno).

#### 3.4.4. ANALISI BIVARIATA: VARIABILE PUR

Nei seguenti paragrafi, indagheremo l'applicabilità di modello in grado di spiegare le tendenze di acquisto negli store fisici. Nel presente paragrafo, in particolare, ci dedicheremo all'esplorazione delle relazioni bivariate tra la variabile dicotomica Pur e le altre variabili individuate, al fine di comprendere le possibili interazioni e correlazioni. Inizieremo a valutare come si comporta Pur, che ricordiamo assumere valore 1 nel caso in cui si sia effettuato almeno 1 acquisto in negozi fisici di vestiario negli ultimi 3 mesi, rispetto alle variabili quantitative individuate.

Ci serviremo dei box-plot, utili a individuare eventuali correlazioni tra una variabile qualitativa (Pur) e una quantitativa.

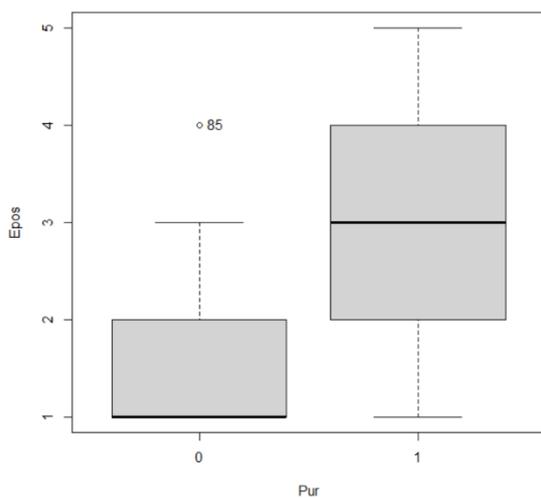


Figura 73. "Scatterplot di Epos in funzione di Pur".  
Fonte: elaborazione propria.

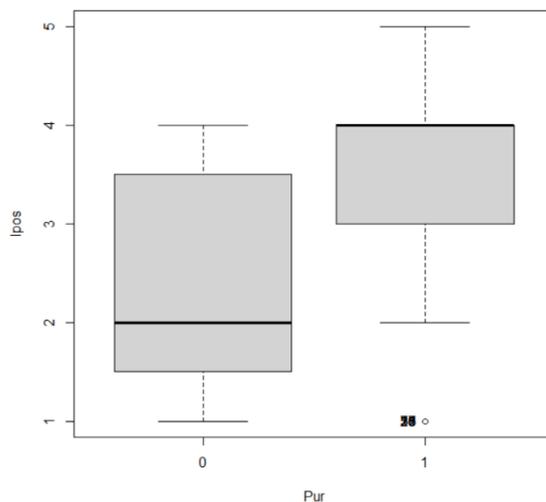


Figura 74. "Scatterplot di Ipos in funzione di Pur".  
Fonte: elaborazione propria.

La variabile Epos (Esposizione ai POS) sembra possa discriminare efficacemente Pur, in quanto le scatole non si sovrappongono (Fig. 73).

La variabile Ipos (Influenza dei POS) sembra possa discriminare efficacemente Pur, in quanto l'intervallo di valori incerti evidenziato dalle scatole è poco esteso (Fig. 74).

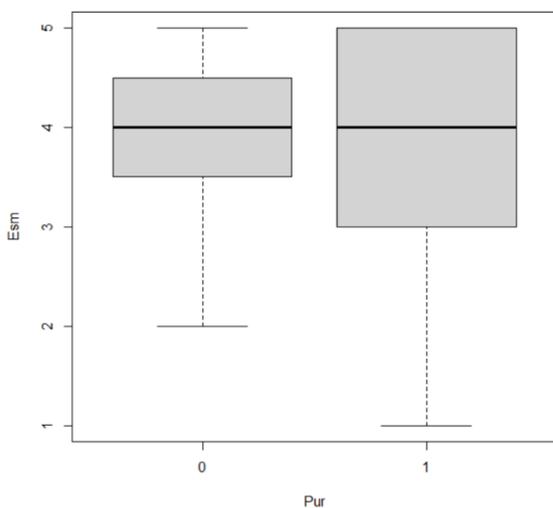


Figura 75. "Scatterplot di Esm in funzione di Pur".  
Fonte: elaborazione propria.

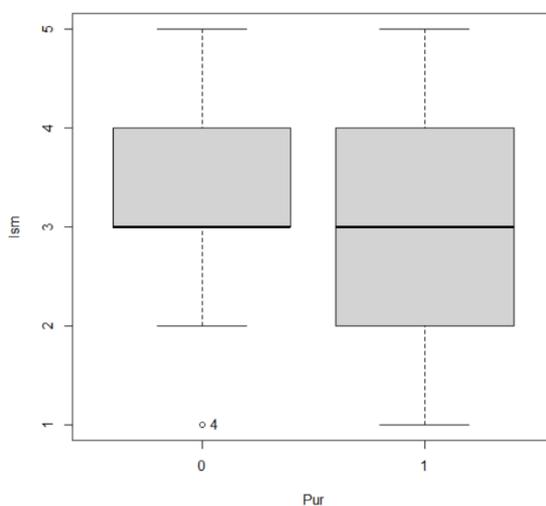


Figura 76. "Scatterplot di Ism in funzione di Pur".  
Fonte: elaborazione propria.

La variabile Esm (Esposizione ai Social) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 75).

La variabile Ism (Influenza dei Social) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 76).

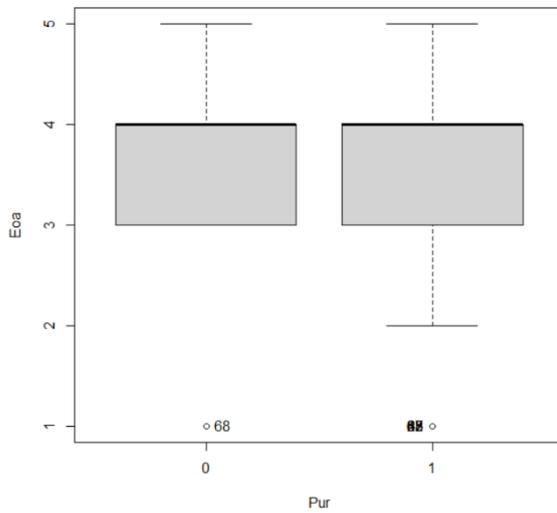


Figura 77. "Scatterplot di Eoa in funzione di Pur".  
Fonte: elaborazione propria.

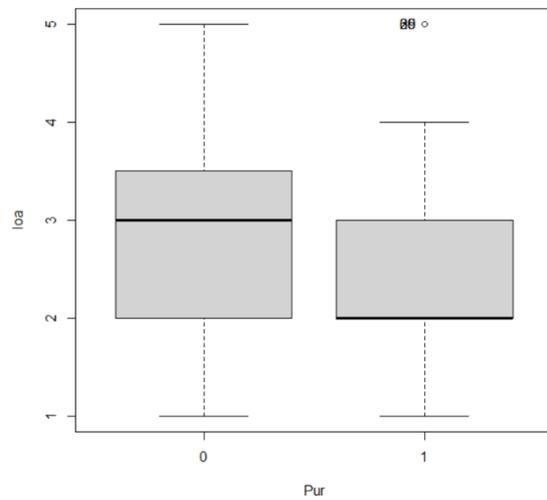


Figura 78. "Scatterplot di Ioa in funzione di Pur".  
Fonte: elaborazione propria.

La variabile Eoa (Esposizione alla pubblicità online) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 77).

La variabile Ioa (Influenza della pubblicità online) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 78).

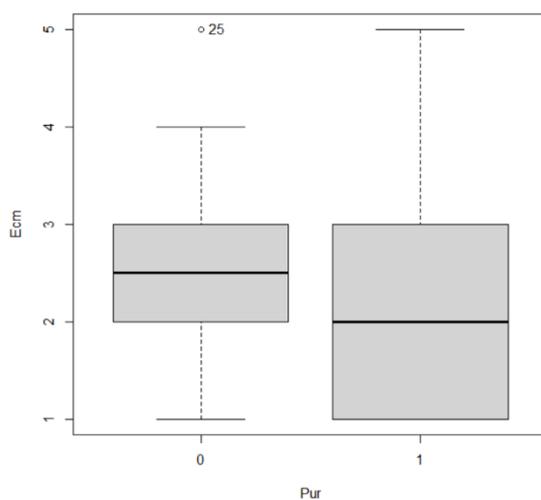


Figura 79. "Scatterplot di Ecm in funzione di Pur".  
Fonte: elaborazione propria.

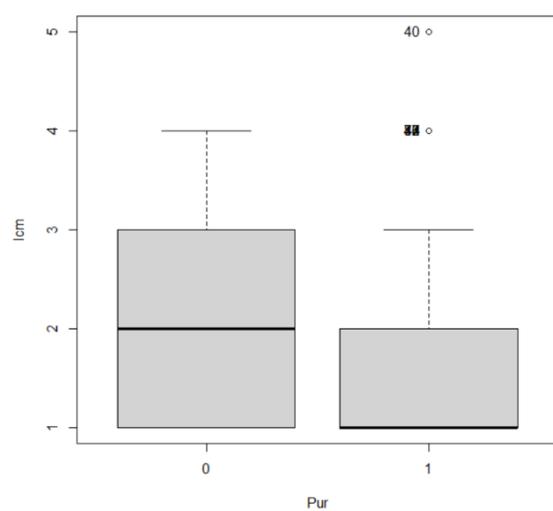


Figura 80. "Scatterplot di Icm in funzione di Pur".  
Fonte: elaborazione propria.

La variabile Ecm (Esposizione ai media classici) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 79).

La variabile Icm (Influenza dei media classici) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 80).

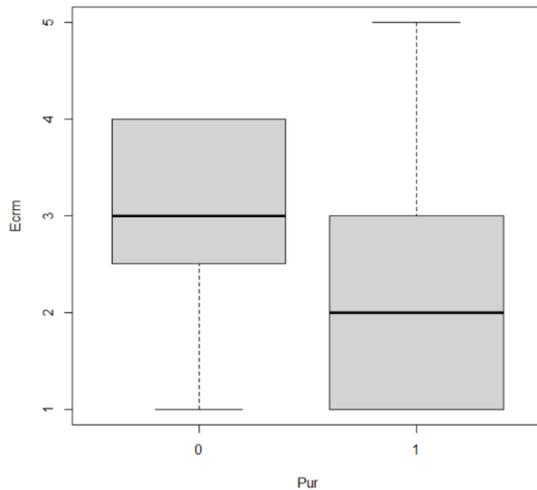


Figura 81. "Scatterplot di Ecm in funzione di Pur".  
Fonte: elaborazione propria.

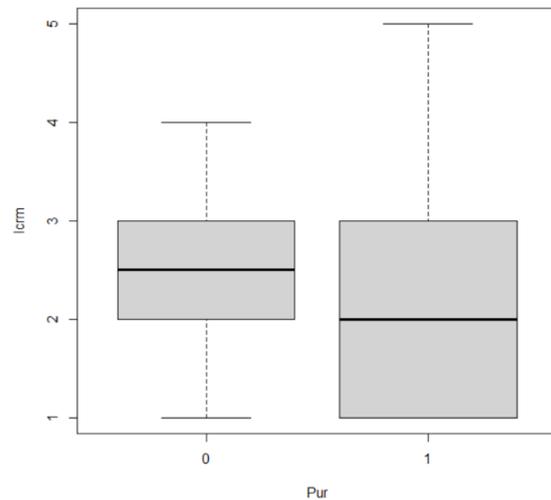


Figura 82. "Scatterplot di Icm in funzione di Pur".  
Fonte: elaborazione propria.

La variabile Ecrm (Esposizione al CRM) sembra possa moderatamente discriminare Pur, in quanto il range di valori incerti è limitato (Fig. 81).

La variabile Icrm (Influenza del CRM) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 82).

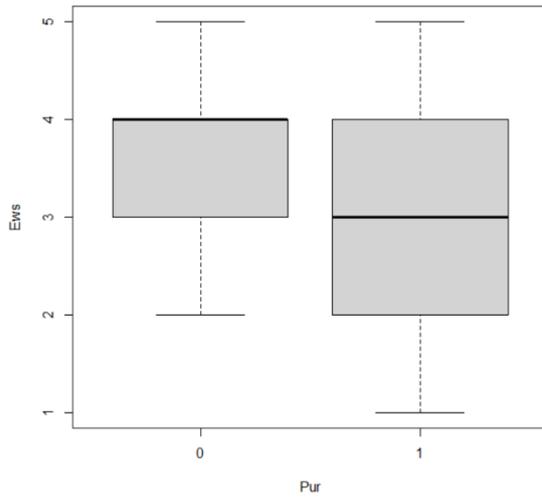


Figura 83. "Scatterplot di Ews in funzione di Pur".  
Fonte: elaborazione propria.

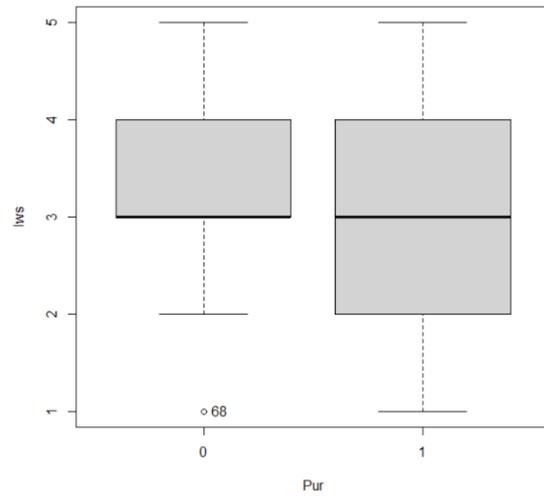


Figura 84. "Scatterplot di Iws in funzione di Pur".  
Fonte: elaborazione propria.

La variabile Ews (Esposizione ai siti web) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 83).

La variabile Iws (Influenza dei siti web) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 84).

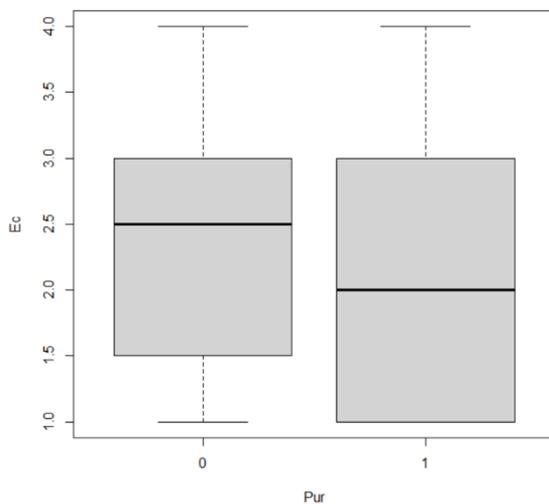


Figura 85. "Scatterplot di Ec in funzione di Pur".  
Fonte: elaborazione propria.

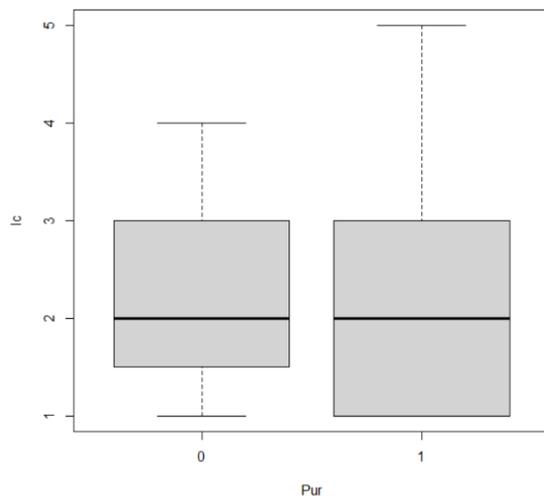


Figura 86. "Scatterplot di Ic in funzione di Pur".  
Fonte: elaborazione propria.

La variabile Ec (Esposizione alle cooperazioni) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 85).

La variabile Ic (Influenza delle cooperazioni) non sembra possa discriminare efficacemente Pur, in quanto le scatole si sovrappongono (Fig. 86).

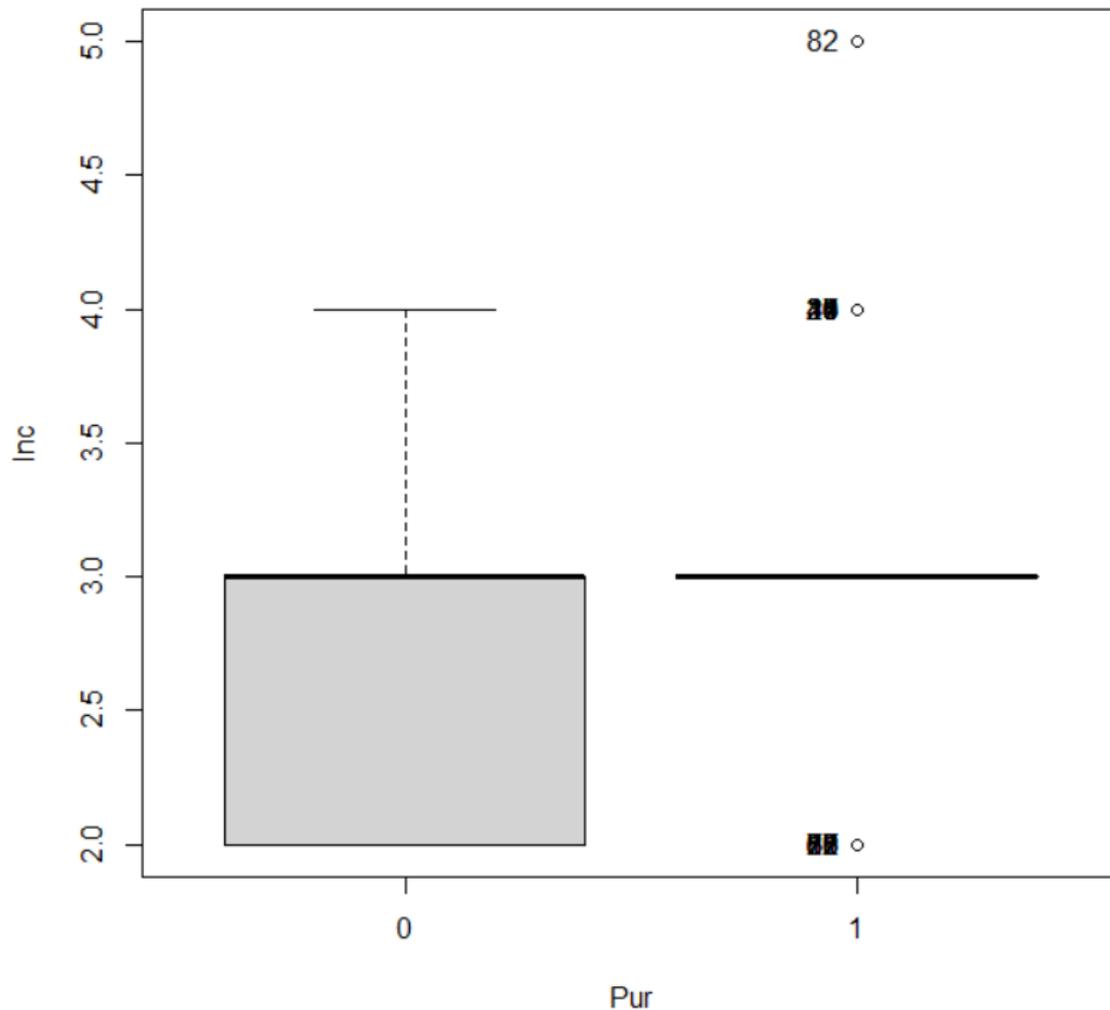


Figura 87. "Scatterplot di Inc in funzione di Pur". Fonte: elaborazione propria.

La scatola di Inc, nel caso in cui Pur assuma valore 1, si comporta in modo peculiare: si addensa totalmente sulla mediana, pari a 3 (Fig. 87). Così facendo, va a sovrapporsi alla scatola di sinistra. Di conseguenza, la variabile Inc (Reddito) non sembra possa discriminare efficacemente Pur.

Proseguiremo l'analisi valutando come si comporta Pur rispetto alle variabili qualitative. Dovendo indagare la relazione tra due variabili qualitative, ci serviremo del test del Chi-Quadrato, che consente di verificare se esista un'associazione significativa tra due variabili dicotomiche.

La Figura 88 mostra la tabella di contingenza e il test del Chi-Quadrato relativi alla relazione tra Pur e Fem. Il valore del p-value è superiore al 5%, quindi non sembra possa esserci una relazione statisticamente significativa tra queste due variabili.

Frequency table:

	Fem	
Pur	0	1
0	8	4
1	35	42

Pearson's Chi-squared test

data: .Table

X-squared = 1.8707, df = 1, p-value = 0.1714

*Figura 88. "Tabella di contingenza tra Pur e Fem". Fonte: elaborazione propria.*

La Figura 89 mostra la tabella di contingenza e il test del Chi-Quadrato relativi alla relazione tra Pur e Over. Il valore del p-value è superiore al 5%, quindi non sembra possa esserci una relazione statisticamente significativa tra queste due variabili.

Frequency table:

	Over	
Pur	0	1
0	11	1
1	63	14

Pearson's Chi-squared test

data: .Table

X-squared = 0.71858, df = 1, p-value = 0.3966

*Figura 89. "Tabella di contingenza tra Pur e Over". Fonte: elaborazione propria.*

La Figura 90 mostra la tabella di contingenza e il test del Chi-Quadrato relativi alla relazione tra Pur e Cit. Il valore del p-value è superiore al 5%, quindi non sembra possa esserci una relazione statisticamente significativa tra queste due variabili.

Frequency table:

	Cit	
Pur	0	1
0	8	4
1	61	16

Pearson's Chi-squared test

data: .Table

X-squared = 0.93919, df = 1, p-value = 0.3325

*Figura 90. "Tabella di contingenza tra Pur e Cit". Fonte: elaborazione propria.*

La Figura 91 mostra la tabella di contingenza e il test del Chi-Quadrato relativi alla relazione tra Pur e Sub. Il valore del p-value è superiore al 5%, quindi non sembra possa esserci una relazione statisticamente significativa tra queste due variabili.

Frequency table:

	Sub	
Pur	0	1
0	5	7
1	24	53

Pearson's Chi-squared test

data: .Table

X-squared = 0.52085, df = 1, p-value = 0.4705

*Figura 91. "Tabella di contingenza tra Pur e Sub". Fonte: elaborazione propria.*

### 3.4.5. APPLICAZIONE DI UN MODELLO STATISTICO: VARIABILE PUR

Nel presente paragrafo, esamineremo l'applicabilità di un modello che possa spiegare la variabile dicotomica Pur, che assume valore 1 nel caso in cui si sia effettuato almeno 1 acquisto in negozi fisici di vestiario negli ultimi 3 mesi.

Essendo Pur una variabile dicotomica, si è deciso di applicare il modello logit. Come prima cosa, si è stimato il modello contenente tutte le variabili esplicative individuate nei paragrafi precedenti, in modo da avere una panoramica generale della situazione (Fig. 92).

Si è notato che la stima restituisce risultati migliori nel caso in cui venga applicata la trasformazione logaritmica alla variabile EXP. Questo perché la Spesa assume valori

sempre positivi (tranne per 1 variabile, che viene scartata) e continui. La trasformazione logaritmica riduce l'effetto delle code, rendendo la distribuzione più simmetrica.

```
Rcmdr> summary(MLM.2, cor=FALSE, wald=TRUE)
Call:
multinom(formula = Pur ~ Cit + Ec + Ecm + Ecrm + Eoa + Epos +
          Esm + Ews + Fem + Ic + Icm + Icrm + Inc + Ioa + Ipos + Ism +
          Iws + LogEXP + Over + Sub, data = TOUCHPOINTS, trace = FALSE)
```

Coefficients:

	Values	Std. Err.	Value/SE
(Intercept)	-19.6830430	37.173729	-0.52948799
Cit[T.1]	-1.0502006	33.588167	-0.03126698
Ec	-1.2309214	2.546171	-0.48344027
Ecm	-0.7167891	2.859379	-0.25067998
Ecrm	-3.1813400	1.990260	-1.59845464
Eoa	3.2794417	2.432849	1.34798391
Epos	7.3967186	4.250889	1.74004044
Esm	-1.1031953	1.259589	-0.87583716
Ews	1.3261469	1.544304	0.85873437
Fem[T.1]	3.4915021	2.998630	1.16436593
Ic	-1.8363388	2.577019	-0.71258249
Icm	0.4051745	3.176229	0.12756462
Icrm	0.8854711	1.715502	0.51615848
Inc	1.6679085	2.202096	0.75741855
Ioa	0.0264927	1.234929	0.02145281
Ipos	0.7500055	1.801006	0.41643709
Ism	-0.8296655	1.338160	-0.62000452
Iws	-5.9894975	4.200358	-1.42594944
LogEXP	9.9631233	7.187307	1.38621090
Over [T.1]	2.8638860	14.524978	0.19716974
Sub [T.1]	-0.8054274	33.467928	-0.02406565

Residual Deviance: 20.55943  
AIC: 62.55943

Figura 92. "Stima del modello logit comprensivo di tutte le variabili". Fonte: elaborazione propria.

Figura 92: la stima evidenzia un elevato numero di variabili non significative, in quanto riportano valori di value/SE piuttosto bassi. Del resto, l'analisi bivariata segnalava diverse variabili di dubbio potere esplicativo.

Anche in questo caso, al fine di individuare il sottoinsieme ottimale di variabili predittive, si è deciso di applicare al modello la tecnica Stepwise backward basata sul criterio AIC. In questo modo, è stato possibile eliminare le variabili con scarso impatto sulla variabile Pur, migliorando l'accuratezza e l'efficienza del modello.

```

Step:  AIC=40.4
Pur ~ Ecrm + Eoa + Epos + Fem + Ic + Iws + LogEXP

      Df   AIC
<none>  40.397
- Eoa   1 40.552
- Fem   1 41.732
- Ic    1 44.527
- Iws   1 45.601
- LogEXP 1 49.271
- Ecrm  1 50.194
- Epos  1 74.820
Call:
multinom(formula = Pur ~ Ecrm + Eoa + Epos + Fem + Ic + Iws +
  LogEXP, data = TOUCHPOINTS, trace = FALSE)

```

```

Coefficients:
(Intercept)      Ecrm      Eoa      Epos      Fem[T.1]      Ic      Iws      LogEXP
-12.755833  -2.420185   1.039765   5.177164   3.121909  -2.060729  -2.241514   7.599580

```

```

Residual Deviance: 24.3973
AIC: 40.3973

```

Figura 93. “Ultimo step dell’Analisi Stepwise del modello logit”. Fonte: elaborazione propria.

La Figura 93 raffigura l’ultimo step dell’Analisi Stepwise, nel quale vengono evidenziate le variabili maggiormente significative. Si è proceduto, quindi, alla stima del modello logit utilizzando soltanto le variabili individuate dalla Stepwise (Fig. 94).

```

Rcmdr> MLM.3 <- multinom(Pur ~ Eoa + Fem + Ic + Iws + LogEXP + Ecrm + Epos, data=TOUCHPOINTS,
Rcmdr+   trace=FALSE)

Rcmdr> summary(MLM.3, cor=FALSE, wald=TRUE)
Call:
multinom(formula = Pur ~ Eoa + Fem + Ic + Iws + LogEXP + Ecrm +
  Epos, data = TOUCHPOINTS, trace = FALSE)

Coefficients:
      Values Std. Err. Value/SE
(Intercept) -12.755833  5.7959789  -2.200807
Eoa          1.039765  0.7676691   1.354444
Fem[T.1]    3.121909  2.0023114   1.559153
Ic          -2.060729  1.0307908  -1.999173
Iws         -2.241514  1.1500709  -1.949023
LogEXP      7.599580  3.2235070   2.357550
Ecrm        -2.420185  1.0005001  -2.418975
Epos        5.177164  1.7848532   2.900611

Residual Deviance: 24.3973
AIC: 40.3973

```

Figura 94. “Stima del modello logit derivante dall’Analisi Stepwise”. Fonte: elaborazione propria.

```
Rcmdr> stargazer(MLM.3, type="text")
=====
Dependent variable:
-----
Pur
-----
Eoa                1.040
                   (0.768)
Fem[T.1]          3.122
                   (2.002)
Ic                -2.061**
                   (1.031)
Iws               -2.242*
                   (1.150)
LogEXP            7.600**
                   (3.224)
Ecrm              -2.420**
                   (1.001)
Epos              5.177***
                   (1.785)
Constant          -12.756**
                   (5.796)
-----
Akaike Inf. Crit.    40.397
=====
Note:                *p<0.1; **p<0.05; ***p<0.01
```

Figura 95. “Stargazer del Modello A”. Fonte: elaborazione propria.

Figura 94: il modello, rinominato “Modello A”, sembra essere di buona qualità. Notiamo, infatti, una evidente riduzione del valore di AIC.

Soltanto due variabili sembrano non significative, Eoa e Fem, poiché presentano value/SE piuttosto basso. Ciò viene confermato dallo specchio offerto dalla funzione Stargazer (Fig. 95).

Per quanto riguarda l’interpretazione numerica dei coefficienti, per esempio, possiamo affermare che un incremento unitario nel punteggio relativo all’esposizione al CRM rende meno probabile che il rispondente abbia effettuato almeno 1 acquisto in POS di vestiario negli ultimi 3 mesi, ferme restando le altre variabili.

Siccome l’introduzione di trasformazioni (quadrati, radici, logaritmi) non comporta miglioramenti nel modello, si è deciso di valutare la bontà della previsione del Modello A. È stata applicata la funzione predict() (Fig. 96).

```
Rcmdr> predict(MLM.9)
[1] 1 1 0 0 1 1 1 1 1 1 1 1 1 1 0 1 1 1 1 1 0 1 0 0 1 1 1 1 1 1 1 1 1 1 1 1 1 1
[39] 1 1 1 1 1 1 1 1 1 1 1 1 0 1 1 1 1 1 1 1 1 1 1 1 0 1 1 1 1 1 0 1 1 0 1 1 1
[77] 1 1 1 1 1 1 1 1 1 1 1 1 1
Levels: 0 1
```

Figura 96. “Stime predette sulla base del Modello A”. Fonte: elaborazione propria.

Ottenute le previsioni, è stato possibile calcolare la Matrice di Confusione (Fig. 97). Questa include quattro elementi principali: i veri positivi, i falsi positivi, i veri negativi e i falsi negativi. Questi valori aiutano a calcolare metriche come l'accuratezza e il misclassification error, fondamentali per misurare la qualità delle previsioni del modello.

```
Rcmdr> table(TOUCHPOINTS$Pur, yprevisto)
      yprevisto
      0  1
0     8  4
1     2 75
```

Figura 97. "Matrice di confusione del Modello A". Fonte: elaborazione propria.

Dai risultati della Matrice di Confusione, è stato possibile calcolare le seguenti metriche:

- $FPR = FP/negativi = 4/12 = 0,33$ . La probabilità di errore di I tipo è pari al 33%. Il livello di specificità del modello è buono poiché questa probabilità è piuttosto contenuta.
- $TPR = TP/positivi = 75/77 = 0,97$ . Questo risultato, se sottratto a 1, restituisce la probabilità di errore di II tipo, pari in questo caso al 3%. Essendo il TPR maggiore del FPR, possiamo affermare che il modello discrimina efficacemente.
- $Misclassification\ Error = falsi/totali = 6/89 = 0,07$ . Lo sottraggo a 1 per trovare l'accuratezza.
- $Accuracy = 1-0,07 = 0,93$ . Il modello ha accuratezza pari al 93%, quindi la curva ROC si troverà sopra la diagonale.

I risultati delle metriche sono ottimi, il modello ha una buona capacità predittiva sul campione oggetto dell'analisi.

Tuttavia, la stima del Modello A (Fig. 94) suggeriva che Eoa e Fem fossero non significative; si è deciso di stimare il modello escludendo le due variabili, al fine di valutare se ci fosse margine di miglioramento rispetto al Modello A. Il nuovo modello è stato rinominato Modello B (Fig. 98).

```
Rcmdr> summary(MLM.13, cor=FALSE, wald=TRUE)
Call:
multinom(formula = Pur ~ Ic + Iws + LogEXP + Ecrm + Epos, data = TOUCHPOINTS,
          trace = FALSE)
```

Coefficients:

	Values	Std. Err.	Value/SE
(Intercept)	-7.4249604	4.0866903	-1.816864
Ic	-1.0735002	0.6349225	-1.690758
Iws	-0.8326129	0.4989667	-1.668674
LogEXP	4.5488282	1.9842280	2.292493
Ecrm	-1.6005452	0.6512978	-2.457470
Epos	3.7823514	1.1371203	3.326254

Residual Deviance: 29.0765

AIC: 41.0765

Figura 98. "Stima del Modello B". Fonte: elaborazione propria.

```
=====
                        Dependent variable:
                        -----
                        Pur
-----
Ic                       -1.074*
                        (0.635)

Iws                       -0.833*
                        (0.499)

LogEXP                    4.549**
                        (1.984)

Ecrm                      -1.601**
                        (0.651)

Epos                      3.782***
                        (1.137)

Constant                  -7.425*
                        (4.087)

-----
Akaike Inf. Crit.        41.076
=====
Note:                    *p<0.1; **p<0.05; ***p<0.01
```

Figura 99. "Stargazer del Modello B". Fonte: elaborazione propria.

Figura 99: il valore di AIC è aumentato passando dal Modello A al Modello B. Tuttavia, ora tutte le variabili esplicative sembrano significative, come confermato dallo specchio offerto dalla funzione Stargazer.

Si è deciso di passare all'analisi della bontà di previsione, applicando la funzione predict(). Ottenute le previsioni, è stato possibile calcolare la Matrice di Confusione (Fig. 100).

```
Rcmdr> table(TOUCHPOINTS$Pur, yprevisto)
      yprevisto
      0  1
0     8  4
1     3 74
```

Figura 100. “Matrice di Confusione del Modello B”. Fonte: elaborazione propria.

Figura 100: dai risultati della Matrice di Confusione, è stato possibile calcolare le seguenti metriche:

FPR = FP/negativi =  $4/12 = 0,33$ . La probabilità di errore di I tipo è pari al 33%. Il livello di specificità del modello è buono poiché questa probabilità è contenuta.

TPR = TP/positivi =  $74/77 = 0,96$ . Questo risultato, se sottratto a 1, restituisce la probabilità di errore di II tipo, pari in questo caso al 4%. Essendo il TPR maggiore del FPR, possiamo affermare che il modello discrimina efficacemente. Il True Positive Rate è diminuito leggermente, di circa l’1%.

Misclassification Error = falsi/totali =  $7/89 = 0,08$ . Lo sottraggo a 1 per trovare l’accuratezza.

Accuracy =  $1-0,08 = 0,92$ . Il modello ha accuratezza pari al 92%, quindi la curva ROC si troverà sopra la diagonale. Anche l’accuratezza è peggiorata di un punto percentuale, rispetto al Modello A.

Complessivamente, possiamo affermare che i risultati delle metriche sono ottimi, tuttavia sono leggermente peggiorati rispetto a quelli ottenuti per il Modello A. Esso, infatti, sembra continuare ad essere la scelta migliore, anche dal punto di vista dell’AIC.

Al fine di comprendere se i risultati del Modello A fossero migliorabili, si è deciso di stimare un modello che comprendesse le interazioni tra le variabili esplicative. Partendo dal Modello B, si sono aggiunte tutte le interazioni possibili; si è stimato il modello diverse volte, escludendo, a ogni stima, le interazioni non significative. Il Modello che ne deriva è stato rinominato Modello C (Fig. 101).

```
Rcmdr> summary(MLM.21, cor=FALSE, wald=TRUE)
Call:
multinom(formula = Pur ~ Ic + Iws + LogEXP + Iws * Ecrm + Ecrm +
  Epos, data = TOUCHPOINTS, trace = FALSE)
```

```
Coefficients:
                Values Std. Err.  Value/SE
(Intercept) -4.248404  6.0769543 -0.6991009
Ic           -1.297300  0.7144566 -1.8157850
Iws          -5.952395  2.7871853 -2.1356294
LogEXP       9.045402  3.7412989  2.4177171
Ecrm        -5.957334  2.5597444 -2.3273160
Epos         5.344487  1.7978527  2.9727054
Iws:Ecrm     1.441617  0.7355666  1.9598728
```

```
Residual Deviance: 22.93573
AIC: 36.93573
```

Figura 101. "Stima del Modello C". Fonte: elaborazione propria.

```
=====
                        Dependent variable:
                        -----
                                Pur
-----
Ic                               -1.297*
                                (0.714)
Iws                              -5.952**
                                (2.787)
LogEXP                           9.045**
                                (3.741)
Ecrm                             -5.957**
                                (2.560)
Epos                             5.344***
                                (1.798)
Iws:Ecrm                          1.442*
                                (0.736)
Constant                          -4.248
                                (6.077)

-----
Akaike Inf. Crit.                 36.936
=====
Note:          *p<0.1; **p<0.05; ***p<0.01
```

Figura 102. "Stargazer del Modello C". Fonte: elaborazione propria.

Figura 102: il valore di AIC mostra un miglioramento, essendo diminuito rispetto al Modello A. Inoltre, le variabili esplicative sembrano tutte significative.

Si è deciso di passare all'analisi della bontà di previsione. Ottenute le previsioni, è stato possibile calcolare la Matrice di Confusione (Fig. 103).

```
Rcmdr> table(TOUCHPOINTS$Pur, yprevisto)
  yprevisto
    0  1
0  10  2
1   2  75
```

Figura 103. "Matrice di Confusione del Modello C". Fonte: elaborazione propria.

Figura 103: dai risultati della Matrice di Confusione, è stato possibile calcolare le seguenti metriche:

$FPR = FP/negativi = 2/12 = 0,17$ . La probabilità di errore di I tipo è pari al 17%. Il livello di specificità del modello è ottimo poiché questa probabilità è contenuta.

$TPR = TP/positivi = 75/77 = 0,97$ . Questo risultato, se sottratto a 1, restituisce la probabilità di errore di II tipo, pari in questo caso al 3%. Essendo il TPR maggiore del FPR, possiamo affermare che il modello discrimina efficacemente.

$Misclassification\ Error = falsi/totali = 4/89 = 0,05$ . Lo sottraggo a 1 per trovare l'accuratezza.

$Accuracy = 1-0,05 = 0,95$ . Il modello ha accuratezza pari al 95%, quindi la curva ROC si troverà sopra la diagonale (Fig. 104).

Dall'analisi delle metriche e del valore di AIC, possiamo affermare che il Modello C sembra essere il modello più efficace tra quelli individuati (Confronto modelli a Tab. 11).

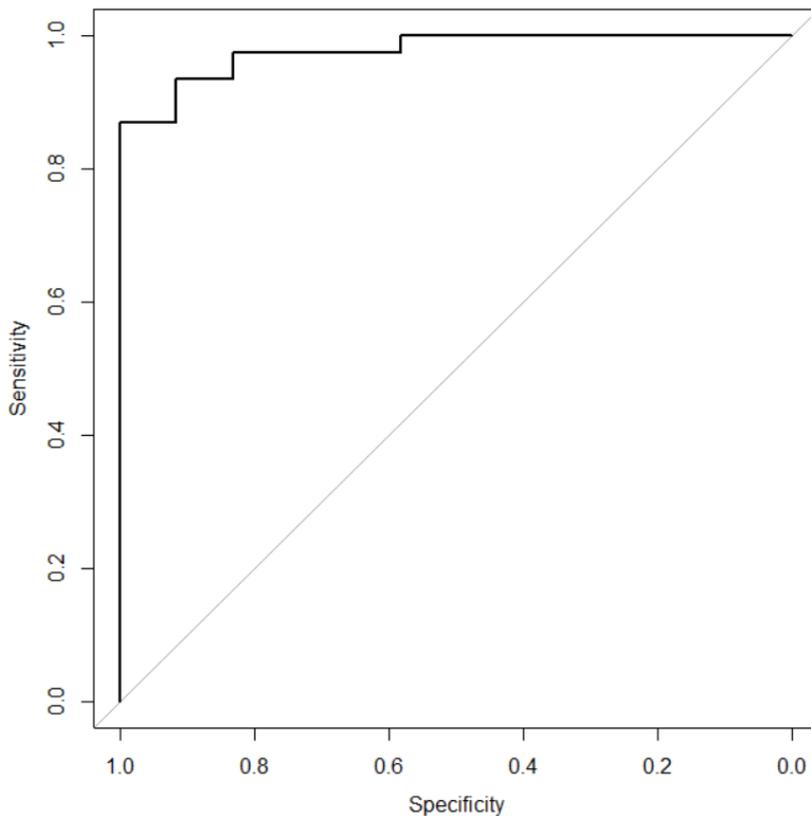


Figura 104. "Curva ROC del Modello C". Fonte: elaborazione propria.

	Intercept	Eoa	Fem [T.1]	lc	lws	LogEXP	Ecrm	Epos	lws:Ecrm
MOD. A	-12,76	1,04	3,12	-2,06**	-2,24*	7,6**	-2,42**	5,18***	
MOD. B	-7,43			-1,07*	-0,83*	4,55**	-1,6**	3,78***	
MOD. C	-4,25			-1,3*	-5,95**	9,05**	-5,96**	5,35***	1,44*

Tabella 11. "Confronto modelli". Fonte: elaborazione propria.

### 3.4.6. INTERPRETAZIONE DEI RISULTATI: VARIABILE PUR

Il modello logit proposto ha come obiettivo spiegare la probabilità che un individuo abbia effettuato almeno un acquisto in negozi fisici di vestiario negli ultimi tre mesi (variabile dicotomica Pur, che assume valore 1 in caso affermativo). Di seguito, analizziamo e interpretiamo i coefficienti delle variabili esplicative incluse nel "Modello C" (modello che sembra più qualitativo), con particolare attenzione alla loro direzione e significatività, per comprendere meglio come influenzino la probabilità di acquisto nei negozi fisici. L'unico coefficiente che non interpreteremo è quello relativo all'intercetta, in quanto anche in questo caso il relativo coefficiente non risulta statisticamente significativo e, inoltre, non è possibile descrivere una situazione in cui tutti i regressori assumono simultaneamente valore zero, data la presenza di variabili espresse su una scala da 1 a 5.

#### 1) Esposizione ai POS

Il coefficiente positivo e significativo associato all'esposizione ai negozi fisici indica che un maggiore contatto con i negozi fisici aumenta la probabilità di effettuare almeno un acquisto in questi punti vendita. Ci aspettavamo questo risultato, soprattutto nel settore dell'abbigliamento. Nel caso del vestiario, infatti, l'esperienza tattile e visiva (compresa la possibilità di provare i capi) che caratterizza i negozi fisici può rafforzare la propensione all'acquisto. Poniamo caso che un individuo acquisti negli store fisici dichiarando di avere bassa esposizione ai POS: probabilmente ci troveremmo davanti a un caso di webrooming, nel quale il cliente acquista da un POS dopo aver visionato il prodotto online. Possiamo affermare che, se all'interno del campione si verificassero casi di webrooming, essi sarebbero comunque poco frequenti.

#### 2) Esposizione al CRM

L'esposizione al Customer Relationship Management ha ottenuto un coefficiente negativo e significativo, suggerendo che una maggiore esposizione alle attività di CRM è associata a una riduzione della probabilità di effettuare acquisti nei negozi fisici. Questo risultato potrebbe riflettere l'efficacia delle attività di CRM nel favorire gli acquisti online

piuttosto che quelli nei negozi fisici, poiché molte campagne CRM offrono sconti o promozioni specifiche per l'e-commerce.

### 3) Influenza delle Cooperazioni

Il coefficiente negativo e significativo relativo all'influenza delle Cooperazioni indica che i consumatori che sono maggiormente influenzati da queste collaborazioni tendono a effettuare meno acquisti nei negozi fisici. Questo risultato è coerente con quello ottenuto dalla ricerca di Zimmermann et al. (2022): in quel caso, l'unica categoria di touchpoint ad avere effetto negativo sulla Spesa era proprio Cooperations. Nel nostro caso, non trattiamo la Spesa, bensì la possibilità di aver acquistato in POS; tuttavia i due effetti risultano coerenti. Il coefficiente negativo riferito a Ic potrebbe suggerire che tali cooperazioni siano percepite più come fenomeni di marketing digitale, con maggiore impatto sugli acquisti online, dove le collaborazioni vengono promosse attraverso piattaforme web e social media. In questo contesto, i consumatori potrebbero essere più inclini ad acquistare i prodotti in collaborazione direttamente online piuttosto che recarsi nei negozi fisici.

### 4) Influenza dei Siti Web

L'influenza percepita dei siti web presenta coefficiente negativo e significativo, suggerendo che i consumatori che si reputano maggiormente influenzati dalle piattaforme online siano meno propensi a fare acquisti nei negozi fisici. Questo risultato è coerente con la crescente tendenza verso l'e-commerce. Inoltre, i siti web forniscono spesso informazioni più dettagliate su prodotti, recensioni e sconti esclusivi, incentivando ulteriormente l'acquisto online, a discapito del negozio fisico.

### 5) Logaritmo della Spesa per vestiario

Il coefficiente positivo e significativo del logaritmo della variabile Spesa indica che, all'aumentare della spesa totale per vestiario negli ultimi tre mesi, aumenta anche la probabilità di aver effettuato almeno un acquisto nei POS negli ultimi tre mesi. Questo risultato è coerente con l'idea che i consumatori con una maggiore propensione alla spesa tendano a diversificare i loro canali di acquisto, includendo sia l'online che il negozio fisico. Inoltre, chi spende di più, potrebbe preferire acquistare dai negozi fisici per interagire direttamente con i prodotti o per godere dell'esperienza di acquisto offerta in loco. Tuttavia, è doveroso riconoscere rispetto a questa variabile che non possiamo

escludere la presenza di reverse causality tra le due variabili in oggetto: oltre a LogEXP a influire sulla variabile Pur, potrebbe anche essere la Variabile Pur a influire su LogEXP. Per questo motivo l'interpretazione di questo modello richiede, in generale, maggiore cautela rispetto al precedente.

#### 6) Interazione tra Influenza dei Siti Web ed Esposizione al CRM ("Iws:Ecrm")

L'interazione tra l'influenza dei siti web e l'esposizione al CRM ha ottenuto un coefficiente positivo e significativo. Questo risultato indica che, per livelli elevati di una delle due variabili, l'incremento dell'altra produce un aumento della probabilità di effettuare un acquisto nei negozi fisici. L'effetto positivo dell'interazione suggerisce che, nonostante le esposizioni ai siti web e al CRM separatamente tendano a ridurre la probabilità di acquistare nei negozi fisici, la loro combinazione può generare un risultato opposto. Una possibile spiegazione è che l'integrazione tra il CRM (che potrebbe includere promozioni personalizzate) e le informazioni fornite dai siti web possa migliorare l'efficacia complessiva dell'azione promozionale, incentivando i consumatori a completare l'acquisto nei negozi fisici, dove potrebbero sfruttare al meglio le promozioni o avere esperienze personalizzate.

## 4. CONCLUSIONI E IMPLICAZIONI MANAGERIALI

### 4.1. SINTESI DEI RISULTATI PRINCIPALI

I risultati della ricerca confermano l'importanza di un approccio omnicanale integrato nell'implementazione delle strategie di marketing nel settore del vestiario.

In particolare, la crescente rilevanza dei social media evidenzia un'evoluzione verso touchpoints più dinamici e interattivi. Piattaforme come Instagram, che consente ai consumatori di interagire direttamente con pagine dei brand (owned media), influencer (paid media) e contenuti generati dagli utenti (earned media), rappresentano uno dei canali di marketing più efficaci, rispetto al campione analizzato.

Al contrario, i media tradizionali come la cartellonistica – sia digitale che fisica – hanno mostrato un impatto negativo sulla spesa per vestiario. Questo effetto, evidenziato anche dallo studio di Zimmermann et al. (2020), suggerisce che tali canali potrebbero essere considerati “superati” dal campione oggetto di analisi, probabilmente a causa della natura unidirezionale del messaggio.

Il potenziale della pubblicità online emerge chiaramente dai risultati del campione, con un effetto positivo sulla spesa per abbigliamento. I paid media, grazie a strumenti come la SEA o il retargeting, permettono alle aziende di raggiungere target specifici con contenuti personalizzati, garantendo risultati più mirati.

Il ruolo dei negozi fisici rimane comunque cruciale, con i rispondenti che dichiarano di essere particolarmente influenzati dalla disponibilità fisica dei prodotti nelle loro scelte d'acquisto.

Tuttavia, le collaborazioni tra brand sembrano avere un impatto negativo sulle decisioni d'acquisto in negozio del campione, in quanto potrebbero essere percepite maggiormente come strumenti di marketing digitale. Questo aspetto è confermato dai risultati di Zimmermann et al. (2020): la ricerca individua tali touchpoints come l'unica categoria ad avere un effetto negativo sulla spesa.

Il Customer Relationship Management ha avuto influenza negativa sulle scelte d'acquisto in negozio del campione. La categoria del CRM comprendeva anche le newsletter, che potrebbero aver indotto i rispondenti a pensare al CRM come uno strumento che manca di personalizzazione nei contatti. Questa interpretazione si troverebbe d'accordo con lo

studio di Cambra-Fierro et al. (2021), che evidenzia come la standardizzazione nei contatti possa avere un effetto negativo sulla percezione della competenza aziendale.

Infine, fattori demografici come età e genere hanno dimostrato di influire sulla spesa all'interno del campione. Le donne hanno mediamente speso meno, mentre gli over 30 risultano essere i consumatori più propensi a spese elevate.

In conclusione, l'analisi dei diversi canali di marketing evidenzia l'importanza di una strategia omni-channel che combini canali tradizionali e digitali in modo sinergico, tenendo conto delle preferenze dei consumatori e del contesto d'acquisto.

#### 4.2. IMPLICAZIONI MANAGERIALI PER IL MARKETING

I risultati della ricerca offrono spunti significativi per ottimizzare le strategie di marketing in un contesto omnichannel. Le caratteristiche e l'efficacia differenti delle diverse categorie di touchpoints richiedono un approccio strategico che integri i vari punti di contatto, con una particolare attenzione all'interazione tra essi.

I dati mostrano che i media classici hanno un impatto negativo sulle vendite all'interno del campione. Per i manager, ciò implica la necessità di rivalutare la frequenza e le modalità di utilizzo dei media tradizionali. Questo non significa abbandonare totalmente questa tipologia di touchpoints, bensì capire come integrarla correttamente all'interno delle proprie strategie omni-channel, allocandovi, inoltre, un corretto quantitativo di risorse.

L'importanza dei social media sul campione è emersa in modo evidente. I consumatori non solo interagiscono con le pagine dei brand, ma sono influenzati anche da influencer, UGC e pubblicità sponsorizzata. Nello specifico, i rispondenti reputano Instagram come uno dei touchpoints maggiormente influenti sulle loro scelte d'acquisto. Per i manager, questo significa che la gestione accurata e strategica dei profili social può aumentare significativamente la brand equity, favorendo la creazione di comunità e fidelizzazione.

La pubblicità online ha dimostrato un impatto positivo sulla spesa per vestiario all'interno del campione. I rispondenti hanno indicato i contenuti sponsorizzati come particolarmente efficaci, sottolineando che questi risultano più autorevoli e affidabili rispetto ai tradizionali banner pubblicitari.

D'altra parte, i negozi fisici continuano a svolgere un ruolo cruciale, specialmente per quanto riguarda la disponibilità fisica dei prodotti, utile a ridurre l'incertezza legata

all'acquisto. Questo sottolinea l'importanza di una strategia omnicanale integrata, dove i punti vendita fisici non sono visti come antagonisti dei canali digitali, ma piuttosto come complementari. I manager dovrebbero quindi considerare di adottare un'integrazione fluida tra l'esperienza online e quella offline.

Le cooperazioni non sembrano generare un impatto positivo sulla spesa o sulla scelta di acquisto nei negozi fisici. Tuttavia, ciò non deve portare all'abbandono di questa tipologia di touchpoints, in quanto le cooperazioni potrebbero avere un effetto positivo in termini di immagine, soprattutto per i brand meno conosciuti.

Infine, le strategie di Customer Relationship Management richiedono una maggiore personalizzazione, in quanto i contatti standardizzati non sono percepiti positivamente dai consumatori. Per i manager, ciò rappresenta un invito a investire in soluzioni CRM capaci di offrire contenuti e offerte personalizzate, con l'obiettivo di fidelizzare i clienti.

In sintesi, i risultati della ricerca evidenziano la necessità di una strategia omnichannel che ottimizzi l'utilizzo dei canali digitali e fisici, e che sia basata su una comunicazione personalizzata e interattiva, in linea con le aspettative dei consumatori moderni.

#### 4.3. LIMITI DELLO STUDIO E SUGGERIMENTI PER FUTURE RICERCHE

Nel presente studio, devono essere presi in considerazione alcuni limiti per valutare con cautela i risultati ottenuti. Il campione, composto da 107 individui, pur avendo una numerosità non trascurabile, rimane limitato e non rappresentativo della popolazione di riferimento, conseguentemente i risultati non possono essere generalizzati. Si ritiene comunque, anche in relazione alla coerenza di alcuni risultati con quanto discusso in letteratura, che il lavoro possa rappresentare un utile punto di vista a supporto delle valutazioni manageriali.

Un primo limite riguarda la modalità di raccolta dei dati: il sondaggio è stato diffuso prevalentemente su piattaforme digitali, il che ha comportato uno sbilanciamento verso partecipanti più giovani, con una netta maggioranza all'interno del campione di rispondenti Under 30. Questo ha escluso, o comunque ridotto, la partecipazione di persone appartenenti a fasce di età più avanzate.

Un altro aspetto critico riguarda la distribuzione geografica dei rispondenti: la presenza di individui provenienti da aree suburbane è risultata sovra-rappresentata rispetto a quella delle aree urbane, che avrebbero dovuto essere più rilevanti. Anche la partecipazione dalle

zone rurali è stata inferiore rispetto alle medie attese, il che potrebbe aver influito sui risultati in termini di comportamenti di acquisto, in virtù, ad esempio, della maggiore difficoltà degli abitanti delle aree rurali nel raggiungere negozi fisici.

Un ulteriore limite riguarda la variabile "Reddito", non essendo questa stata misurata direttamente, bensì attraverso una domanda sul tenore di vita percepito dai rispondenti. Questo potrebbe aver introdotto un margine di errore dovuto alla soggettività della percezione economica individuale.

Inoltre, alcune variabili, come le percezioni relative ai touchpoints, sono state misurate utilizzando scale Likert, che, pur essendo strumento utili, possono non sempre garantire la totale affidabilità delle risposte, essendo basate su percezioni soggettive.

In aggiunta, la somministrazione del questionario in formato digitale, senza la possibilità di spiegare in dettaglio ogni domanda, ha lasciato spazio a potenziali interpretazioni errate da parte dei partecipanti.

Complessivamente, i risultati dello studio devono essere interpretati nel contesto di questi limiti e non possono essere generalizzati alla popolazione globale.

Infine, rispetto al modello logit relativo all'analisi della probabilità di acquisto nei negozi fisici, si ricorda la necessità di una certa cautela nell'interpretazione dei risultati in quanto, come si è discusso, non è possibile escludere un problema di endogeneità rispetto a uno dei regressori.

Per future ricerche, sarebbe opportuno ampliare il campione, includendo una distribuzione più equilibrata in termini di età e provenienza geografica, considerando l'utilizzo di metodi di rilevazione più diversificati, non solo digitali, per assicurarsi una maggiore rappresentatività.

Inoltre, sarebbe opportuno approfondire l'analisi con variabili più precise, integrando anche metriche oggettive data-driven (e.g. numero di contatti avuti da un cliente con una determinata tipologia di touchpoints in un dato periodo di tempo).

In aggiunta, il problema legato alla potenziale presenza di una variabile endogena potrebbe essere approfondito ed eventualmente corretto utilizzando strumenti econometrici più sofisticati.

In conclusione, un focus su nuovi strumenti digitali emergenti, come l'intelligenza artificiale nel marketing, potrebbe offrire spunti interessanti per esplorare le future evoluzioni del comportamento dei consumatori in un contesto omnicanale sempre più complesso.

## 5. REFERENZE

Accenture. (2023). One Billion New Online Shoppers Are Entering the Market Creating Significant Growth Opportunities for Digital Commerce.

<https://newsroom.accenture.com/news/2023/one-billion-new-online-shoppers-are-entering-the-market-creating-significant-growth-opportunities-for-digital-commerce-finds-new-study-by-accenture> [Consultato 14 ottobre 2024]

Anderl, E., Schumann, J. H. e Kunz, W. (2016). Helping firms reduce complexity in multichannel online data: A new taxonomy-based approach for customer journeys. *Journal of Retailing*, 92(2). <https://doi.org/10.1016/j.jretai.2015.10.001>

Belanche, D., Cenjor, I., e Pérez-Rueda, A. (2019). Instagram Stories versus Facebook Wall: An advertising effectiveness analysis. <https://www.emerald.com/insight/content/doi/10.1108/SJME-09-2018-0042/full/html&gt>

Brodie, R. J., Hollebeek, L. D., Juric, B., e Ilic, A. (2011). Customer engagement: Conceptual domain, fundamental propositions, and implications for research. *Journal of Service Research*, 14(3). <https://doi.org/10.1177/1094670511411703>

Brynjolfsson, E., Hu, Y. J., e Rahman, M. S. (2013). Competing in the age of omnichannel retailing. *MIT Sloan Management Review*, 54(4)

Cambra-Fierro, J., Polo-Redondo, Y., e Trifu, A. (2020). Short-term and long-term effects of touchpoints on customer perceptions. *Journal of Business Research*, 121. <https://doi.org/10.1016/j.jretconser.2021.102520>

Chen, J., Zhang, Y., Cai, H., Liu, L., Liao, M., & Fang, J. (2024). A comprehensive overview of micro-influencer marketing: Decoding the current landscape, impacts, and trends. <https://www.mdpi.com/2076-328X/14/3/243>

CPP-Luxury. (2023). Italian fashion to surpass sales of 102 billion euros. <https://cpp-luxury.com/italian-fashion-to-surpass-sales-of-102-billion-euros/> [Consultato 14 ottobre 2024]

Eurostat. (2022). Urban-rural Europe - demographic developments in rural regions and areas. [https://ec.europa.eu/eurostat/statistics-explained/index.php?oldid=588518#Population\\_structure](https://ec.europa.eu/eurostat/statistics-explained/index.php?oldid=588518#Population_structure) [Consultato 3 ottobre 2024]

Fain, I. (2014). The mask behind the veil: Identifying the many-faced consumer across channels. *Colloquy*.

Forrester. (2014). *Customer desires vs. retailer capabilities: Minding the omni-channel commerce gap*. A Forrester Consulting Thought Leadership Paper.

Hallikainen, H., Alamäki, A., & Laukkanen, T. (2019). *Individual preferences of digital touchpoints: A latent class analysis*. <https://doi.org/10.1016/j.jretconser.2018.07.014>

Ieva, M., e Ziliani, C. (2018). Mapping touchpoint exposure in retailing: Implications for developing an omnichannel customer experience. *Journal of Retailing and Consumer Services*, 45. <https://doi.org/10.1108/IJRDM-04-2017-0097>

Jarrar, Y., Awobamise, A. O., Aderibigbe, A. A. (2020). Effectiveness of Influencer Marketing vs Social Media Sponsored Advertising. <http://doi.org/10.5281/zenodo.4280084>

Juaneda-Ayensa, E., Mosquera, A., e Sierra Murillo, Y. (2016). Omnichannel customer behavior: Key drivers of technology acceptance and use and their effects on purchase intention. <https://www.frontiersin.org/articles/10.3389/fpsyg.2016.01117/full>

Lemon, K. N., e Verhoef, P. C. (2016). Understanding customer experience throughout the customer journey. *Journal of Marketing*, 80(6). <https://doi.org/10.1509/jm.15.0420>

Li, H., e Kannan, P. K. (2014). Attributing conversions in a multichannel online marketing environment: An empirical model and a field experiment. *Journal of Marketing Research*, 51(1).

Lopez, R. A., Liu, Y., & Zhu, C. (2015). TV advertising spillovers and demand for private labels: The case of carbonated soft drinks. *Applied Economics*, 47(25).

McKinsey & Company. (2022). What is omnichannel marketing? McKinsey & Company. <https://www.mckinsey.com/featured-insights/mckinsey-explainers/what-is-omnichannel-marketing> [Consultato 14 ottobre 2024]

Melero, I., Sese, F. J., e Verhoef, P. C. (2016). Recasting the customer experience in today's omni-channel environment. *Journal of Business Research*, 69(8). <https://doi.org/10.1016/j.jbusres.2016.01.022>

Payne, A., e Frow, P. (2004). The role of multichannel integration in customer relationship management. *Industrial Marketing Management*, 33(6)

Pluta-Olearnik, M., e Jadach, R. (2019). Multichannel selling – The key to success in retail. *Marketing of Scientific and Research Organizations*, 33(3).

Rios Marques, I., Casais, B. & Camilleri, M.A. (2020). The effect of macro celebrity and micro influencer endorsements on consumer-brand engagement on Instagram. In Camilleri, M.A. (Ed.) *Strategic Corporate Communication in the Digital Age*, Emerald, Bingley, UK. <https://doi.org/10.1108/978-1-80071-264-520211008>

Shah, D., Rust, R. T., Parasuraman, A., Staelin, R., e Day, G. S. (2006). The path to customer centricity. *Journal of Service Research*, 9(2). <https://doi.org/10.1177/1094670506294666>

Sopadjieva, E., Dholakia, U. M., e Benjamin, B. (2017). A study of 46,000 shoppers shows that omnichannel retailing works. Harvard Business Review. <https://hbr.org/2017/01/a-study-of-46000-shoppers-shows-that-omnichannel-retailing-works> [Consultato 14 ottobre 2024]

Stanford University. (2022). Know your Gen Z. <https://news.stanford.edu/stories/2022/01/know-gen-z> [Consultato 5 ottobre 2024]

Stephen, A. T., e Galak, J. (2012). The effects of traditional and social earned media on sales: A study of a microlending marketplace. *Journal of Marketing Research*, 49(5). <https://doi.org/10.1509/jmr.09.0401>

Verhoef, P. C., Kannan, P. K., e Inman, J. J. (2015). From multi-channel retailing to omni-channel retailing: Introduction to the special issue on multi-channel retailing. *Journal of Retailing*, 91(2). <https://doi.org/10.1016/j.jretai.2015.02.005>

Zhang, Y., Lin, Y., & Goh, K. H. (2018). Impact of online influencer endorsement on product sales: Quantifying the value of online influencers. *Journal of Marketing Research*, 55(5).

Zhao, Y., Goh, K.-Y., e Hou, L. (2020). Evaluating the effectiveness of online customer touchpoints in omni-channel environments. *Journal of Retailing*, 96(3). <https://doi.org/10.1016/j.jretai.2020.02.001>

Zimmermann, R., Weitzl, W., e Auinger, A. (2022). Identifying sales-influencing touchpoints along the omnichannel customer journey. *Procedia Computer Science*, 196. [Identifying Sales-Influencing Touchpoints along the Omnichannel Customer Journey - ScienceDirect](https://doi.org/10.1016/j.procs.2022.01.001)