

# The economics of Conversational Agents



Mario Zucca

Dipartimento di Economia (DIEC)

Università degli Studi di Genova

Supervisor

Anna Bottasso, Università degli Studi di Genova

In parziale adempimento dei requisiti per il conseguimento del titolo

Tesi di Dottorato di Ricerca in Economia

(XXXII ciclo)

Gennaio, 2020

# The economics of Conversational Agents



Mario Zuca

# The economics of Conversational Agents

For many years software has been developed to automate the internal processes of a company. Over the years, we have learned to measure the cost/benefit ratio linked to the introduction of new automation tools. We have also figured out how to define a strategy that allows introduction into the company by minimizing risks and maximizing returns. The digital transformation process implies the launch of initiatives aimed at preparing the organization for the forthcoming changes.

However, in the last period, we are observing a constant growth in the demand for new automation models that can make the most of recent scientific advances made in the field of cognitive services. In last years we have witnessed the introduction of new automation services for the processes borrowed from the experiences made in the field of robotics and adapted to more complex business models. With the advent of increasingly sophisticated AI tools, we can easily imagine how, by combining RPA tools with cognitive services, we can significantly extend the services that companies can offer.

We can think of automating business processes by integrating cognitive services, allowing us to add a new dimension of intervention, allowing the system to interact using natural language. We can briefly define these new tools as conversational agents.

There are already several concrete implementations of these technologies that are abandoning the field of research to try their hand in the industrial world. We are witnessing a progressive spread of conversational platforms, also in the consumer sphere. Some of the most concrete examples that have had outstanding commercial success are Google Home<sup>®</sup>, Alexa<sup>®</sup>, Siri<sup>®</sup>, Cortana<sup>®</sup>, etc. Such a significant achievement has cleared the concept of a virtual assistant.

All the leading companies have begun the introduction of these technologies through the implementation of simple chatbots, which, however, are changing the primary way of interacting with customers through the progressive replacement of traditional call centers. However, many decision-makers remain doubting about the claims surrounding the promised business value of the conversational platforms. Potential adopters must be informed about the actual benefits and economic returns of the technological investments needed to introduce these new tools into organizations.

In this work, we want to define what the conversational agents are and provide an economic model that allows estimating the factors that influence the adoption of this technology and the returns of the investments.





## Abstract

L'obiettivo dello studio è quello di analizzare i dati raccolti nel lancio di un agente conversazionale, progettato, sviluppato e infine adottato da un'importante multinazionale italiana nel 2019.

Questa società, con oltre 60 mila dipendenti in tutto il mondo, si è posta l'obiettivo di fornire un servizio in tutti i differenti paesi dove è presente, utilizzando differenti linguaggi e su diversi ambiti, partendo da quello delle Human Resources (timesheet, cedolino,...), per ampliarlo alla comunicazione personalizzata su temi di interesse specifico, all'eLearning per conoscere o partecipare a corsi o eventi o in ambito organizzativo.

I dati analizzati sono quelli contenuti nelle conversazioni tra gli utenti e il nostro agente nel periodo che va dal 10 novembre al 31 dicembre 2019. Dopo aver reso disponibile ad un numero limitato di utenti il servizio, l'azienda ha deciso di estenderlo a tutti i propri dipendenti italiani, accompagnandolo con un'importante campagna informativa. In questo range temporale sono state registrate ben 10.321 conversazioni, con 119.357 messaggi.

Lo studio proposto presenta subito una complessità il cui fattore principale è rappresentato dalla natura intrinsecamente multidisciplinare del sistema. Infatti esso abbraccia campi diversi dall'ingegneria al marketing, dalla psicologia all'economia.

L'economia, in particolare, gioca un ruolo determinante di "coordinamento" ed "interrelazione" degli altri settori disciplinari, inquadrandoli in una rigorosa cornice scientifica. Questo permette di fornire spunti di riflessione e di determinare anche gli impatti economici che l'introduzione della tecnologia, propria degli agenti conversazionali, ha per le imprese e per gli utenti. La governance delle stesse imprese manifesta in maniera crescente la necessità di avere elementi e strumenti di valutazione per decidere "se e quanto" investire in questa tecnologia, almeno a medio termine.

Ancora oggi, dopo anni di applicazione degli agenti conversazionali in diversi contesti operativi, non sono così definiti e disponibili gli elementi e gli strumenti di valutazione dell'efficacia dell'uso nella relazione con gli utenti.

Questo lavoro si focalizza dunque sull'analisi del funzionamento dell'agente, del comportamento degli utenti, della qualità della conversazione, ovvero sull'interpretazione di centinaia di migliaia di dati generati da un servizio che per la propria natura deve "reagire" in modalità *unattended*.

La trattazione si sviluppa per poter esaminare e proporre possibili metodologie utili all'identificazione di metriche. Le metriche sono basate su un paradigma interpretativo funzionale ad identificare i fattori tecnico-economico che influenzano l'adozione e la diffusione di questa tecnologia.

Nella parte conclusiva la visione dell'azienda e l'interesse all'uso da parte degli utenti devono convergere, in quanto questi ultimi sono indotti a decidere se utilizzare questo nuovo canale di comunicazione che l'azienda aggiunge ad altri già in uso per diverse tipologie di servizi interni. Si rappresenta una sorta di "competizione" tra i canali che concorrono strategicamente per la conquista di una quota di mercato potendo agire sulla qualità del servizio e/o sugli investimenti in comunicazione. Abbiamo quindi provato a definire un modello duopolistico di concorrenza strategica, in cui gli agenti competono esercitando azioni sul prezzo e sulla comunicazione. L'azienda che propone l'agente conversazionale utilizza una rete Q-Learning per implementare il comportamento strategico al fine di massimizzare i profitti con atteggiamento non collusivo.



Il documento, dunque, si articola nei seguenti capitoli:

**-Capitolo 1 Conversational Agents:** Introduzione al contesto degli agenti conversazionali, alle definizioni comuni utilizzate in tutta la trattazione raccogliendo interessanti spunti di riflessione attraverso le analisi pubblicate da società di consulenza leader a livello mondiale. In questo primo capitolo abbiamo quindi definito il dominio legato agli agenti conversazionali, la loro diffusione sul mercato, il trend di crescita e la raccolta di informazioni relative alle strategie che, verosimilmente, adotteranno i principali player.

**-Capitolo 2:** Studio del comportamento degli utenti. In questo capitolo proviamo a definire le metriche per valutare la qualità del servizio. L'idea è quella di misurare il fenomeno per derivarne, indirettamente, una misura della qualità del servizio. È altresì necessario poter suddividere un mercato così eterogeneo secondo fasce omogenee che ci possano permettere di eseguire analisi puntuali sul reale funzionamento del sistema. Gli obiettivi di questa ricerca sono quindi: metrica per la valutazione del servizio, criteri e strumenti per la segmentazione del mercato.

**-Capitolo 3:** Comprensione dei dialoghi e valutazione della qualità. Come vedremo un sistema conversazionale è caratterizzato dallo scambio di messaggi con l'utente al fine di raggiungere un obiettivo. Che sia operativo o informativo. Vengono pertanto scambiati migliaia, in alcuni casi anche decine di migliaia di messaggi al giorno, e senza un adeguato strumento di controllo diventa impossibile verificare l'effettiva convergenza del sistema. Durante la fase sperimentale si è visto che i feedback degli utenti sono uno strumento inutilizzabile. In questo capitolo l'obiettivo della ricerca è stato quello di identificare strumenti e metodologie per interpretare i dialoghi con il duplice scopo: comprendere cosa chiedono gli utenti e creare una metrica per valutare la qualità. Definire una metrica per la valutazione della qualità ci permette una clusterizzazione dei dialoghi. Questo ci potrà permettere, in futuro, di capire la correlazione tra utilizzo del sistema e qualità offerta. Nel breve sarà comunque possibile analizzare i dialoghi, sia quelli che hanno avuto particolarmente successo e quelli che evidenziano delle criticità. Questo sarà tanto più importante quanto più saranno complesse le funzionalità offerte dall'agente conversazionale e, di conseguenza, le articolazioni dei dialoghi necessari per supportare tali funzionalità.

**-Capitolo 4:** Implicazioni economiche derivanti dall'introduzione dell'agente conversazionale in una azienda. L'esempio concreto studiato analizza le dinamiche derivanti dall'offrire agli utenti una metodologia alternativa per fruire dei servizi aziendali. Considerando che accedere ai servizi aziendali è una necessità per tutti i dipendenti questi possono scegliere tra modalità differenti per la fruizione. Considerando fissa e predeterminata la "quantità" di accessi che gli utenti devono fare. Abbiamo provato a modellare l'introduzione della nuova modalità di accesso come un duopolio in cui due aziende competono su un mercato chiuso (i dipendenti) agendo sul prezzo (la qualità del sistema) con l'obiettivo di aumentare la quantità erogata. Questo si sviluppa attraverso un gioco competitivo, ipotizzando comportamenti non collusivi.

## CAPITOLO 1 Conversational Agents

“No matter how sophisticated or powerful our thinking machines become, there still will be two kinds of people: those who let the machines do their thinking for them, and those who tell the machines what to think about.” C.J. Lewis

### Introduzione

Per essere in grado di rispondere all'ambiente sempre più competitivo e soddisfare le esigenze e le aspettative dei clienti, pervasivamente sollecitati da una comunicazione digitale, i tradizionali fornitori di servizi sono costretti a intraprendere una profonda trasformazione digitale dei loro processi, che a sua volta implica anche una ristrutturazione dei loro modelli di business tradizionali e un riallineamento strategico del modo in cui interagiscono con i loro utenti, non necessariamente clienti, attraverso l'innovazione del servizio (Barrett et al., 2015).

Negli ultimi anni abbiamo assistito ad una sorprendente proliferazione di strumenti conversazionali. Tutte le principali aziende mondiali hanno iniziato a fornire ai propri utenti servizi di questo tipo. Anche in Italia possiamo vedere casi di successo come Tobit<sup>®</sup> di Vodafone che è, alla data, uno dei servizi più utilizzati ma anche Enel, TIM, Sky hanno iniziato a rendere disponibili questi servizi. Ancora più sorprendente è però l'esplosione di questo tipo di assistenti a livello consumer. Abbiamo infatti assistito ad un fenomeno che complessivamente nell'ultimo anno ha superato il miliardo di dispositivi venduti. L'esperienza di Siri<sup>®</sup> prima, dell'assistente vocale di Google<sup>®</sup> poi e quindi il fenomeno, sempre più diffuso, degli smart speakers hanno portato ad un rapido aumento di questa nuova tipologia di interazione. Basti pensare all'introduzione dell'interfaccia vocale e conversazionale per accedere ai servizi a bordo dell'automobile da parte di Mercedes<sup>®</sup>.

Secondo Canalys gli smart speaker hanno superato la quota di 100 milioni di dispositivi venduti nel 2018 e oltre 28 milioni nel solo primo trimestre del 2019. Il 50% di questo mercato è oggi governato da Amazon con i suoi dispositivi Alexa<sup>®</sup>.

Worldwide smart speaker shipments and annual growth					
Canalys smart speaker market pulse: Q3 2019					
Vendor	Q3 2019 shipments (million)	Q3 2019 market share	Q3 2018 shipments (million)	Q3 2018 market share	Annual growth
Amazon	10.4	36.6%	6.3	31.9%	65.9%
Alibaba	3.9	13.6%	2.2	11.1%	77.6%
Baidu	3.7	13.1%	1.0	4.9%	290.1%
Google	3.5	12.3%	5.9	29.8%	-40.1%
Xiaomi	3.4	12.0%	1.9	9.7%	77.7%
Others	3.6	12.5%	2.5	12.5%	44.0%
<b>Total</b>	<b>28.6</b>	<b>100.0%</b>	<b>19.7</b>	<b>100.0%</b>	<b>44.9%</b>

Note: percentages may not add up to 100% due to rounding  
Source: Canalys Smart Speaker Analysis (sell-in shipments), November 2019



Figura 1 Mercato degli smart speaker in Q3 2018 e 2019

Questo rilevante fenomeno ha sollecitato molte aziende di consulenza ad analisi previsionali in termini di applicazioni e investimenti a medio termine. Secondo il gruppo Gartner<sup>1</sup>, entro il 2022 il 70% dei white-collars

<sup>1</sup> <https://www.gartner.com/smarterwithgartner/chatbots-will-appeal-to-modern-workers/>

interagiranno giornalmente con una piattaforma conversazionale ed i CIO delle aziende intervistate identificano i chatbots come la principale applicazione dell'AI nelle loro aziende.

Anche Accenture ha pubblicato i risultati di interviste a CIO e CTO nel mondo<sup>2</sup>, di cui addirittura il 56% afferma che i bot conversazionali stanno rivoluzionando il loro settore e che il 43% dei concorrenti sta già implementando tale tecnologia nei loro sistemi. Inoltre, il 57% degli intervistati concorda che i bot conversazionali possono garantire un alto ritorno degli investimenti con un minimo sforzo.

Secondo Cap Gemini<sup>3</sup> "AI offers one of the most significant opportunities in the retail space. Retailers across the world are investing in this advanced technology to improve the customer experience while driving up operational efficiency and productivity. It is estimated that global annual spending on AI by retailers will top \$7.3 billion by 2022".

Questi investimenti saranno finalizzati principalmente all'interazione con i clienti (74%), e una quota, comunque rilevante, pari al 26% sarà rivolta alla gestione delle operazioni di routine. Tali operazioni caratterizzano la quotidianità lavorativa di moltissime persone e rappresentano un mercato rilevante in parziale sovrapposizione con il mercato RPA (Robotics Process Automation). È molto interessante notare come anche lo studio di Capgemini individui i chatbot come uno dei principali driver degli investimenti nell'intelligenza artificiale di molte aziende leader.

Nell'ultimo decennio si è assistito ad una sempre più rapida diffusione di tecnologie resa possibile da un insieme correlato di evoluzioni in settori afferenti all'informatica, alla comunicazione e alla connettività più comunemente conosciute come tecnologie Social, Mobile, Analytics, Cloud e Internet of Things (SMACIT). Queste tecnologie abbinate ai progressi nel campo dell'intelligenza artificiale (AI) hanno prodotto una **digital transformation** rispetto al modo in cui i servizi tradizionali generano valore (*Schuelke-Leech, 2018*). In particolare, secondo diversi studi, nel mondo delle imprese l'implementazione di servizi innovativi basati su tecnologie conversazionali può contribuire a migliorare l'efficienza lungo la catena del valore, ridurre i costi e generare fedeltà e fiducia negli utenti (*Barrett et al., 2015; Ross et al., 2016*). Tuttavia, nonostante i vantaggi, il successo dell'adozione di questo tipo di tecnologia dipende dalla comprensione delle percezioni e degli atteggiamenti dei principali attori (ad esempio professionisti<sup>4</sup> e potenziali utenti) verso il funzionamento del servizio. Un agente conversazionale ha come principale obiettivo quello di *fornire servizi agli utenti in modo non supervisionato*. Questa peculiare caratteristica rende complesso valutare l'effettivo gradimento del servizio del cliente che non può essere desunto in via diretta.

Occorre quindi trovare metodologie "indirette" che permettano di ricavare tali informazioni. Infatti, nonostante i vantaggi, il successo dell'adozione di questo tipo di tecnologia dipende dalla capacità di comprendere le percezioni e gli atteggiamenti dei principali attori (ad esempio professionisti e potenziali utenti) verso il funzionamento del servizio.

L'obiettivo di questa tesi è quella di esaminare le possibili metodologie per identificare metriche basate su un paradigma interpretativo per identificare i fattori tecnico, economico e sociali più critici per l'adozione e la diffusione della tecnologia. In generale l'implementazione di innovazioni tecnologiche sotto forma di sistemi conversazionali (ad es. Chatbot) può contribuire a sbloccare nuove soluzioni e opportunità commerciali se i sistemi di cui sopra sono adeguatamente integrati nella tradizionale catena del valore attraverso mezzi di strategie digitali a lungo termine basate sul coinvolgimento del cliente (*Ross et al., 2016*).

---

<sup>2</sup> <https://www.accenture.com/acnmedia/pdf-77/accenture-research-conversational-ai-platforms.pdf>

<sup>3</sup> <https://www.capgemini.com/wp-content/uploads/2018/12/Report-%E2%80%93-Building-the-Retail-Superstar-Digital1.pdf>

<sup>4</sup> In questo caso con professionisti intendiamo le persone che, a vario titolo, contribuiscono al funzionamento del sistema (ingegneri, contents manager, marketing, ecc.).

In questo modo, attraverso l'implementazione di Chatbot come interfaccia verso l'utente diventa possibile convertire l'approccio multicanale attualmente adottati nei sistemi offerti dai principali fornitori di servizi<sup>5</sup> in un'unica "esperienza omni-channel in modo che i clienti possano ordinare, richiedere, pagare e ricevere supporto in modo coerente da qualsiasi canale in qualsiasi momento", come sostenuto da Ross et al. (2016). Di conseguenza, l'adozione di Chatbot potrebbe migliorare l'efficienza lungo la catena del valore, ridurre i costi, aumentare l'accessibilità per i clienti e generare fedeltà e fiducia (Barrett et al., 2015; Ross et al., 2016).

Ancora secondo la definizione di Schuelke-Leech, si può immaginare i conversational agents come una "disruption" del secondo ordine. Secondo la definizione questo tipo di rivoluzione "has much larger influences, affecting many industries and substantially changing societal norms and institutions".

Così si inquadra perfettamente il fenomeno in cui si inserisce questo studio.

Secondo Winkler & Söllner (2018), negli ultimi anni, i graduali miglioramenti dell'IA, dei social media e delle tecnologie di analisi hanno consentito nuove possibilità tecniche per l'adozione di chatbot in diversi settori come l'assistenza sanitaria, il turismo e l'istruzione. Tuttavia, nonostante gli alti tassi di adozione previsti dalle principali società di consulenza, i tassi di adozione effettivi rimangono bassi. Ad esempio, in un sondaggio condotto su 85 compagnie assicurative tedesche intervistate, il 44% di loro ha voluto investire di più in Chatbot nel 2018, ma solo il 7% ha effettivamente implementato assistenti digitali entro il 2017 (Branchenkompas Insurance, 2017). Se invece analizziamo l'adozione nelle società di vendita al dettaglio online, telecomunicazioni, produzione e ingegneria high-tech queste hanno segnalato in un sondaggio un tasso di adozione di Chatbot previsto del 45% entro il 2020, con un'adozione effettiva del 31% entro il 2016 (Oracle Corporation, 2016). Sebbene i livelli di supporto all'adozione di Chatbot siano simili in tutti i settori, il divario tra l'adozione prevista e quella effettiva indica l'esistenza di una posizione ambivalente determinata dal sistema o determinata dal mercato (cioè percezioni, atteggiamenti e credenze). Per poter invertire la tendenza (van Offenbeek et al., 2013) il fenomeno deve essere esaminato in tutte le sue caratteristiche al fine di comprendere appieno le dinamiche costi-benefici che sottendono l'adozione di un agente conversazionale. Tuttavia, mancano studi che forniscano conoscenze teoriche o prove sistematiche sui meccanismi cognitivi, affettivi e comportamentali sottostanti che guidano l'adozione della tecnologia Chatbot.

Alla luce di quanto visto nelle pubblicazioni citate e dalle esperienze di questi ultimi anni occorre colmare una lacuna nella letteratura esistente. **Questo lavoro vuole fornire un contributo in tal senso, sviluppando un percorso di analisi dei dati di un caso reale, per poter esaminare e proporre possibili metodologie utili all'identificazione di metriche. Le metriche sono basate su un paradigma interpretativo funzionale volto ad identificare i fattori tecnico-economici che influenzano l'adozione e la diffusione di questa tecnologia.**

Scegliamo come un possibile punto di partenza di questa prima parte di trattazione un'esigenza primaria comune a tutte le aziende e/o agli utenti di un servizio: **umentare l'efficienza**. Negli anni abbiamo visto come questo obiettivo sia ormai quasi un sinonimo di automazione. La prima domanda fondamentale che dobbiamo porci quando pensiamo all'automazione dei processi aziendali è la seguente: "Cosa può essere automatizzato e cosa può, invece, essere fatto solo dagli umani?". Certamente non è una domanda né nuova né originale. Tuttavia, gli incredibili sviluppi a cui stiamo quotidianamente assistendo sia nell'apprendimento automatico che nel deep learning rendono la risposta a questa domanda un traguardo sempre più ambizioso. Abbiamo infatti visto come l'intelligenza artificiale stia diventando sempre più pervasiva nella nostra vita quotidiana e di come questa contribuisca a semplificarci semplici task quotidiani. Un esempio tanto sofisticato nella tecnologia quanto di uso sempre più comune è il navigatore. L'introduzione della tecnologia GPS ci ha permesso di conoscere la nostra posizione, in qualsiasi momento e luogo, con estrema precisione. Questo ha permesso, attraverso sofisticati algoritmi matematici, la creazione di un mercato crescente dei

<sup>5</sup> Sito web, mobile app, presenza sui social (twitter, facebook, ecc.), call center.

navigatori che ha profondamente modificato le nostre abitudini quotidiane. L'avvento successivo di rivoluzionarie tecniche di machine learning ha portato la fruibilità di questi strumenti ad un livello ancora più sofisticato. Attraverso l'adozione di google maps®, o prodotti simili (Waze® ecc.) è possibile interagire con lo strumento non chiedendo di portarci ad una via specifica, ma indicando direttamente il luogo che vogliamo raggiungere, che sia un negozio o una scuola. Poter indicare la "Facoltà di Economia dell'Università di Genova" anziché la "Via Vivaldi 5" rende più facile, intuitiva ed efficace la fruizione del servizio e quindi ne facilita la maggiore diffusione.

Se aggiungiamo informazioni semantiche al "contesto" è possibile cambiare radicalmente l'outcome del servizio migliorandone la fruibilità da parte dell'utente. L'aggiunta di tali informazioni permette anche di poter correlare informazioni creando, al contempo, ulteriori informazioni.

Nel nostro esempio correlare l'informazione semantica (Università) con una posizione geografica ci permette una migliore fruizione del servizio (il navigatore). Questo perché l'utente che non ha più bisogno di convertire il suo problema (devo recarmi all'università) nello spazio della soluzione (l'indirizzo preciso nel navigatore) ma tale conversione è fornita dal sistema stesso. Questo inoltre permette al sistema di inferire un'altra informazione che prima non aveva: "X è andato il giorno Y all'università" aggiungendo una informazione al suo patrimonio informativo .

Questo permette a questi strumenti di poter anticipare alcune nostre abitudini e consigliarci. Infatti i modelli di navigatori più recenti sono in grado di prevenire eventuali nostre esigenze e fornirci suggerimenti. Il navigatore, elaborando una serie di informazioni (posizione dell'auto, orario, percorso abituale,...) è in grado di anticiparci la situazione del traffico, inviandoci un messaggio del tipo *"con questo traffico potrai raggiungere l'ufficio in ... minuti"*. La combinazione di tecniche di intelligenza artificiale, statistica e inferenza semantica permettono a questi navigatori di facilitarci nella nostra personale mobilità, in maniera sempre più puntuale ed efficiente. I navigatori sono *agenti conversazionali*.

Esistono sul mercato diverse implementazioni commerciali di agenti conversazionali, più conosciuti come **Chatbot**. Il termine Chatbot è un neologismo che deriva dalle parole "Chat" e "Bot" per descrivere una conversazione "automatica" tra un utente e robot software (Schumaker et al., 2007; Puschmann, 2017).

Sempre più siti aziendali propongono Chatbot che permettono agli utenti, tipicamente clienti, di interagire con i sistemi dell'azienda utilizzando un linguaggio naturale. Il Chatbot è in grado di comprendere le richieste degli utenti e mapparle sui servizi interni. Il loro principale obiettivo è quello di fornire un punto di contatto attivo 24h al giorno in grado di rispondere alle richieste degli utenti nascondendo le complessità del sistema informativo interno. In generale i Chatbot sono caratterizzati da un limitato "set" di competenze e sono in grado di rispondere a servizi predeterminati tipicamente all'interno di un dominio applicativo decisamente ridotto.

Esiste un altro agente conversazionale, conosciuto come **Virtual Agent**, che è in grado di interagire con l'utente su domini molto differenti. Questi sono per lo più utilizzati all'interno dell'azienda per fornire servizi ai propri dipendenti, con l'obiettivo, comune ai Chatbot, di agevolare l'accesso ai servizi interni dei propri dipendenti mascherando le complessità dei servizi e delle procedure interne riducendo al contempo il costo dei servizi spostando il peso da workforce verso l'automazione. I Virtual Agent fondamentalmente agiscono come wrapper rispetto a servizi già esistenti e fruibili, rappresentano un'offerta alternativa e non come sostitutiva degli stessi. Infine l'eterogeneità dei domini applicativi rende molto più difficile la comprensione degli intent espressi dagli utenti. Inoltre la possibilità di interagire su ambiti eterogenei implica la capacità del Virtual Agent di dover cambiare contesto durante una conversazione. Questa è una caratteristica comune nelle conversazioni umane in cui è naturale sospendere un contesto, iniziarne un altro e poi riprendere il precedente dal punto in cui era stato interrotto. Prendiamo come esempio la prenotazione di un viaggio. Se pensiamo ad un Chatbot questo può essere implementato definendo i dialoghi possibili per permettere al bot di raccogliere tutte le informazioni necessarie per poter eseguire la prenotazione: data di partenza, data

di rientro, località, mezzo di trasporto, preferenze generiche. Queste sono alcune, molto semplificate, delle informazioni necessarie per poter eseguire una prenotazione.

Nel caso di un Virtual Agent possiamo immaginare che questo implementi sia lo scenario eTravel che lo scenario Meteo in grado di fornire all'utente le previsioni meteo di interesse. In questo semplice esempio i domini applicativi su cui il Virtual Agent può rispondere sono due: i viaggi e il meteo. A differenza di un Chatbot l'agente virtuale deve essere in grado di interagire avvicinandosi il più possibile al comportamento umano, per cui essere in grado di passare senza problemi da un contesto ad un altro. Se ipotizziamo un dialogo da un'agenzia di viaggi, questo potrebbe essere così rappresentato:

1. Cliente → Avrei bisogno di andare a Roma
  - 1.1. Impiegato → Quando? – Come? – Preferenze? Ecc.

A metà del dialogo il cliente potrebbe chiedere: "Quali sono le previsioni meteo?". Una persona umana sarebbe automaticamente in grado di colmare il "buco informativo" della data e della località in quanto implicite nel discorso. Inoltre, in qualsiasi momento del dialogo relativo alla prenotazione l'impiegato è in grado di riprendere il processo di prenotazioni senza richiedere informazioni aggiuntive.

Questo processo è tanto complesso per un software quanto importante per un utente. Dover "ripetere" informazioni per lui scontate potrebbero rendere l'esperienza di fruizione estremamente frustrante.

Nel caso aziendale la frustrazione nell'esperienza utente può portare gli utenti a non usare il servizio compromettendo seriamente gli investimenti fatti nel progetto. Poter gestire casi di questo tipo il sistema software molto più complesso ma molto più vicino ad una interazione naturale.

Con il progredire della tecnologia e gli ingenti investimenti da parte delle primarie società di software si è assistito al progressivo dilagare delle **comunicazioni basate sulla voce** che continua ad essere lo strumento di interazione più naturale. Strumenti come Siri® di Apple®, Alexa® di Microsoft o l'assistente di Google® utilizzano principi comuni alle tecnologie che approfondiremo in questo capitolo.

Possiamo quindi definire un agente conversazionale nel seguente modo:

---

*Un sistema di dialoghi che permette all'utente di interagire con altre funzioni software attraverso messaggi in linguaggio naturale.*

---

In un'interazione conversazionale il linguaggio naturale è, ovviamente, la caratteristica distintiva più importante che lo differenzia maggiormente dalle modalità di interazione uomo-macchina viste finora. Tale conversazione, a seconda del grado di raffinatezza e progettazione, può essere costruita:

- a. su una logica basata su alberi decisionale
- b. oppure attraverso un sofisticato sistema di domande in lingua naturale (NL).

Nel caso di alberi decisionali il sistema utilizza un algoritmo di pattern matching basato su regole per identificare le parole chiave nel testo di input e restituisce la risposta che si ritiene più correlata (Lucente, 2002; Schumaker & Chen, 2010). Esistono anche dei tentativi, seppur non troppo diffusi nei sistemi commerciali più moderni che sono in grado di estrarre gli intenti da un set di dialoghi precedenti che vengono clusterizzati utilizzando un algoritmo *k-means*. Quindi la query di input viene elaborata utilizzando algoritmi di elaborazione delle query come l'algoritmo Krovetz Stemming e l'algoritmo Parallel Stemmer. Dopo aver elaborato la query di input, i dati richiesti vengono recuperati dal sistema informativo e visualizzati all'utente finale (Shabariram, C. P e altri, 2017).

Nella nostra trattazione ci concentreremo esclusivamente sulla tipologia di interazione conversazionale basata su tecniche NLP. Approfondiremo quindi i sistemi che utilizzano strumenti di Machine Learning (ML) o Deep Learning (DL) per comprendere l'essenza della domanda attraverso una fase di training più o meno complessa che può passare anche attraverso una revisione supervisionata delle precedenti conversazioni.

L'introduzione della tecnologia Chatbot è iniziata nel 1966 con il programma per computer noto come ELIZA, uno psicoterapeuta virtuale basato su una semplice corrispondenza di parole chiave basata su regole. Negli ultimi anni, i gradualmente miglioramenti nelle tecnologie dell'informazione, dell'informatica, della comunicazione e della connettività hanno consentito nuove possibilità tecniche per l'adozione dei chatbot in diversi settori, già sopracitati, come l'assistenza sanitaria, il turismo e l'istruzione (Winkler & Söllner, 2018). Nel settore assicurativo, i principali segni dell'adozione e della diffusione della tecnologia Chatbot possono essere osservati nel mercato tedesco attraverso l'implementazione dell'assicurazione di viaggio ARAG Chatbot (ARAG, 2019) e dell'Assistente di lavoro Allianz Chatbot (Allianz SE, 2017). Entrambi usano Facebook come piattaforma per l'esecuzione.

Un altro caso molto interessante è stata l'introduzione di Tobi® da parte di **Vodafone®** (Vodafone 2019). È interessante notare il claim commerciale proposta dall'azienda stessa: "TOBi risponde a ogni tua esigenza: controlla le spese, attiva nuove offerte, propone configurazioni e molto altro. Disponibile sull'app My Vodafone, Whatsapp, Facebook Messenger, sito Vodafone, Alexa e messaggistica avanzata Android." Che mostra esplicitamente sia i servizi offerti che la omnicanalità descritta in precedenza. Sempre sul mercato italiano risulta interessante anche l'esperienza di Enel® (Enel 2019) in cui il claim è molto più tecnico e si concentra sulla storia e sui servizi offerti. «Credo che alla fine del secolo l'uso delle parole e l'opinione delle persone di cultura saranno cambiate a tal punto che si potrà parlare di macchine pensanti senza aspettarsi di essere contraddetti». Sono parole scritte da Alan Turing nel 1950, in un articolo dal titolo *Computing Machinery and Intelligence* pubblicato su una rivista scientifica inglese dell'epoca. Turing, che durante la Seconda Guerra Mondiale fu decisivo nel decodificare le comunicazioni naziste, viene considerato uno dei padri dell'informatica. Arrivando al tempo presente, il suo pensiero fu un pezzo decisivo della strada che avrebbe portato, nel giro di poco più di mezzo secolo, un cliente di **Enel Energia** a ottenere le informazioni di cui ha bisogno in una conversazione Facebook con un chatbot."

## Agenti conversazionali

Gli agenti conversazionali sono quindi sofisticati programmi software in grado di interagire con gli utenti per fornire loro informazioni o aiutarli nell'esecuzione di compiti specifici. Più semplicemente a fronte di domande espresse in forma testuale sono in grado di fornire una risposta, attraverso un'interfaccia utente più o meno sofisticata, ma libera e guidata da un **linguaggio naturale**. Questa caratteristica li differenzia fortemente dai programmi tradizionali.

Possiamo suddividere gli agenti conversazionali in due categorie principali: **chitchat e task oriented**.

- ❖ **Chitchat**: Questi sono adibiti unicamente a condurre una conversazione con l'utente senza un obiettivo preciso. Questo tipo di agenti sono più utilizzati in ambiente consumer ed esulano dagli obiettivi di questa discussione.
- ❖ **Informational**: Questi permettono di fornire informazioni specifiche e contestualizzate ad un utente
- ❖ **Task oriented**: Progettati per permettere all'utilizzatore di raggiungere un obiettivo attraverso un dialogo.

Nel caso "Task Oriented" possiamo modellare il dialogo per raggiungere un obiettivo specifico come un insieme ordinato di coppie domande/risposte progettate per raccogliere le informazioni necessarie per richiamare una funzione specifica. In generale per eseguire un determinato task  $\tau$  abbiamo bisogno di un set di parametri  $(\alpha_1, \alpha_2, \dots, \alpha_n)$ . Possiamo infatti immaginare che una determinata funzione aziendale possa

essere rappresentata da una API<sup>6</sup> che possiamo modellare come  $\tau(\alpha_1, \alpha_2, \dots, \alpha_n)$ . In questo caso il dialogo con l'utente ci servirà per raccogliere i parametri  $(\alpha_1, \alpha_2, \dots, \alpha_n)$  attraverso opportune domande. Seppure i dialoghi di tipo “chit-chat” siano molto diffusi e, da un punto di vista tecnico, estremamente stimolanti in questo lavoro ci concentreremo esclusivamente sulla tipologia di agente “task oriented” per cercare di capire quali grandezze influenzino o meno l'adozione del sistema. Attraverso le determinanti dell'adozione saremo poi in grado di definire il comportamento, che supporremo razionale, degli utenti per arrivare a definire un modello economico che possa permettere alle aziende di definire, in anticipo, gli investimenti necessari per realizzare un agente conversazionale e, di conseguenza, i ritorni economici derivanti dall'adozione dello stesso.

Dunque per rispondere a queste richieste del mercato, in questa trattazione concentreremo la nostra analisi sugli agenti conversazionali task-oriented. Il nostro obiettivo è quello di cercare delle metriche utili alla misurazione delle loro prestazioni. È un problema caratterizzato dalla complessità intrinseca di questi sistemi che interseca diversi domini di ricerca: dalla statistica, all'ingegneria e all'economia. L'approccio a questa ricerca empirica è basata su un reale caso di utilizzo. Abbiamo infatti potuto raccogliere le conversazioni degli utenti dipendenti di una importante realtà produttiva multinazionale italiana con un'importante presenza su tutto il territorio nazionale. L'obiettivo del progetto è quello di fornire ai dipendenti un sistema di intelligenza artificiale in grado di aiutare i dipendenti nel disbrigo di pratiche comuni come la prenotazione di riunioni o per fornire informazioni utili quali le informazioni sul cedolino o sull'organizzazione attraverso una moderna piattaforma conversazionale.

Introduciamo nella trattazione ancora un altro concetto quello del Natural Language Processing, poi ripreso nel capitolo successivo.

## Natural Language Processing (NLP) e Natural Language Understanding (NLU)

L'elaborazione del linguaggio naturale o Natural Language Processing (o NLP) è un insieme di tecniche per permettere ad un software di interpretare un testo. È un problema estremamente complesso che, ad oggi, è stato solo parzialmente risolto attraverso delle rappresentazioni più semplici che descrivono aspetti limitati delle informazioni testuali. Per quanto riguarda il nostro obiettivo possiamo limitarci a introdurre alcune definizioni relative ad un **sottoinsieme del NLP che è il NLU** (Natural Language Understanding). La definizione data da Gartner di NLU è la seguente:

---

*“the comprehension by computers of the structure and meaning of human language (e.g., English, Spanish, Japanese), allowing users to interact with the computer using natural sentences”.*

---

La comprensione del linguaggio naturale permette di interpretare il significato di un testo comunicato dall'utente attraverso una classificazione delle intenzioni esprimibili. Ad esempio, è relativamente facile per gli umani che parlano la stessa lingua capirsi, anche se errori di grammatica, scelta del vocabolario o dialetti specifici possono complicarlo. NLU si occupa di una serie di argomenti correlati alla comprensione del testo quali: la categorizzazione del testo, l'analisi del contenuto e l'analisi del sentiment.

Per i nostri scopi sarà sufficiente, dato un testo che descrive una richiesta dell'utente identificare, l'**intent** ossia l'intenzione che l'utente vuole esprimere e le **Named Entities**, ossia le entità collegate all'intent.

## Robotic Process Automation

Negli ultimi anni le primarie società di consulenza hanno coniato un nuovo termine: Robotic Process Automation (RPA). RPA è un termine generico che definisce una famiglia di strumenti in grado di far interagire

<sup>6</sup> Application Programming Interface

strumenti software differenti sfruttando le interfacce utente già esistenti in modo molto simile a come farebbe un essere umano. RPA permette di automatizzare questi processi attraverso una automazione “esterna” in sostanza senza la necessità che i programmi siano stati effettivamente progettati per interoperare. In questo modo il sistema informativo può rimanere invariato e non richiedere nuove versioni dei software che lo compongono. Gartner definisce Robotic Process Automation (RPA) come segue:

---

*Robotic process automation (RPA) is a productivity tool that allows a user to configure one or more scripts (which some vendors refer to as “bots”) to activate specific keystrokes in an automated fashion. The result is that the bots can be used to mimic or emulate selected tasks (transaction steps) within an overall business or IT process. These may include manipulating data, passing data to and from different applications, triggering responses, or executing transactions. RPA uses a combination of user interface interaction and descriptor technologies. The scripts can overlay on one or more software applications.*

---

Uno strumento RPA opera mappando un processo in un copione che il robot software esegue (Tornbohm 2017). Pertanto, gli strumenti RPA mirano a ridurre l'onere di compiti ripetitivi e semplici per i dipendenti (Aguirre e Rodriguez 2017). La caratteristica principale di questi strumenti è la capacità di eseguire compiti ripetitivi infinite volte e ad una velocità molto superiore a qualsiasi essere umano.

La sempre crescente necessità di ridurre i costi di produzione ha permesso negli ultimi anni un crescente aumento della domanda. L'RPA è attualmente visto come un modo per ottenere rapidamente un elevato ritorno sull'investimento (ROI). È relativamente semplice definire una metrica che ci permetta di capire quali processi automatizzare e come. In figura 1 abbiamo ipotizzato un semplice asse cartesiano in cui sull'asse delle ascisse poniamo le differenti tipologie di casi in cui un task si può presentare, mentre sull'asse delle y le sue occorrenze.

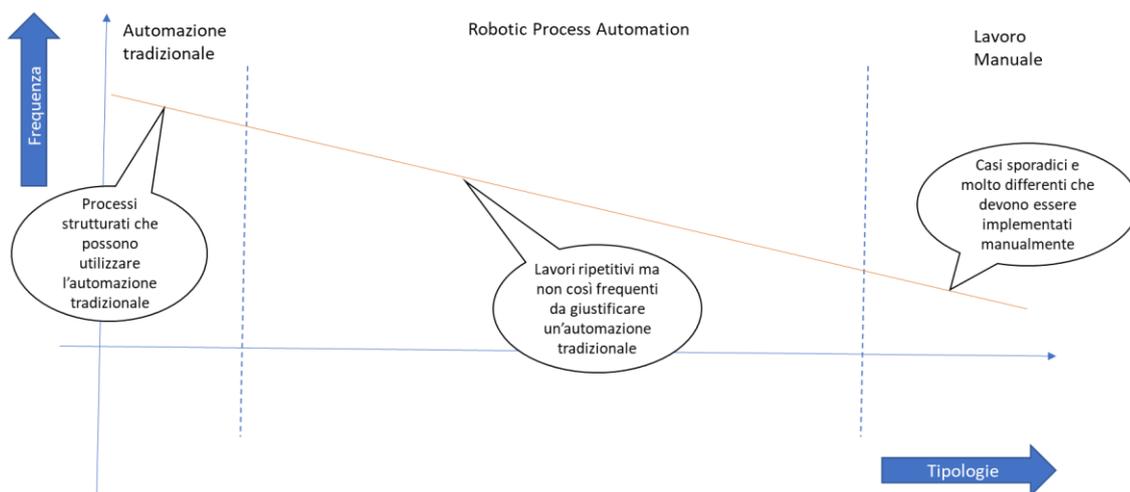


Figura 2 Tipologie di automazione in funzione dei task

In questo modo è facilmente intuibile che task che presentano poche tipologie di casi ed una elevata frequenza di utilizzo sono i candidati principali per una automazione “tradizionale” con software definito ad hoc e che permette di risolvere il problema nel modo migliore possibile. L'estremo opposto è dato da task utilizzati poco frequentemente e che si presentano con un elevato grado di variazioni sul tema. In questo caso, molto probabilmente, l'intervento umano rimane il più conveniente per la naturale capacità delle persone di adattarsi a contesti molto eterogenei. Nel mezzo troviamo tutti i naturali candidati ad essere

automatizzati attraverso l'utilizzo di tecniche RPA. In questa categoria possiamo infatti trovare lavori ripetitivi ma non così frequenti da giustificare un'automazione tradizionale e che, peraltro, si presentano in un limitato caso di alternative potendo quindi immaginare un'automazione basata su script.

La natura relativamente semplice dell'automazione tradizionale ha permesso di creare dei modelli di ritorno degli investimenti basati sul costo dello sviluppo del software, della manutenzione, della formazione e dei costi di esercizio. Ottenuti i costi è relativamente facile valutare i benefici diretti dell'adozione in termini di risparmi e/o riduzione degli errori. Gli enormi vantaggi che si possono ottenere con l'introduzione dell'automazione hanno reso anche quasi superfluo calcolare i ritorni "indiretti" quali il grado di soddisfazione degli operatori o dei clienti. Anche il modello per valutare il ritorno economico basato sulla RPA non è molto differente. I costi sono facilmente individuabili così come i benefici ottenibili dall'adozione di strumenti automatici.

Pur condividendo lo stesso principio ispiratore ed essendo entrambi software in grado di automatizzare e standardizzare compiti specifici, esiste tuttavia una differenza sostanziale tra un sistema basato su RPA e un Conversational Agent: la natura deterministica del primo, in confronto alla natura probabilistica del secondo. Nel primo caso, fornendo al software gli opportuni parametri, il sistema è sempre in grado di condurre l'utente al risultato. Un Conversational Agent, che interagisce con l'utente attraverso un'interfaccia conversazionale, al contrario si basa su strumenti probabilistici basati su tecniche di *Machine Learning* (in particolare NLP) che rendono il raggiungimento dell'obiettivo una probabilità che dipende da un insieme di fattori ma che, di solito, è abbastanza distante dal 100% del primo caso. Approfondiremo meglio in seguito questi concetti e vedremo anche che tale probabilità è condizionata da tre fattori principali: dalle tecnologie (software, hardware e algoritmi), dalla disponibilità di un adeguato training set e dalle domande fatte dagli utenti. Il terzo è un fattore spesso sottovalutato negli strumenti tradizionali. Vedremo che la capacità degli utenti di esprimere ogni domanda in uno statement corretto che l'agente possa comprendere non è così scontata e dipende da diversi fattori.

Data, dunque, la natura probabilistica dell'agente conversazionale le strategie adottate, almeno fino a questo momento, da parte delle aziende è quello di offrire un agente conversazionale *come alternativa rispetto ai sistemi tradizionali*. Questo comporta quindi, quotidianamente, una scelta da parte dell'utente se utilizzare il sistema tradizionale, ad esempio lo sportello telefonico, rispetto all'agente conversazionale.

### Il problema

Il nostro obiettivo è capire quali sono i fattori che maggiormente influenzano l'utilizzo di un agente conversazionale da parte degli utenti. Dobbiamo tenere conto che, nel nostro contesto specifico, i "servizi" che un agente conversazionale può garantire sono sempre offerti in concorrenza. Cioè è, generalmente, possibile ottenere la stessa risposta sia attraverso domande all'agente conversazionali o attraverso i sistemi tradizionali offerti dall'azienda stessa. Questo implica che un utente deve scegliere se utilizzare l'agente conversazionale o raggiungere i suoi obiettivi utilizzando le alternative. Intuitivamente possiamo pensare differenti fattori che possono influenzare la scelta dell'utente: la conoscenza del servizio stesso, la sua attitudine a fruire di servizi conversazionali, la qualità dei servizi offerti e la quantità dei servizi offerti. Tuttavia è necessario identificare quantitativamente i fattori che influenzano, positivamente e negativamente, la scelta del consumatore. In questo articolo analizzeremo il comportamento degli utenti nel periodo iniziale del lancio di un servizio conversazionale in una primaria azienda.

### Conclusioni

In questo primo capitolo abbiamo esplorato il contesto attraverso riferimenti a precedenti studi, definito il dominio legato ai virtual agent o agli agenti conversazionali, la loro diffusione sul mercato, citando esempi di agenti conversazionali utilizzati da big player del mercato. Abbiamo, inoltre, raccolto informazioni relative alle strategie che, verosimilmente, i player adotteranno al riguardo. Abbiamo, infine, evidenziato peculiarità degli agenti conversazionali rispetto ad altre tecnologie.



## CAPITOLO 2 User Behaviour

“I try to build a full personality for each of our cartoon characters - to make them personalities.”

**Walt Disney**

In questo capitolo analizzeremo il comportamento degli utenti del servizio conversazionale. L’obiettivo principale è riuscire a comprendere il comportamento degli stessi e cercare di identificare le dinamiche prevalenti in modo da poter modellare le determinanti della domanda.

Nella prima parte definiremo un vocabolario comune, mentre poi adatteremo alcune metriche derivate dalle ricerche nel mondo marketing che ci permettono di definire il comportamento degli utenti. In particolare, abbiamo studiato una tecnica di clustering degli utenti basata sulla “*customer value analysis*” per capire il posizionamento degli utenti nel nostro caso di studio.

Nella seconda parte proveremo ad esplorare delle tecniche alternative che ci possano permettere di anticipare il comportamento degli utenti basandosi sulle dinamiche inferite dai dati raccolti.

### Obiettivo

L’obiettivo di ricerca è l’identificazione di una metrica che ci permetta di **verificare l’effettiva adozione** e il relativo gradimento del servizio presso gli utenti. Riuscendo a distinguere gli utenti che gradiscono il servizio da quelli che lo hanno abbandonato dovremmo essere in grado di capire cosa non funziona per quegli utenti e quali correzioni occorre adottare. Dovrebbe inoltre fornire le basi per poter poi permettere di analizzare il ritorno dell’investimento. Possiamo comunque supporre che questo sia direttamente proporzionale al gradimento degli utenti.

Occorre quindi focalizzarsi sull’identificare le informazioni che rivestono una particolare importanza e significatività al fine di calcolare la retention degli utenti distinguendole da quelle relativamente meno importanti. Queste analisi adeguatamente strutturate diventano uno strumento di governance del servizio che, in prospettiva, potrà essere in grado anche di generare dati sulle richieste degli utenti, i dipendenti delle aziende, fornendo informazioni strategiche soprattutto in realtà particolarmente grandi e diffuse sul territorio la cui conoscenza del proprio personale è senza dubbio poco agevole ed estremamente dispendiosa.

### Il Contesto

Prima di affrontare il problema delle metriche è importante definire alcuni concetti propedeutici in modo da rendere la terminologia non ambigua. Come già visto esistono moltissime implementazioni di sistemi conversazionali. Per i nostri scopi, argomento dello studio, cominciamo con il distinguere tre tipologie principali di Virtual Agents: **conversazionali, informativi e transazionali**.

- ❖ **Conversazionali:** detti anche *chit-chat*, permettono di interagire con un utente umano parlando di argomenti anche decontestualizzati senza un obiettivo specifico. La valutazione scientifica della capacità colloquiale per questa tipologia di agenti è un problema di ricerca complesso e poco approfondito. La criticità principale dipende dal fatto che è difficile definire il successo della conversazione e, come nel caso dei dialoghi umani, la soddisfazione di un interlocutore con un robot potrebbe essere legata a fattori soggettivi come: quanto coinvolgente, coerente e piacevole è stata la conversazione.
- ❖ **Informativi:** rispondono alle domande degli utenti su domini specifici. Il loro obiettivo fondamentale è fornire informazioni utili a clienti o dipendenti.
- ❖ **Transazionali:** detti anche task-oriented. Sono progettati per fornire un servizio all’utente attraverso un dialogo. Possiamo modellare tale dialogo come un percorso necessario per raccogliere



tutte le informazioni necessarie per svolgere uno specifico compito. Il dialogo con l'utente ci servirà per raccogliere i parametri ( $\alpha_1, \alpha_2, \dots, \alpha_n$ ) attraverso opportune domande inserite in un dialogo appositamente progettato per cercare di capire quali grandezze influenzino o meno l'adozione del sistema.

La tipologia che andiamo a considerare in questo lavoro è l'ultima, il **Virtual Agente transazionale**, che permette l'utilizzo di specifiche funzionalità attraverso un'**interfaccia conversazionale**. Infatti è proprio un Virtual Agent Transazionale quello adottato dalla multinazionale italiana, di cui andiamo ad analizzare i dati reali.

### L'Interfaccia conversazionale

Un'interfaccia conversazionale può essere indifferentemente basata sul testo o sulla voce. L'obiettivo principale di questa tipologia di interfaccia consiste nel raccogliere dall'utente tutte le informazioni necessarie per compiere una specifica azione. Attraverso l'interfaccia si guida anche l'utente nelle diverse iterazioni permettendogli, in funzione del contesto, di modificare le sue scelte in modo da ottenere l'outcome desiderato. La differenza principale tra una interfaccia conversazionale e un qualsiasi altro programma informatico consiste nella capacità del software di comprendere quello che l'utente richiede. Per semplicità, da ora in poi, ipotizzeremo che l'interazione tra utente e chatbot avvenga unicamente attraverso lo scambio di messaggi testuali. Questo non toglie generalità all'approccio utilizzato in quanto con le tecnologie attuali, le conversazioni vocali vengono prima trasformate in testo e, quindi, applicate tutte le tecniche applicate alle conversazioni basate su messaggi.

### Natural Language Processing (NLP)

Dal punto di vista ingegneristico la principale problematica alla base di una interfaccia conversazionale risiede nell'interpretazione dei messaggi scambiati. Per poter rispondere adeguatamente alle richieste degli utenti è necessario, come prima cosa, comprenderne la richiesta.

Alcuni ricercatori fanno risalire i primi studi di NLP addirittura al 1950 quando il matematico inglese Alan Turing scrisse il famoso paper "Computing Machinery and Intelligence". Interessante la definizione di Natural language processing data da James Allen nell'enciclopedia di Computer Science del 2003: "Natural language processing (NLP) refers to computer systems that analyze, attempt to understand, or produce one or more human languages, such as English, Japanese, Italian, or Russian. The input might be text, spoken language, or keyboard input. The task might be to translate to another language, to comprehend and represent the content of text, to build a database or generate summaries, or to maintain a dialogue with a user as part of an interface for database/information retrieval."

Negli anni successivi diversi scienziati hanno pubblicato importanti lavori creando addirittura un filone di ricerca chiamato linguistica computazionale. Tuttavia, oggi tutti i principali vendor si stanno focalizzando unicamente su strumenti di machine learning ed è su questi che ci focalizzeremo in questo lavoro [4].

Tralasciando i dettagli tecnici è necessario introdurre alcuni concetti base che utilizzeremo nel seguito. Il primo concetto fondamentale è l'identificazione di un **intent**. Si tratta di identificare, dato un messaggio ricevuto da un utente, di identificare cosa l'utente vuol chiedere all'interno di un insieme finito che il sistema è in grado di trattare. Frasi come "vorrei prenotare un viaggio" oppure "ho bisogno di una sala riunioni" esprimono chiaramente due diverse intenzioni. Un altro problema estremamente complesso ma di fondamentale importanza è dato dalla identificazione delle **entità**. Tale funzione nota anche come NER (Named Entity Recognition) permette di identificare, all'interno di una frase, le entità significative all'interno di un contesto. Riprendendo gli esempi precedenti possiamo completare le frasi nel modo seguente: "vorrei prenotare un volo per giovedì" o "ho bisogno di una sala riunioni per 10 persone venerdì". Nella prima frase volo e domani sono due entità che esprimono due concetti fondamentali nel contesto di una prenotazione: il primo è la tipologia di trasporto di cui ho bisogno e il secondo della data in cui vorrei partire. Occorre notare

che, in molti casi, è anche necessaria una disambiguazione dei termini: che cosa significa giovedì? Il termine cambia significato a seconda del contesto. Dovendo prenotare una risorsa è evidente che ci riferiamo al futuro (diverso è, ad esempio, il caso in cui volessimo informazioni) e il “futuro” cambia in funzione della data attuale per cui se oggi è martedì intendiamo tra due giorni da oggi mentre se è venerdì intendiamo 6 giorni da oggi. Se invece ci riferiamo ad azioni passate come ad esempio “dammi il verbale della riunione di giovedì” è, per noi, implicito che ci riferiamo ad un giovedì passato rispetto ad oggi. Per cui il valore numerico (nel nostro caso una data) dovrà essere trasformata in modo differente a seconda del contesto della frase e del giorno in cui siamo oggi.

Vedremo nel seguito come l’accuratezza nell’identificare gli intenti e le entità giochi un fattore determinante nella valutazione complessiva dell’interazione con un sistema automatico.

### L’Agente conversazionale del caso reale analizzato

Come già anticipato brevemente, l’agente conversazionale ha visto inizialmente una diffusione al fine di fornire informazioni da parte di aziende, ad esempio i provider telefonici (tariffe, copertura geografica del servizio,...). In questi ultimi anni l’applicazione dei virtual agent è stata estesa anche per fornire supporto ai dipendenti interni per la fruizione di servizi.

I dati che analizzeremo in seguito sono quelli basati sul servizio offerto da una multinazionale italiana ai propri dipendenti, oltre 60 mila in tutto il mondo. Servizi che dovranno essere erogati in differenti linguaggi e su diversi ambiti, partendo da quello delle Human Resources (timesheet, cedolino,...), per ampliarlo alla comunicazione personalizzata su temi di interesse specifico, all’ eLearning per conoscere o partecipare a corsi o eventi o in ambito organizzativo.

Anche in questo caso reale, ha rivestito una notevole importanza la possibilità di accrescere gli ambiti applicativi senza dover modificare l’intero sistema. Come abbiamo visto questa è una delle principali differenze tra un chatbot e un agente conversazionale. Quest’ultimo è, infatti, in grado di offrire una interfaccia conversazionale in diversi ambiti. Poiché uno specifico ambito di conoscenze è definito **skill**, ovvero un insieme di azioni di cui può fornire risposte, un agente conversazionale offre diversi skills.

### Le metriche

Il primo obiettivo di questo articolo è definire le metriche principali di un agente conversazionale. È quindi necessario dare una definizione univoca di metrica. Per noi una metrica è

---

*una misura quantificabile univoca e ripetibile che viene utilizzata per valutare uno specifico stato di un definito processo aziendale.*

---

È importante rimarcare il concetto di ripetibile perché per i nostri obiettivi è necessario poter ripetere più volte un esperimento e i valori delle metriche associate non devono cambiare.

Un aspetto distintivo di un agente conversazionale rispetto a tutti gli altri servizi è che può funzionare in modalità completamente non supervisionata. Questo impone di poter verificare l’effettivo funzionamento, e il grado di soddisfazione degli utenti, in maniera indiretta e a posteriori. Introducendo un ritardo tra gli eventi e la loro misura. Diventa quindi importante introdurre delle metriche che possano dare, con il minor ritardo possibile, evidenza sulle diverse dimensioni del fenomeno. In questa analisi cercheremo di analizzare le reazioni degli utenti, in particolare la loro soddisfazione, analizzando il comportamento a posteriori degli stessi.



## L'esperienza

Il nostro esperimento consiste nell'analizzare le conversazioni tra gli utenti e il nostro agente conversazionale nel periodo tra il 10 di novembre 2019 e il 31 dicembre 2019. Si è deciso di analizzare tale periodo in quanto il **14 novembre** l'azienda ha deciso di estendere il servizio a tutti i dipendenti italiani dopo una fase sperimentale ristretta ad un gruppo chiuso di utenti. Potremo quindi esaminare l'effetto "lancio" in quanto il servizio è stato ampiamente pubblicizzato e portato a conoscenza di quasi tutti i dipendenti con ampio risalto nella comunicazione interna. Come è facile prevedere questo ha inizialmente generato un gran numero di contatti che poi si sono stabilizzati nel tempo. Questo ci ha permesso di rilevare le misure significative dell'effetto transitorio di lancio e le relative reazioni degli utenti. Nel periodo di sono registrate 10321 conversazioni con 119357 messaggi di cui 32488 degli utenti con 654016 caratteri scritti dagli utenti. Ipotizzando un comportamento razionale degli utenti dovremmo essere in grado, analizzando i dati, di suddividere gli utenti "occasionalmente", ovvero quelli attirati dalla novità, rispetto agli utenti effettivamente interessati al servizio. Il servizio è organizzato nel seguente modo:

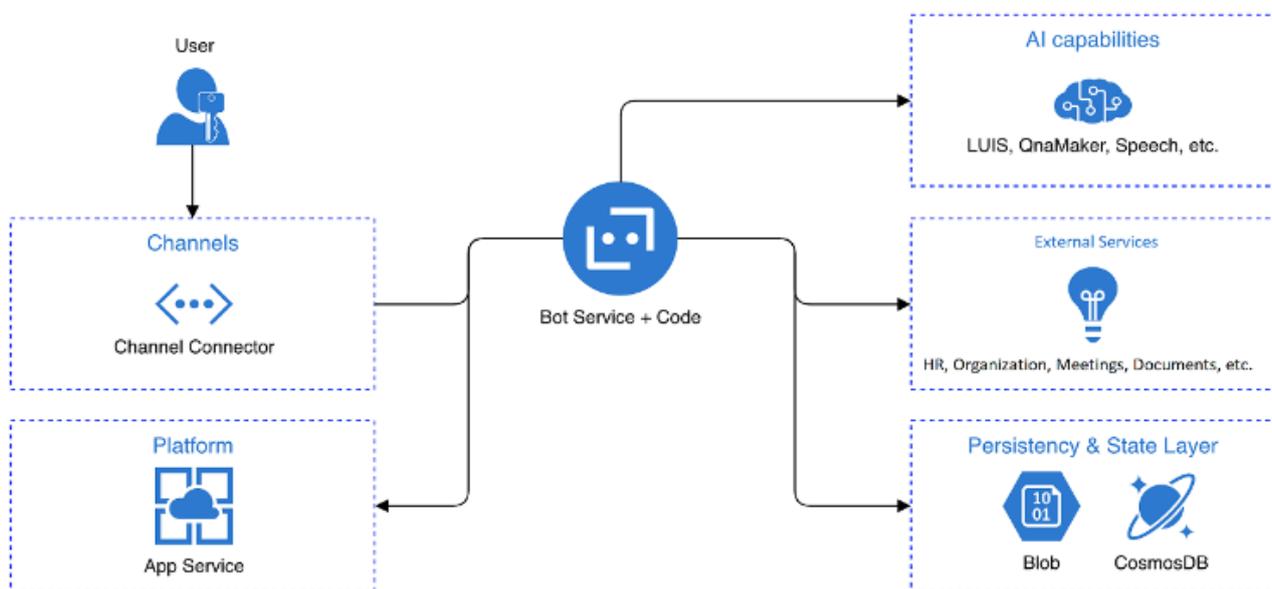


Figura 3 Architettura dell'Agente Conversazionale

L'agente conversazionale interagisce con l'utente attraverso un "channel connector" che permette al software di astrarsi rispetto ai protocolli fisici implementati dai diversi canali quali: telegram, skype, mail, web chat, ecc. una volta ricevuto un messaggio il bot richiede ad un servizio esterno l'interpretazione del messaggio attraverso un motore NLP (nel nostro caso utilizziamo LUIS di Microsoft®). Individuato l'intent e completata la fase di raccolta delle informazioni il BOT interagirà con i sistemi preposti dall'Azienda (nel nostro caso HR, organizzazione, documenti, ecc.) e, infine, salverà tutte le informazioni raccolte in uno storage da cui raccoglieremo le informazioni necessarie per questa analisi. La capacità di rispondere in modo appropriato alle richieste dell'utente è direttamente collegata alla capacità dell'agente conversazionale di comprenderle. Tale comprensione dipende dalla capacità dell'azienda di fornire al motore NLP esempi adeguati in modo che possa imparare a classificare in modo appropriato le richieste degli utenti. Senza entrare nei dettagli tecnici di tale meccanismo è evidente come la capacità di comprendere le richieste degli utenti influenzi in modo significativo la loro propensione all'utilizzo del servizio stesso. Nella nostra analisi aggiungeremo ai dati estratti dall'archivio un indicatore numerico che ci fornirà una indicazione indiretta della qualità della conversazione sostenuta dall'utente.

## La metodologia

Possiamo immaginare le conversazioni come modelli sequenziali di informazioni tempo-varianti. Il nostro obiettivo è quello di analizzare tali modelli sequenziali per estrarre delle regole associative che ci permettano

di rilevare comportamenti correlati al tempo nel database delle sequenze. Per ottenere ciò dobbiamo estendere la nostra analisi aggiungendo anche il tempo nell'analisi delle transazioni.

Dobbiamo quindi estendere il nostro modello di analisi perché non si fermi ad osservare le regole di associazione intra-transazione rappresentata, nel nostro caso, da un singolo dialogo. Per comprendere meglio il fenomeno occorre estendere la nostra analisi cercando i modelli inter-transazione considerando cioè l'insieme di dialoghi in cui siamo necessariamente costretti a considerare anche il tempo. La tecnologia di estrazione sequenziale dei modelli è stata applicata in molti domini, tra cui analisi dei tweet o dei post sui social media, analisi del comportamento di acquisto dei clienti, analisi delle cartelle cliniche, ecc. Data la quantità di dati da estrarre occorre anche considerare che il tempo impiegato per accedere ai dati potrebbe essere considerevole e dovremo pertanto considerare algoritmi mutuati dalle tecnologie "big data". Nella nostra sperimentazione trascureremo questi problemi che, comunque, possono essere risolti applicando vari vincoli nel processo di data mining sequenziale.

La metodologia RFM permette di esplorare tali pattern analizzando sequenze di dati tenendo in considerazione oltre alla **frequenza** due ulteriori vincoli: **recency** e **monetary**. In questo modo è quindi possibile determinare degli schemi sequenziali nei comportamenti che verranno classificati rispetto alle tre dimensioni analizzate: RFM (recenti, frequenti e monetari). Vediamo ora di analizzare le grandezze in gioco.

La **recency** è il periodo trascorso dall'ultimo acquisto e la **monetary** è la quantità di denaro spesa in un determinato periodo. Il vantaggio di considerare questi due fattori aggiuntivi è che ciò può garantire che tutti i modelli siano recenti, attivi e redditizi. L'algoritmo proposto utilizza le conversazioni come unità elementare a cui abbiamo aggiunto altre informazioni distintive derivate dal dialogo stesso. In particolare abbiamo calcolato il numero di query fatte dall'utente, il numero di messaggi inviati dal bot, il numero di volte in cui il bot non ha capito la richiesta, il numero di eventuali malfunzionamenti riscontrati ecc..

Sebbene l'efficienza del mining il set completo di modelli sequenziali sia stato sostanzialmente migliorato, in molti casi, il mining di modelli sequenziali deve ancora affrontare sfide difficili sia in termini di efficacia che di efficienza. Da un lato, potrebbe esserci un gran numero di modelli sequenziali in un database di grandi dimensioni. Un utente è spesso interessato solo a un piccolo sottoinsieme di tali schemi. Presentare il set completo di schemi sequenziali può rendere il risultato del mining difficile da capire e ancora più complesso l'utilizzo. D'altro canto, sebbene siano stati proposti algoritmi sempre più efficienti, il mining di una grande quantità di schemi sequenziali da grandi database di sequenze di dati è un'attività ancora molto dispendiosa. Se possiamo concentrarci solo su quegli schemi sequenziali interessanti per gli utenti, potremmo essere in grado di risparmiare molti costi di calcolo da quegli schemi poco interessanti che non aumentano il nostro patrimonio informativo.

L'interpretazione dei modelli estrapolati deve essere valutata con attenzione in funzione del contesto. Se analizziamo il settore delle vendite al dettaglio e consideriamo solo la frequenza potremmo trovare schemi che hanno scarso valore. Nel caso specifico della vendita al dettaglio tale informazione non ha un particolare valore proprio perché è molto comune che i consumatori acquistino spesso articoli a basso costo come tessuti, latte, succo di frutta o sapone, ma raramente acquistano prodotti costosi come gioielli o apparecchi elettronici. Senza considerare il valore monetario di un modello, i decisori troveranno un numero enorme di modelli economici, che hanno poco o nessun uso per aumentare il profitto di un'azienda visto anche che il comportamento degli utenti cambia nel tempo.

Dovremmo quindi categorizzare il comportamento degli utenti valutandolo contemporaneamente su più dimensioni. L'idea alla base di questa metodologia è proprio quella di includere il fattore di **recency** e il fattore **monetario** nel modello sequenziale di mining. Lo scopo principale dell'algoritmo proposto è quello di trovare modelli sequenziali che soddisfino i vincoli di frequenza, recency e monetari che vengono solitamente utilizzati dai ricercatori di marketing per effettuare la segmentazione dei clienti o del mercato.



I dati che l'agente conversazionale raccoglie sono orientati al tracciamento del processo. Dobbiamo pertanto applicare delle trasformazioni sui dati in modo da poter estrarre le informazioni rilevanti ai fini della nostra statistica. In questa metodologia empirica seguiremo una strada puramente statistica ed estrarremo le informazioni numeriche rilevanti analizzando le conversazioni registrate per categorizzare gli utenti in funzione delle loro conversazioni.

### L'Analisi Statistica

Come è possibile vedere in tabella 1 il numero di conversazioni è aumentato considerevolmente a partire dal 14 Novembre, data del lancio su tutti i dipendenti. È anche opportuno ricordare che, essendo un servizio offerto ai dipendenti, c'è un calo sensibile degli accessi durante i giorni festivi.

Dall'analisi di questo grafico possiamo estrarre alcune informazioni empiriche ma di sicuro interesse. La prima è che l'azienda ha investito parecchio per far conoscere il servizio. Questo lo si può ricavare dall'elevato numero di utenti univoci che hanno utilizzato il servizio le prime due settimane. I circa duemila utenti univoci delle prime due settimane rappresentano oltre il 30% del mercato potenziale.

La seconda informazione che possiamo ricavare è che l'effetto lancio rappresenta un transitorio e che, una volta passata la novità, solo gli utenti che trovano un effettivo beneficio dal servizio continueranno ad usarlo. Questo fenomeno provoca, naturalmente, un consolidamento del numero, su una base più o meno stabile. È anche importante notare che i maggiori lavori scientifici sul marketing hanno dimostrato che, in mancanza di novità, gli utenti tendono naturalmente ad abbandonare un servizio. Questo è, ovviamente, un caso particolare in quanto si rivolge ad un mercato specifico formato dai dipendenti di un'azienda di cui, ad oggi, non esiste letteratura sul tema. In questa prima parte del lavoro dobbiamo quindi individuare delle metriche che ci permettano di misurare la retention degli utenti. Identificando una metrica univoca saremo poi in grado di verificare le nostre previsioni in modo inequivocabile.

StartDate	ConversationId
2019-11-11	22
2019-11-12	28
2019-11-13	62
2019-11-14	587
2019-11-15	480
2019-11-16	54
2019-11-17	47
2019-11-18	381
2019-11-19	331
2019-11-20	259

Come si può notare abbiamo ricompreso nella nostra indagine anche i tre giorni precedenti al lancio in cui il servizio era disponibile solo ad un gruppo pilota che coinvolgeva un numero molto ristretto di utenti<sup>7</sup>.

Nella tabella seguente possiamo vedere che le conversazioni i giorni 11, 12 e 13 novembre erano nell'ordine di qualche decina rappresentando circa il 10% degli utenti abilitati. I due giorni del lancio (il 14 e 15 Novembre) tale numero è cresciuto di un ordine di grandezza. Possiamo quindi apprezzare in modo numerico l'effetto WOW come ricaduta degli investimenti nella comunicazione del nuovo servizio al lancio dello stesso.

Tabella 1 Andamento delle conversazioni per data

Possiamo vedere l'effetto WOW analizzando il numero di accessi nei mesi successivi al lancio. Nella figura seguente abbiamo quindi analizzato il numero di utenti univoci che hanno fruito del servizio nei mesi successivi al lancio. Possiamo quindi notare un andamento progressivamente decrescente che a partire dai picchi del giorno del

lancio cala progressivamente. Vediamo anche che mentre le prime due settimane presentano un numero elevato di utenti, tale numero è in forte diminuzione le settimane successive. Dalla terza settimana in poi si può apprezzare una stabilizzazione del numero di utenti univoci nell'intorno dei 150.

<sup>7</sup> Circa 300

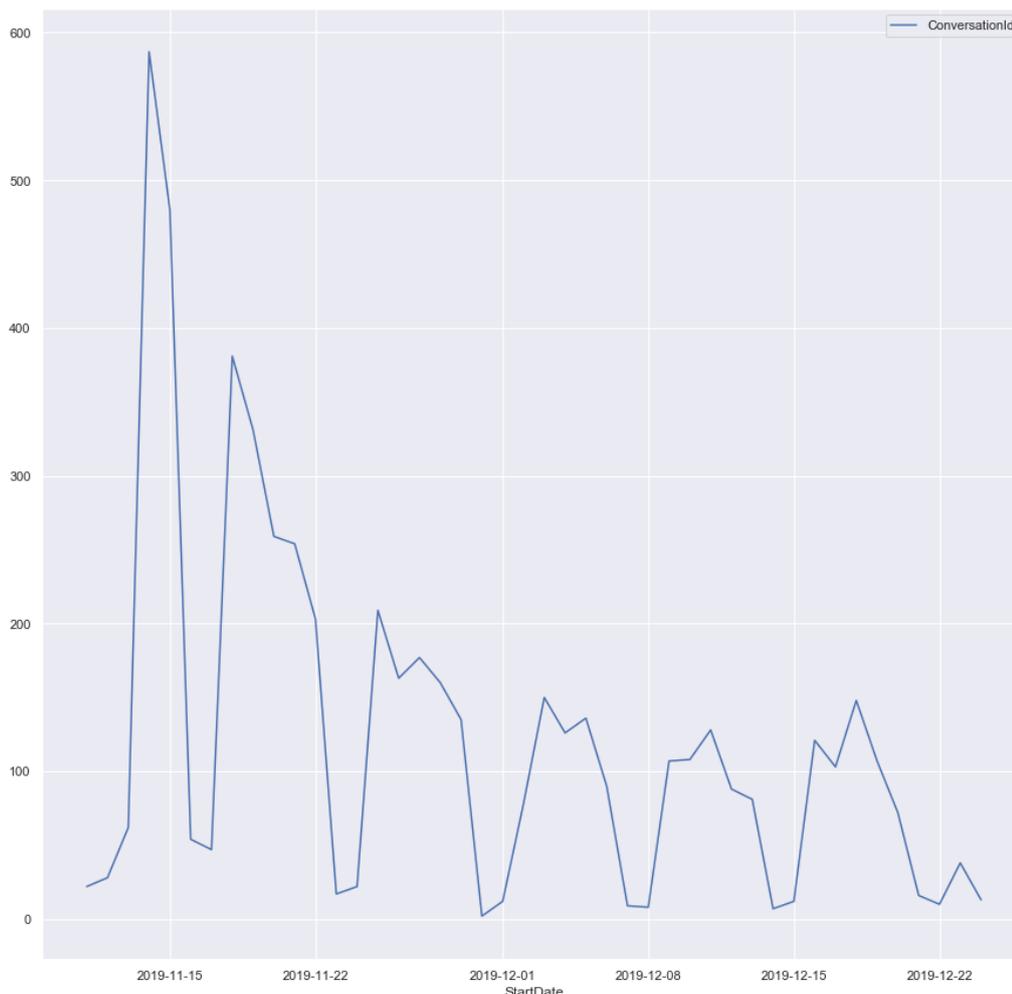


Figura 4 Andamento del numero di conversazioni nel periodo di osservazione.

Un'altra metrica molto utilizzata nel marketing delle aziende, specialmente nel mondo dei servizi, è quella legata all'andamento del numero di utenti. Questa metrica è indispensabile per valutare la profittabilità o il valore commerciale delle aziende che vendono servizi in abbonamento. Per queste aziende possiamo facilmente ipotizzare che il loro valore sia strettamente legato al numero di utenti "fedeli". Basti pensare alle aziende di telecomunicazione, alle aziende di streaming ma, più in generale, alle aziende che vendono abbonamenti. Per queste aziende è di fondamentale importanza valutare non solo gli utenti attivi ma anche il rischio potenziale di abbandono. Cercando su Google scholar è possibile vedere che cercando i paper per "churn prediction"<sup>8</sup> otteniamo oltre 4000 paper scientifici solo nell'ultimo anno.

Per quantificare l'oscillazione di questi utenti prendiamo da tali ricerche un parametro molto importante: il **retention index**. Tale valore indica il numero che rimangono attivi nel servizio in un determinato periodo di tempo. Nel nostro caso valutare questa metrica non è banale e, certamente, non è univocamente determinabile. La difficoltà deriva dal fatto che non essendoci parametri fissi ed oggettivi quali un contratto o un abbonamento il concetto stesso di "abbandono" è opinabile. Per poter definire la metrica abbiamo ipotizzato un periodo di osservazione pari ad una settimana. Questo ci permette una granularità abbastanza fine per misurare un fenomeno recente e ancora non consolidato. Per misurare al meglio gli effetti e le variazioni puntuali calcoleremo il retention index con una periodicità settimanale. Questo dovrebbe permetterci non solo di misurare l'effetto lancio ma anche di avere un quadro significativo anche su periodi più lunghi. Definiamo quindi il retention index come:

<sup>8</sup> Anno 2019 comprendendo brevetti e citazioni

Dato  $E$  il numero di utenti univoci alla fine del periodo,  $N$  il numero di nuovi utenti e  $S$  il numero di utenti all'inizio del periodo il **retention index** è calcolato come:  $\left(\frac{E-N}{S}\right) * 100$ .

In tabella 2 vediamo l'andamento degli utenti nelle settimane di osservazione che vanno dalla settimana 46 alla settimana 52.

Week	StartUsers	EndUsers	NewUsers	RetentionIndex	DropIndex
46	0	2151	2151	0.00	0.00
47	2151	1958	1466	22.87	77.13
48	1958	1162	838	16.55	83.45
49	1162	930	751	15.40	84.60
50	930	713	609	11.18	88.82
51	713	844	726	16.55	83.45
52	844	135	110	2.96	97.04

Tabella 2 Andamento del numero di utenti per settimana.

Come possiamo vedere il retention index per la seconda settimana, rispetto alla prima, è circa del 23% con un drop index superiore al 77%. Nella figura successiva possiamo vedere l'andamento del retention index nelle settimane:

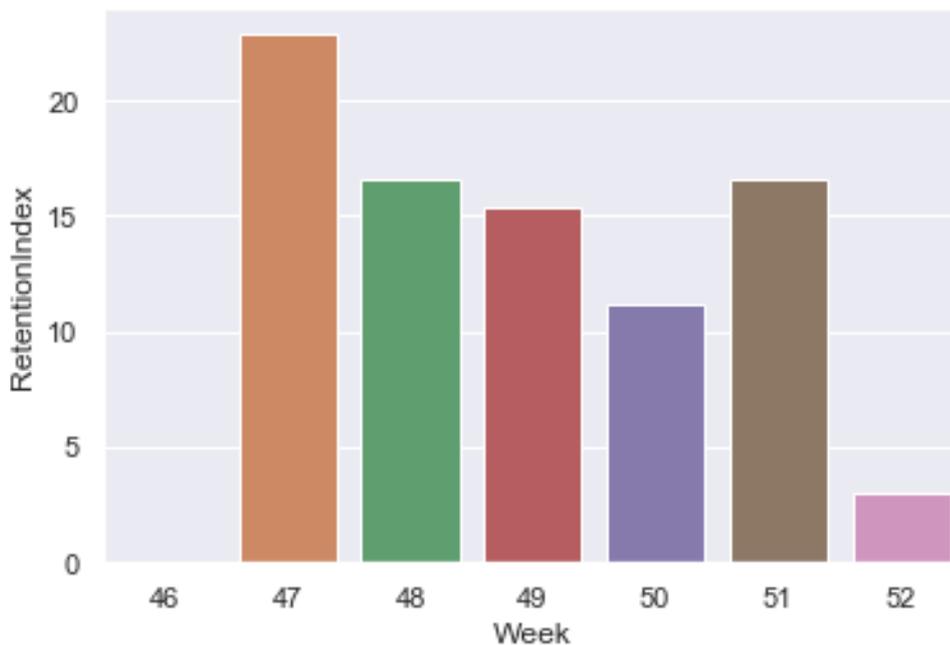


Figura 5 Andamento del retention index per settimana.

I dati della settimana 52 non sono attendibili in quanto ancora incompleti e sicuramente influenzati dalle festività.

Gli utenti

Il retention index ci dà una metrica chiara sul gradimento del servizio. Dato il range temporale definito per condurre le nostre analisi possiamo anche ricavare informazioni sugli effetti transitori del lancio. Possiamo

infatti notare che durante tutto il periodo hanno utilizzato il servizio 6821 utenti con oltre il 10% del numero totale di dipendenti ma con una distribuzione tutt'altro che omogenea.

L'obiettivo dell'azienda è quella di massimizzare l'accesso al servizio e incrementarlo nel tempo. Per fare ciò è importante capire le determinanti della domanda. L'obiettivo di questa parte dello studio è quello di sfruttare i moltissimi dati a disposizione per derivare empiricamente tali informazioni direttamente dai dati disponibili.

Il nostro obiettivo di ricerca, una volta identificata la metrica di riferimento che, nel nostro caso è la retention degli utenti, è quello di meglio comprendere le determinanti della domanda in modo da guidare l'evoluzione dell'offerta al fine di ottimizzare la predetta metrica.

## Il Clustering

Per identificare le discriminanti della domanda occorre definire un framework di analisi che ci permetta di investigare una ampia mole di dati orientando lo studio su gruppi di utenti omogenei. Durante la fase di studio abbiamo incontrato alcune realtà i cui dati generati dal bot superavano il terabyte di informazioni giornaliere per oltre 5000 conversazioni l'ora. Da questa esperienza risultano evidenti due considerazioni empiriche importanti. La prima è che l'elevato numero di contatti può rappresentare, in tempi relativamente rapidi, una base informativa enorme in grado di contenere importanti informazioni relative allo "stato" dei clienti: aspettative, richieste, umore ecc. La seconda è che esiste, naturalmente, una forte eterogeneità degli utenti che rende complessa e, probabilmente, poco utile una generalizzazione dei comportamenti su una platea così ampia. L'idea quindi alla base di questo lavoro è quella di provare a segmentare gli utenti in classi omogenee in modo da poter poi condurre analisi su campioni relativamente più omogenei. Condurremo quindi questa analisi identificando due metodologie. La prima è statica e deriva dalla metodologia RFM che descriveremo in seguito mentre nel secondo caso esploreremo una metodologia ancora immatura ma che promette, in teoria, di ricomprendere nella classificazione la dinamicità intrinseca degli utenti.

Il nostro obiettivo è quindi quello di creare cluster omogenei che ci permettano di studiare gli utenti e le loro conversazioni per identificare meglio le loro aspettative confrontando dati semanticamente omogenei investigando su quanto gli utenti abbiano apprezzato, o meno, il servizio.

## Recency Frequency e Monetary

Esiste una metodologia consolidata nel marketing che permette la classificazione dei clienti sulla base di 3 parametri: Recency, Frequency e Monetary o RFM. Tale metodologia si basa sostanzialmente sull'attribuire, per ciascun cliente, un punteggio in funzione di quando ha acquistato il prodotto privilegiando gli acquisti più recenti, quanto spesso compra e il volume monetario degli acquisti. L'idea è molto semplice calcoliamo l'ultima volta che hanno comprato il prodotto ogni volta comprano e il volume complessivo degli acquisti. Una volta ottenuti i valori delle tre grandezze vediamo, rispetto alla massa dei clienti a quale quartile appartiene ogni singolo cliente. Avremo quindi, ad esempio, l'indice 111 che rappresenta un cliente che appartiene al primo quartile in tutte le categorie. È di facile intuizione che rappresentano i nostri migliori clienti. Al contrario i clienti nel cluster 444 sono quelli che appartengono al 4 quartile in tutte le nostre categorie e, di fatto, sono i nostri peggiori clienti.

È una metodologia ormai consolidata che permette di condensare in forma numerica informazioni privilegiando la relazione tra utente e servizio piuttosto che il semplice valore della transazione. Tuttavia il nostro agente conversazionale, seppure molto simile, è sostanzialmente diverso in quanto non esiste un valore monetario diretto. Esiste un valore monetario, indiretto, legato ai risparmi indotti dall'utilizzo dell'agente conversazionale ma è al di fuori del nostro contesto di analisi.

## Recency, Frequency e Usage

Siccome abbiamo la necessità di adattare tale metrica al nostro contesto sostituiamo il valore monetario con l'utilizzo effettivo del sistema. Definiamo come utilizzo il numero di messaggi che l'utente invia all'interno di



una conversazione. Empiricamente possiamo immaginare che un uso “intensivo” del sistema sia caratterizzato da un numero significativo di messaggi inviati. Al contrario un utilizzo occasionale è caratterizzato da un numero limitato di messaggi. Ai fini della nostra ricerca abbiamo utilizzato Python come linguaggio per l’analisi dei dati e le librerie pandas e numpy per i calcoli. Come prima cosa abbiamo estratto i dati dal database di produzione e creato un archivio di testo realizzato accorpando i dati delle conversazioni. Abbiamo identificato alcuni parametri che abbiamo estratto dalle conversazioni e che sono: l’identificativo della conversazione, dell’utente, la data e la durata della conversazione il numero di messaggi inviati dal bot e quelli inviati dall’utente. Inoltre abbiamo raccolto alcune informazioni che ci potranno essere utili in approfondimenti successivi: il numero di topic (skills nella nostra nomenclatura) su cui il bot è stato interrogato, il numero di messaggi di “benvenuto” o di spiegazione del servizio, il numero di messaggi che il bot non ha capito e che ha richiesto chiarimenti all’utente, il numero di messaggi ritenuti offensivi e il numero di malfunzionamenti riscontrati dal bot. In particolare questi ultimi li abbiamo ricavati analizzando le risposte del bot che sono codificate in funzione di determinate casistiche e che abbiamo trasformato in valori numerici. Un esempio è riportato nella tabella seguente:

User	Language	StartDate	Duration	Turns	BotMessages	UserMessages	Skills	TotalSkills	Greetings	Confused	Offensive	Malfunctions
User00761	IT	2019-11-25 11:02:26	62	14	10	4	job	1	5	0	0	0
User02922	IT	2019-11-19 15:02:26	2	2	2	0	NaN	0	2	0	0	0
User04403	IT	2019-11-28 13:02:27	3	2	2	0	NaN	0	2	0	0	0
User01889	IT	2019-11-14 14:02:26	15	4	3	1	apptools	1	2	0	0	0
User01156	IT	2019-11-29 11:02:29	37	6	4	2	NaN	0	3	1	0	0
User01216	IT	2019-12-17 13:02:35	67	10	6	4	job-apptools	2	2	3	0	0
User02921	IT	2019-11-18 15:02:31	74	14	10	4	support-finalgreetings-apptools	3	7	0	0	0
User04013	IT	2019-11-18 12:02:32	28	10	7	3	eprofile	1	4	0	0	0
User01771	IT	2019-11-27 10:02:35	104	13	10	3	ticket	1	4	0	0	0
User05157	IT	2019-11-25 13:02:32	97	14	10	4	enelnumbers-apptools	2	5	0	0	0

Tabella 3 Elenco degli utenti con relative conversazioni

Date le conversazioni abbiamo costruito le aggregazioni sugli utenti in base ai tre assi identificati come mostrato nella figura seguente:

```
rfuTable = df1.groupby('User').agg({'StartDate': lambda x: (NOW - x.max()).days, # Recency
                                  'ConversationId': lambda x: len(x), # Frequency
                                  'UserMessages': lambda x: x.sum()}) # Usage Value

rfuTable['StartDate'] = rfuTable['StartDate'].astype(int)
rfuTable.rename(columns={'StartDate': 'recency',
                          'ConversationId': 'frequency',
                          'UserMessages': 'usage'}, inplace=True)
```

Figura 6 Aggregazione degli utenti

Possiamo quindi vedere le statistiche dei primi 5 utenti:

	recency	frequency	usage
User			
User00000	13	1	1
User00001	46	1	0
User00002	7	7	12
User00003	33	6	11
User00004	45	1	4

Tabella 4 Indici RFU calcolati per i primi 5 utenti.

Una volta calcolati i valori siamo in grado di clusterizzare i valori in funzione del quartile di appartenenza nel modo seguente:

```
quantiles = rfuTable.quantile(q=[0.25,0.5,0.75])
quantiles
```

	recency	frequency	usage
0.25	21.0	1.0	0.0
0.50	34.0	1.0	2.0
0.75	42.0	2.0	6.0

Tabella 5 Calcolo dei quartili

Possiamo quindi creare un indice combinando i valori di recency, frequency e usage. Ad ognuno delle tre dimensioni assegniamo un valore da 1 a 4 indicando con 1 il migliore e 4 il peggiore. Dobbiamo però tenere presente che per quanto riguarda recency, più valore alto peggio è. Mentre vale il contrario per gli altri due indici. Nella tabella seguente è riportato il risultato dell'applicazione di tale algoritmo:

	recency	frequency	usage	R_Quartile	F_Quartile	M_Quartile	RFUClass
User							
User00000	13	1	1	1	4	3	143
User00001	46	1	0	4	4	4	444
User00002	7	7	12	1	1	1	111
User00003	33	6	11	2	1	1	211
User00004	45	1	4	4	4	2	442

Tabella 6 Calcolo della classe RFU per i primi 5 utenti.

Come possiamo notare l'utente User00002 è il migliore della nostra lista in quanto appartiene al primo quartile per tutti e tre i parametri: bassa recency (7) alta frequency (7) e alto usage (12) generando quindi un indice pari a 111. Al contrario l'utente User00001 è il peggiore in quanto ha usato il servizio una volta sola 46 giorni fa non mandando neanche un messaggio. A questo punto possiamo vedere il numero di utenti per cluster. Come possiamo vedere le prime settimane di utilizzo del servizio sono caratterizzate da uno squilibrio degli utenti verso il lato destro del grafico che identificano gli utenti con meno propensione all'utilizzo del servizio stesso.

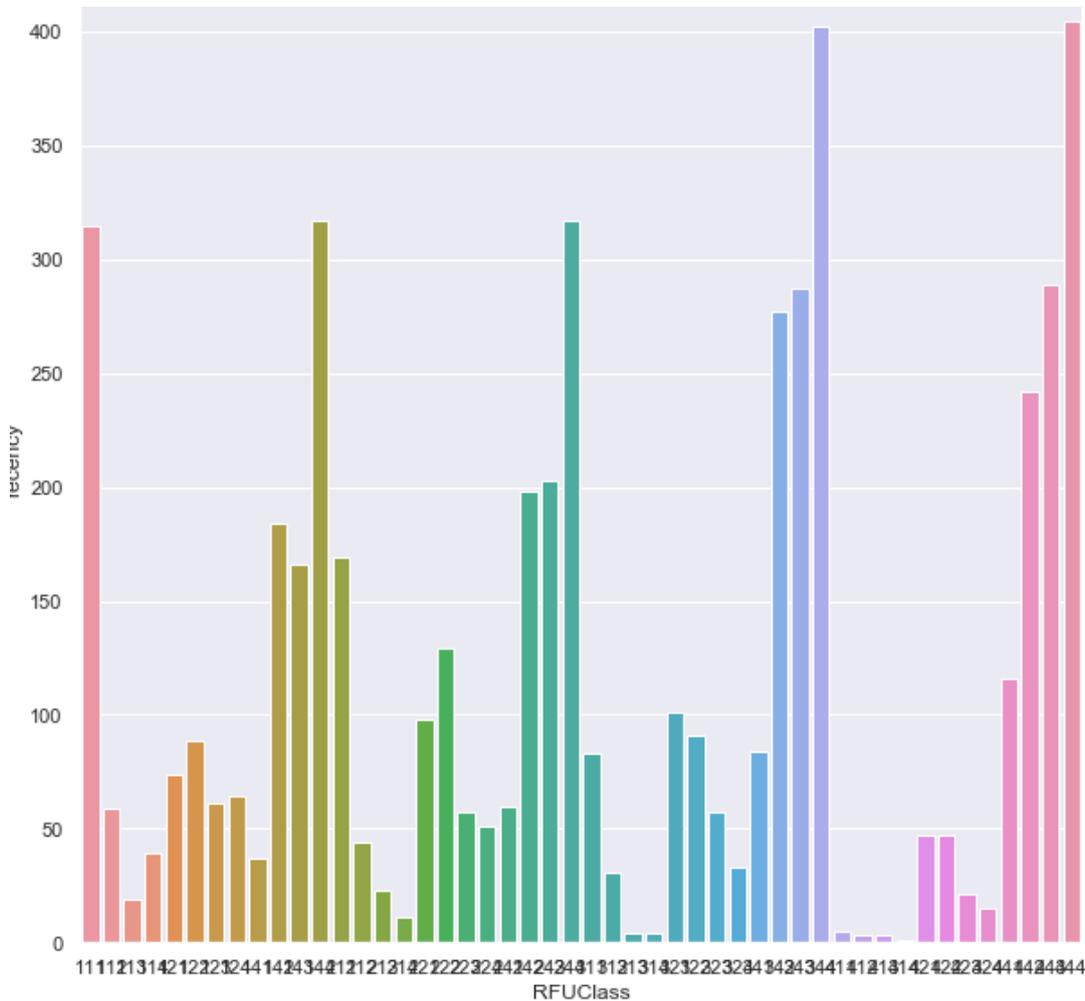


Figura 7 Distribuzione degli utenti in funzione dell'indice RFU

### Dynamic Time Warping

In questa seconda parte del primo capitolo abbiamo deciso di provare ad analizzare il comportamento delle sequenze temporali degli utenti. Se infatti prendiamo il nostro dataset contenente le conversazioni di ogni utente possiamo verificare che ognuno di essi è costituito da un insieme di punti. Nelle nostre ipotesi un punto è l'inizio di una nuova conversazione ed è caratterizzato da un insieme di attributi che abbiamo ricavato dalla nostra base dati e che identificano una conversazione. Gli attributi che si sono ritenuti significativi e che sono stati aggiunti ad ogni conversazione sono i seguenti:

1. Linguaggio<sup>9</sup>
2. Data di inizio della conversazione
3. Data di fine della conversazione

<sup>9</sup> Il linguaggio utilizzato dall'utente (nel nostro caso solo IT o ES)

4. Durata<sup>10</sup>
5. Numero totale di messaggi scambiati
6. Numero di messaggi inviati dal bot
7. Numero di messaggi inviati dall'utente
8. Numero di messaggi di benvenuto
9. Numero di volte che il bot non ha capito<sup>11</sup>
10. Numero di messaggi ritenuti offensivi
11. Numero di malfunzionamenti durante la conversazione
12. Numero di click premuti dall'utente
13. Numeri di concetti non compresi da NLP<sup>12</sup>
14. Valore medio del confidence factor degli intent riconosciuti

Se prendiamo un utente possiamo rappresentare su un diagramma cartesiano le sue interazioni con il servizio. Possiamo ipotizzare l'asse delle x come il tempo e disegnare un istogramma con il valore della durata della conversazione.

In questo caso abbiamo il comportamento, legato ad una sola grandezza, di due utenti che varia nel tempo. Come possiamo vedere in figura ogni utente ha una propria signature che caratterizza il suo comportamento.

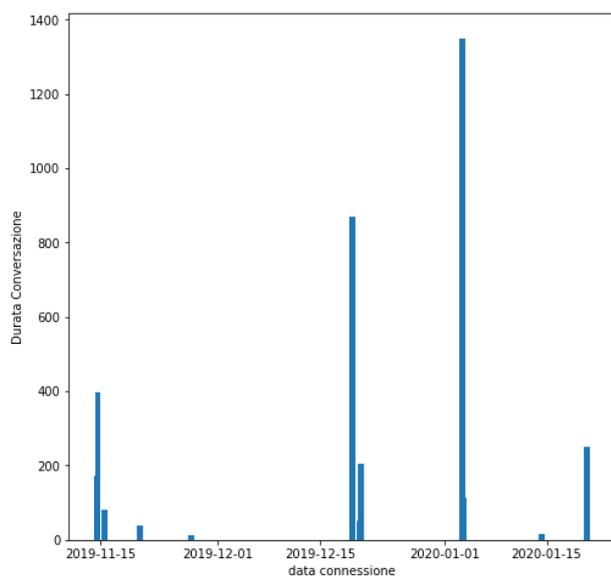


Figura 8 Andamento durata conversazioni Utente1

<sup>10</sup> In secondi

<sup>11</sup> Una frase che l'utente ha detto e che ha bisogno di precisazioni da parte dell'utente

<sup>12</sup> Indica tutte le volte che il risultato del motore NLP è inconcludente ma che potrebbe essere comunque stato compreso dal BOT.

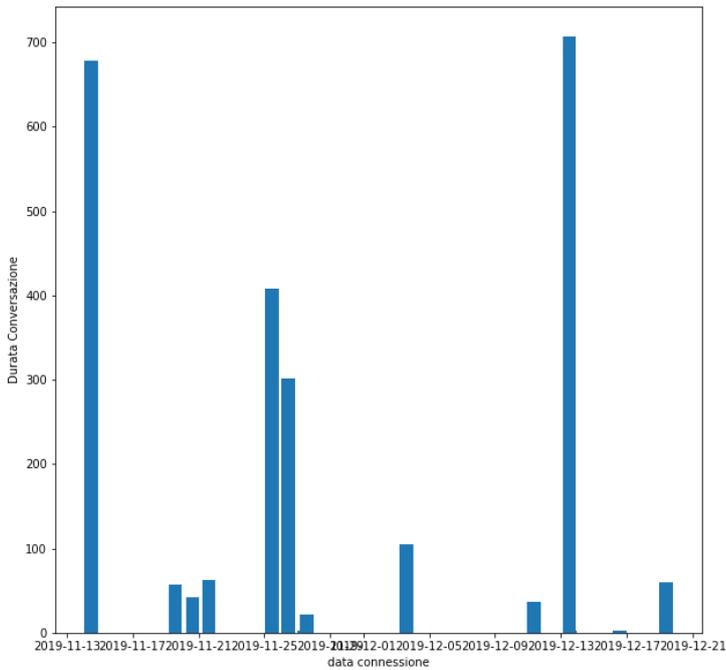


Figura 9 Andamento durata conversazioni Utente2

Come si può vedere chiaramente dagli ultimi due grafici la signature è molto differente per i due utenti. Possiamo tracciare i due grafici per qualsiasi grandezza associata alla conversazione di un utente.

Di seguito tracciamo gli stessi grafici mostrando però il numero di messaggi inviati al bot dall'utente per conversazione. In questo caso l'informazione è molto diversa e il pattern cambierà come valori ma, ovviamente, non come frequenza nel tempo essendo grandezze differenti relative però agli stessi eventi<sup>13</sup>.

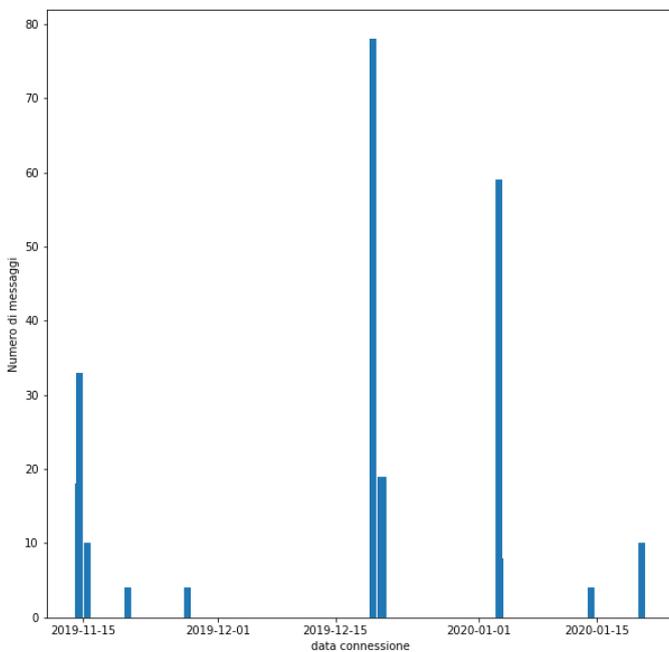


Figura 10 Numero di messaggi nel tempo per l'utente 1

<sup>13</sup> Nel nostro caso la conversazione

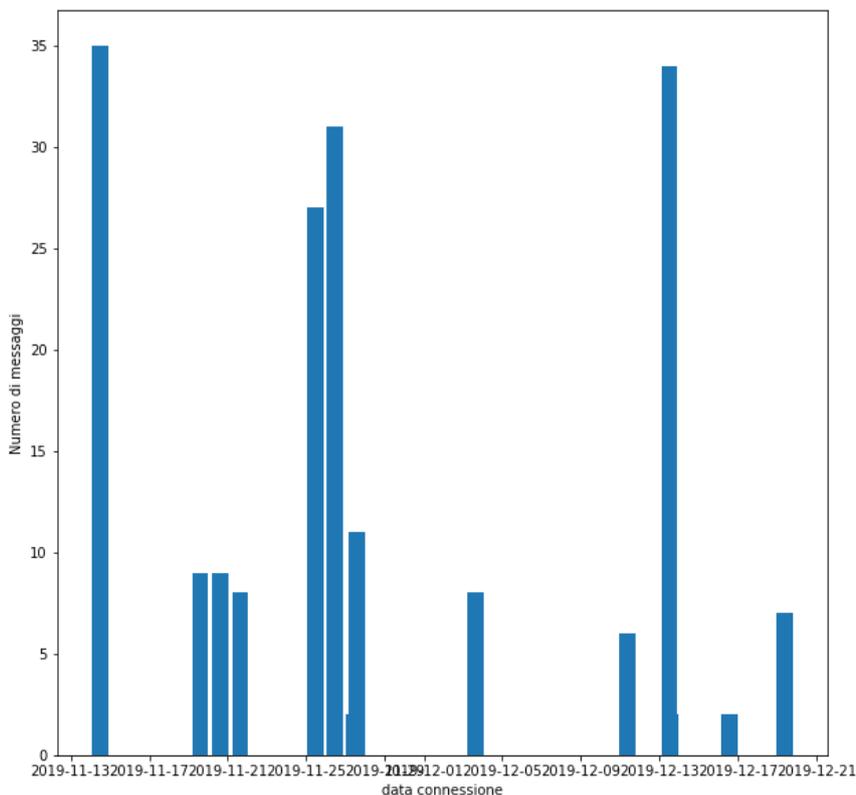


Figura 11 Numero di messaggi nel tempo per l'utente 2

Per capire meglio la differenza di signature del comportamento degli utenti rispetto al numero di messaggi possiamo confrontare i valori assoluti costruendo un grafico che, normalizzando l'asse dei tempi, permette di valutare la differenza tra le due grandezze come mostrato nella figura seguente.

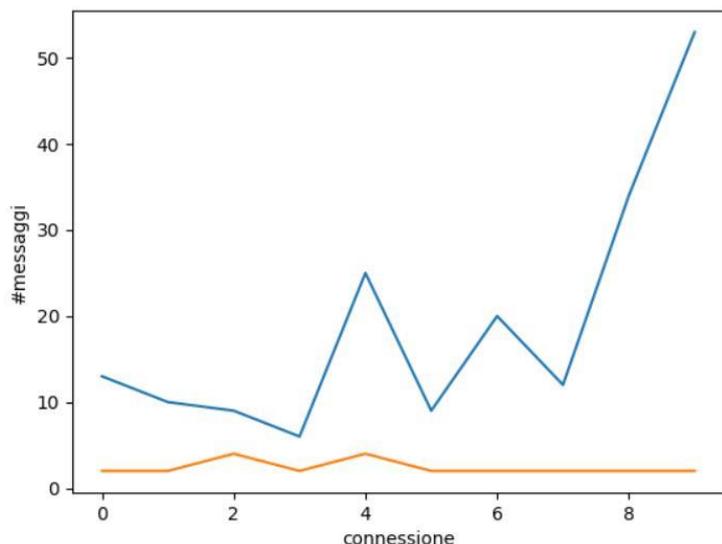


Figura 12 Confronto tra il numero di messaggi fra utenti nel tempo

In 2 possiamo quindi notare la differenza di comportamento tra due utenti in riferimento al numero di messaggi. Per meglio confrontare la differenza tra i valori del numero di messaggi abbiamo normalizzato l'asse del tempo. Sull'asse x quindi abbiamo riportato, in questo caso, il progressivo della conversazione per meglio confrontare i due comportamenti molto differenti. Nelle nostre analisi useremo come parametro



temporale la distanza rispetto all'origine che considereremo il go-live del servizio. Questo perché il tempo rappresenta una grandezza fondamentale per classificare il comportamento degli utenti.

Se estendiamo il concetto a tutti gli utenti, abbiamo un gruppo di serie temporali uniformemente distribuite nel nostro intervallo di osservazione ognuna rappresentante diverse grandezze. L'obiettivo è raggruppare le serie temporali definendo schemi generali presenti nei dati. Come vedremo meglio nel seguito una caratteristica distintiva di questo gruppo di serie temporali è che queste hanno una bassa densità informativa. È infatti semplice immaginare che le interazioni tra gli utenti e il nostro agente conversazionale siano nell'ordine di una o due per settimana. Questo implica che ogni serie è caratterizzata da un numero relativamente basso di campioni.

Per l'analisi delle somiglianze dei comportamenti abbiamo deciso di adattare un algoritmo utilizzato in passato per l'analisi di sequenze tempo-varianti. Il dynamic time warping o deformazione temporale è uno degli algoritmi più utilizzati per misurare le somiglianze tra due serie temporali. La deformazione temporale appare naturalmente soprattutto nelle attività di esseri umani. Possiamo infatti notare che una persona può riprodurre uno stesso movimento o, anche più frequentemente, lo stesso discorso a un ritmo e un'accelerazione diversi. Per la mente umana è facile aggregare comportamenti simili, seppure molto diversi, e dare anche un giudizio numerico sulla somiglianza. Basta pensare al lavoro continuo che fanno, ad esempio, i medici nelle attività riabilitative o gli istruttori sportivi. Tuttavia questa è un'operazione estremamente complessa per un algoritmo che non può, semplicemente, misurare le distanze tra due sequenze perché basterebbe anche un minimo sfasamento temporale per renderlo del tutto irriconoscibile. La distorsione temporale è presente anche in sequenze d'azione discrete. Dynamic Time Warping (DTW) è una misura della distanza che è stata utilizzata in dozzine di lavori di ricerca sull'estrazione di dati di serie temporali equamente campionati (*Keogh 2002*).

Molti di questi lavori hanno dimostrato che attraverso un semplice raggruppamento gerarchico dei dati si possono clusterizzare con successo gli schemi giornalieri di una persona utilizzando la distanza Dynamic Time Warping (DTW) invece della distanza euclidea che è ancora ampiamente usata.

L'idea nasce da un articolo scientifico del 1978 (*Sakoe, Chiba*) in cui si propone un algoritmo per il riconoscimento del parlato. In particolare, il documento riporta un algoritmo di **normalizzazione temporale** basato sulla programmazione dinamica ottimale (DP) per il riconoscimento delle parole. Nell'articolo viene introdotta una funzione di time-warping in modo da normalizzare una forma d'onda nel tempo, che è il concetto alla base del nostro esperimento.

L'idea alla base dell'esperimento è quella di superare il concetto di RFU introducendo una clusterizzazione degli utenti che permetta l'analisi delle dinamiche nel tempo piuttosto che il comportamento "statico" tipico dell'analisi RFU. L'analisi RFU è molto importante per definire cosa "sono" i nostri utenti e caratterizza più che adeguatamente alcuni cluster, in particolare, il cluster "111" e "444" che rappresentano rispettivamente i nostri clienti migliori e peggiori. È molto più difficile invece, proprio a causa dell'assetto statico dell'analisi, interpretare tutti i cluster intermedi. Nell'analisi classica questo problema viene superato con importanti analisi successive che sono però, necessariamente, calate sulla realtà specifica e possono difficilmente essere astratte per definire comportamenti più generici o adattabili in contesti differenti.

### La metodologia

DTW è una tecnica che permette di ricavare la similarità di due serie di dati ordinati nel tempo, anche di durata differente (anche se nel nostro caso utilizzeremo solamente timeseries con lo stesso numero di samples).

Prendiamo ad esempio due segnali sinusoidali che durano 10 secondi, quanto sono simili? Uno dei due viene preso come segnale di riferimento, l'altro come segnale da testare. Imponiamo che i sample iniziali combacino, così come i sample finali. Andiamo a costruire una matrice quadrata, ad ogni colonna corrisponde

un sample del segnale di riferimento e a ogni riga corrisponde un sample del segnale da confrontare: ogni cella della matrice rappresenta allora una coppia di sample del tipo (riferimento, segnale). Per ogni sample del segnale da confrontare cerchiamo il sample, nella timeseries di riferimento, che ha distanza minima da esso, ed evidenziamo la cella corrispondente. La matrice risultante evidenzia il **warping path**, cioè il modo in cui dovremmo "mappare" i due segnali per renderli uguali. La **warping distance** è la somma di tutte le distanze precedenti.

### L'algoritmo

Il primo passo è quello di estrarre i dettagli delle conversazioni degli utenti che utilizzeremo per creare delle nuove features che useremo per arricchire i dati di utilizzo del bot. Un parametro fondamentale è la data di partenza del servizio che fissiamo al 14 novembre 2019, per attenuare l'effetto wow abbiamo pensato di applicare una funzione sigmoideale  $f(x) = \frac{1}{1+e^{-(x+11)}}$  (Equazione 1) che permette di esaltare gli accessi più recenti e penalizzare quelli più vicini al lancio del prodotto. L'andamento della sigmoide è mostrato in figura. La traslazione della sigmoide permette di calibrare la "saturazione" della funzione, che nei dintorni dell'origine assume valori nulli, a metà del dominio (11 giorni) prende il valore 0.5 e tende poi asintoticamente per  $x \rightarrow \infty$  a tende a 1.

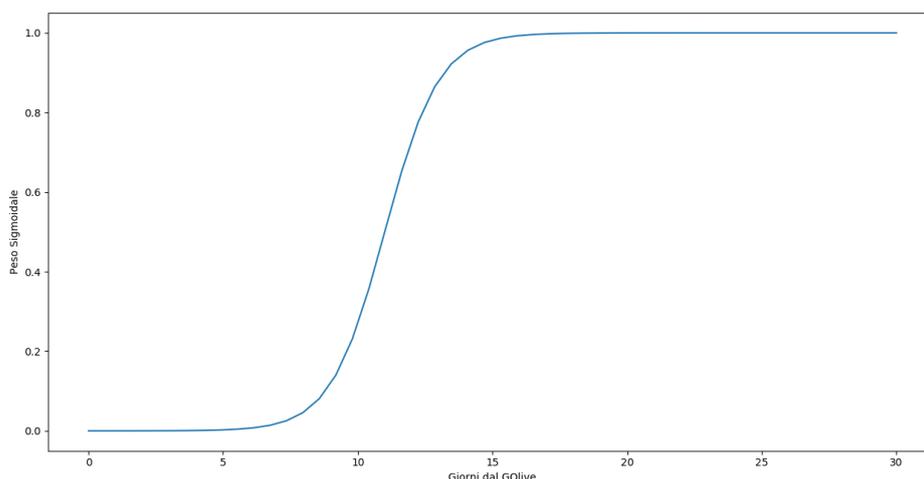


Figura 13 Andamento della sigmoide che attenua il peso degli accessi intorno alla data del go live

Consideriamo le connessioni al servizio degli utenti e consideriamo i dati a partire dal GOLive come mostrato in figura:

```
#Prendo solo i dati dopo il secondo GOLive, del 14 Novembre 2019
df_user = df_login[df_login['timestamp']>Golive].reset_index(drop=True)
df_user['fromGolive!'] = df_user['timestamp'] - Golive
df_user.head(5)
```

	conversationId	usermail	timestamp	Datekey	fromGolive!
0	102OfFrCyAE5F4G1qEtFspr-h	5EIDfZmPCgV30xypiPBHRLWwXSmSXoEq1b1DLf4TXwluC7...	2020-01-07 14:47:20.627	20200107	54 days 14:47:20.627000
1	10BLjA6QSyHGx7FWAdR4Fj-h	5EIDfZmPCgV30xypiPBHRLWwXSmSXoEq1b1DLf4TXwluC7...	2019-11-25 09:50:00.843	20191125	11 days 09:50:00.843000
2	10CMACBSf7slZPPSp4vG4v-h	5EIDfZmPCgV30xypiPBHRLWwXSmSXoEq1b1DLf4TXwluC7...	2019-11-19 13:13:43.170	20191119	5 days 13:13:43.170000
3	10KgtiBusbn5ubHmRY3KYQ-h	5EIDfZmPCgV30xypiPBHRLWwXSmSXoEq1b1DLf4TXwluC7...	2019-11-28 11:55:27.580	20191128	14 days 11:55:27.580000
4	10KSzNnVr0DYEEnUKG9tUI-h	5EIDfZmPCgV30xypiPBHRLWwXSmSXoEq1b1DLf4TXwluC7...	2019-11-14 12:32:06.550	20191114	0 days 12:32:06.550000

Una volta assegnati i pesi alle conversazioni abbiamo creato un pattern "generico" di utilizzo: per ogni utente  $k$ -esimo è stato calcolato l'intervallo medio  $\tau_k$  fra una conversazione e la successiva, e la relativa deviazione

standard  $\sigma_k$ . Il tempo medio di riconnessione per utente  $\tau_k$  viene confrontato con l'intervallo in giorni fra due conversazioni consecutive  $\delta_{ij}^k = c_i^k - c_j^k$ , e a ognuno di questi viene assegnato uno score secondo la regola

$$s = \begin{cases} 1 & \text{se } \delta_{ij}^k \leq \tau_k \\ -1 & \text{se } \delta_{ij}^k > \tau_k \end{cases} \quad \text{Equazione 2}$$

Questi score vengono salvati per lo stesso utente in una lista, alla voce "normalized\_pattern" del dataframe.

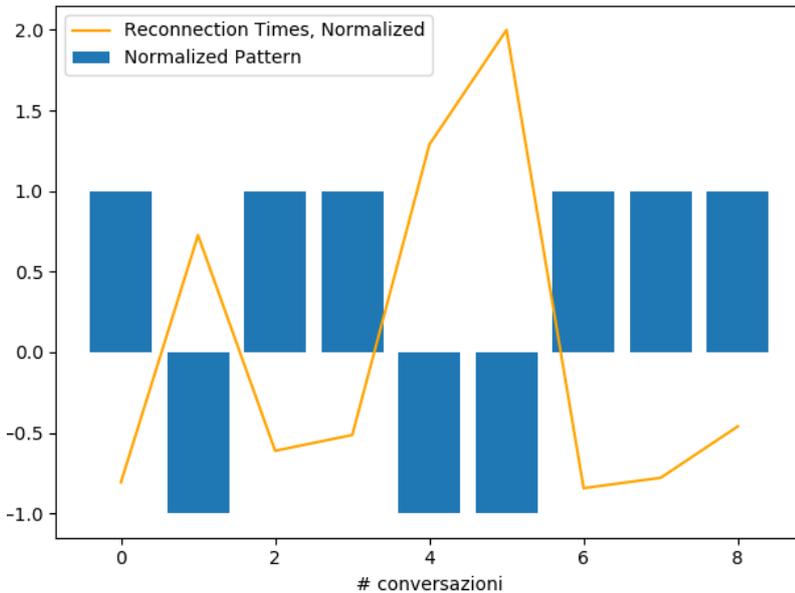


Figura 14 Utente 1: Tempo di riconnessione e Pattern normalizzato

Vediamo ora il comportamento con queste modifiche dell'utente 2, rappresentato nella figura seguente:

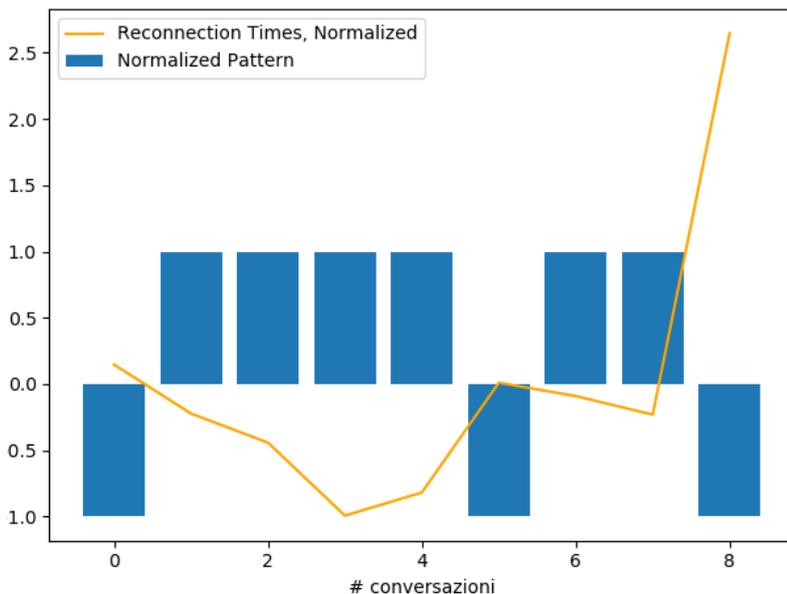


Figura 15 Utente 2: Tempo di riconnessione e Pattern normalizzato

Il "pattern normalizzato" di ogni utente viene impiegato per modellare l'utilizzo dell'agente conversazionale. Viene sommato ogni elemento di un singolo pattern per ricavare uno score ("score"): a parità di numero di conversazioni, un utente con uno score alto si è connesso in modo più costante di un utente con uno score basso. Il pattern viene trattato come una serie numerica, in cui all'intervallo di tempo  $n$ -esimo fra due

conversazioni associamo l'elemento  $n$ -esimo del pattern: si calcola a partire da questo il fit lineare sui punti  $f(x)=ax+b$  ("linear"), da cui si estrapola il coefficiente angolare  $a^k$  ("trend").

Grazie ad  $a^k$  possiamo distinguere due tipologie differenti di utenti:

$$\begin{cases} \text{utente affezionato } a^k \geq 0 \\ \text{utente disaffezionato } a^k < 0 \end{cases}$$

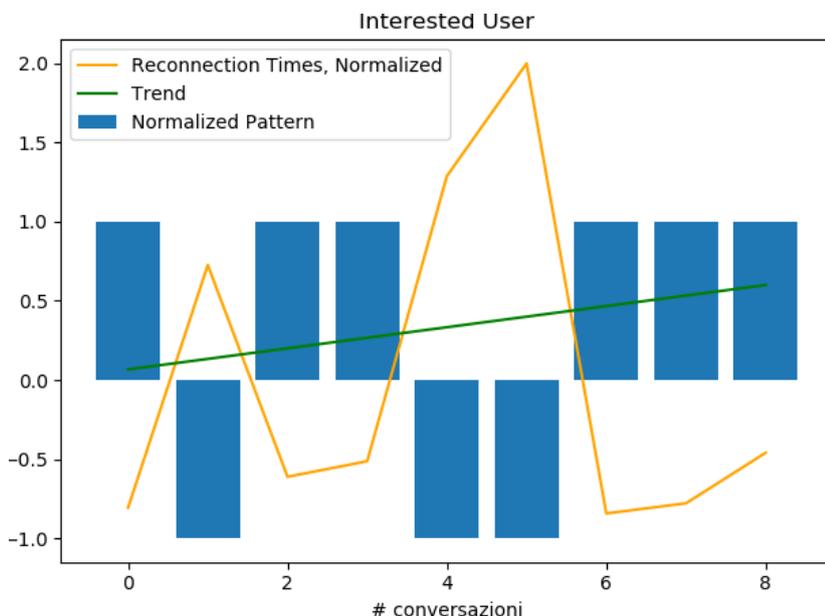


Figura 16 Esempio di utente affezionato

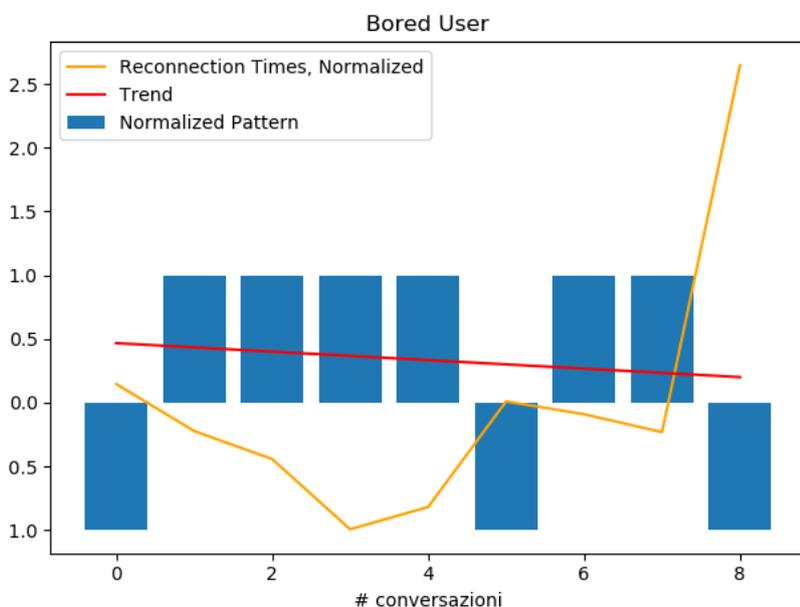


Figura 17 Esempio di utente disaffezionato

Al coefficiente angolare associamo l'angolo corrispondente, calcolato da  $\theta=\arctan(a)$  che identifichiamo come "phase". Per ogni utente, gli elementi del vettore dei pesi "lineari" trovato in precedenza ("fromGOlive!") vengono moltiplicati pointwise per gli elementi del "normalized\_pattern", per trovare un nuovo schema delle conversazioni che chiamiamo semplicemente "pattern"



Ogni utente può essere schematizzato come una realizzazione di un processo aleatorio, da cui si possono ricavare valor medio e deviazione standard: per il teorema centrale del limite il processo aleatorio (o meglio, l'insieme delle sue realizzazioni) può essere considerato gaussiano. In questa ottica potrebbe essere interessante ricalcolare il pattern di ogni utente basandosi sul valor medio estrapolato dalla distribuzione gaussiana che descrive il processo.

Dobbiamo ora calcolare l'intervallo che intercorre tra due conversazioni consecutive di un utente. Possiamo sintetizzare l'algoritmo nel modo seguente:

- Filtro il dataframe "TOTALE" per utente, e lo metto in ordine cronologico
- Shifto i timestamp di una casella
- Calcolo l'intervallo di tempo fra due conversazioni
- Calcolo in media ogni quanto si connette un utente, e con quale varianza
- Salvo i dati per ogni utente: media, varianza e numero di conversazioni
- Calcolo quanti giorni sono passati dal 14 Novembre
- Assegno un peso "sigmoidale"<sup>14</sup> ai giorni che sono passati fra il 14 Novembre e la conversazione

Dopodichè calcolo altri attributi che si ritengono importanti al fine della classificazione degli utenti nel modo seguente:

- Se media e varianza non sono nulle, e se ci sono almeno tre conversazioni per utente, studio le conversazioni degli utenti
- Standardizzo i valori rispetto a media e varianza dell'utente
- Calcolo la "temperatura" della conversazione di un utente: se l'intervallo di tempo che passa fra due conversazioni è inferiore al tempo medio assegno un punteggio +1, se no se è maggiore assegno -1
- Tutti i dati di "temperatura" vengono inseriti in una lista, che contiene perciò il profilo di un utente
- Un'idea che abbiamo avuto è quella di "fittare" linearmente il pattern, per capire se il comportamento ha trend positivo o negativo
- Trovo l'angolo corrispondente, con cui rappresentare il singolo utente su un grafico polare con modulo pari al numero di conversazioni
- Creo un nuovo tipo di pattern, in cui moltiplico ogni elemento per il numero di giorni che sono passati dal GOlive<sup>15</sup>

Creato questo nuovo dataset si tolgono gli elementi che hanno valori non numerici e si convertono i valori medi e di deviazione standard in ore. Questa fase di elaborazione è relativamente lunga<sup>16</sup>.

In figura vengono riportati alcuni valori dei primi 5 utenti:

---

<sup>14</sup> Si è deciso di assegnare un peso sigmoidale al numero di giorni tra il golive per penalizzare l'effetto wow e premiare gli utenti più fedeli che hanno continuato a collegarsi molto dopo l'avvio del servizio.

<sup>15</sup> prima avevo provato con i pesi dati dalla sigmoide in `w_time`, in modo da mediare l'effetto WOW i giorni molto vicini al rilascio e dare più peso ai giorni distanti dal rilascio, ma non sembra significativo. Un'altra idea è calcolare, sul pattern "normalizzato" di 1 e -1, la somma di tutti i numeri.

<sup>16</sup> Su un computer standard anche un paio d'ore. Nelle elaborazioni definitive si è usato un sistema basato su cloud Azure per accelerare notevolmente i tempi utilizzando hardware più potente basato su GPU.

	mean_reconnection_time	std_reconnection_time	#conversations	fromGOLive!	sigmoid_weights	trend	linear	phase
hITCQHf=	2 days 16:57:21.085400	3 days 11:55:51.655885	11	[0, 11, 12, 14, 14, 18, 25, 26, 26, 27, 27]	[1.670142184809518e-05, 0.5, 0.731058578630004, ...]	0.109091	[-0.0909090909090911, 0.01818181818181802, 0.1...]	6.22583
COjOKGOS	0 days 01:49:45.467666	0 days 02:03:53.771039	4	[0, 0, 0, 0]	[1.670142184809518e-05, 1.670142184809518e-05, ...]	-1	[1.333333333333315, 0.333333333333204, -0.6...]	-45
oYvdjzrxUxl	18 days 15:08:15.943333	17 days 08:19:33.967946	4	[0, 4, 13, 56]	[1.670142184809518e-05, 0.0009110511944006454, ...]	-1	[1.333333333333315, 0.333333333333204, -0.6...]	-45
n5D33AYnu	6 days 20:10:40.944000	9 days 22:31:36.473912	11	[0, 4, 6, 6, 13, 19, 20, 22, 22, 57, 68]	[1.670142184809518e-05, 0.0009110511944006454, ...]	-0.157576	[1.109090909090908, 0.9515151515151505, 0.7939...]	-8.95479
IHTIAuH6J2	2 days 16:53:13.616666	3 days 01:33:23.034817	4	[27, 34, 34, 35]	[0.9999998874648379, 0.999999998973812, 0.999...]	1	[-0.666666666666661, 0.333333333333339, 1.33...]	45

Figura 18 I valori DTW dei primi 5 utenti

I parametri che abbiamo calcolato per ogni utente sono i seguenti:

1. Tempo medio di riconnessione e relativa deviazione standard del tempo di riconnessione
2. Numero di conversazioni
3. I pesi della sigmoide
4. Il numero medio di ore di utilizzo e relativa deviazione standard

Per semplicità proviamo ad analizzare gli utenti che hanno fatto 10 conversazioni. Questo ci permette di analizzare il trend temporale tra soggetti che hanno lo stesso numero di campionamenti.

```
DF = DF1.loc[DF1['#conversations']==10,:]  
#Preparo una matrice quadrata, con dim = "# utenti che hanno effettuato 10 conversazioni"  
dim1 = DF.shape[0]  
print('Numero di utenti con 10 conversazioni: %s' % str(dim1))  
# Cerco di trovare la similarità di utilizzo del bot da parte degli utenti: visto che devo fare dei grafici viene più comodo far  
# su un sottoinsieme di essi, per esempio solo 6  
dist_matrix_6 = pd.DataFrame(index=range(0,6),columns=range(0,6))  
#Faccio una "mappatura" delle mail, se no se si mettono le etichette sui grafici non ci si capisce nulla  
DF_mail_6 = pd.DataFrame(data={'indice':range(0,6),'mail':DF.iloc[:6].index})
```

Numero di utenti con 10 conversazioni: 18

Figura 19 Estrazione degli utenti con 10 conversazioni

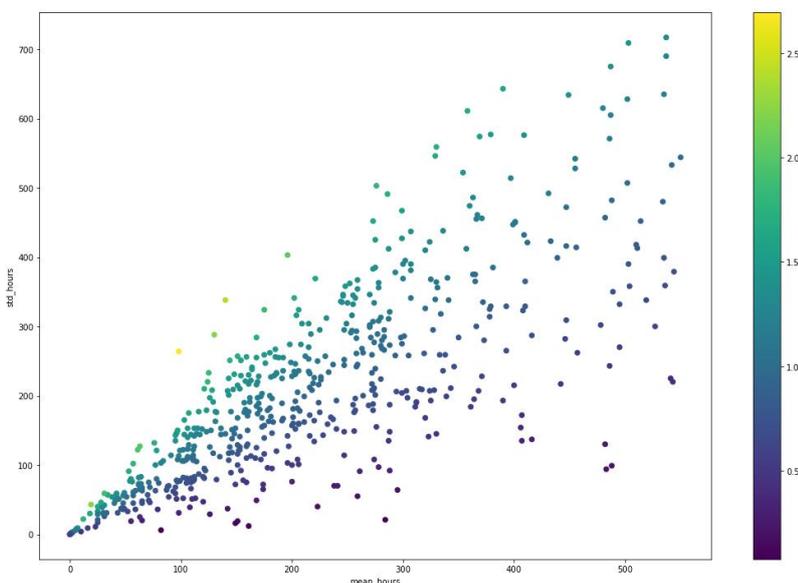


Figura 20 Distribuzione degli intervalli tra le conversazioni degli utenti



Una rappresentazione polare può essere utilizzata per avere una visione d'insieme dell'andamento degli utenti: la fase rappresenta l'angolo ricavato dal fit lineare sui pattern normalizzati di utilizzo degli utenti, il modulo è il numero di conversazioni ma può essere sostituito da altre grandezze (lo score per esempio per singolo utente). Mostriamo la forma polare ricavata nella figura successiva.

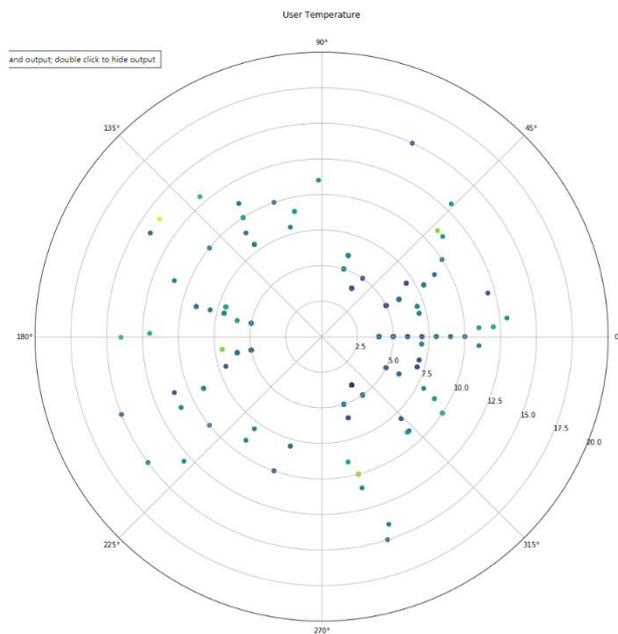


Figura 21 Rappresentazione polare dell'andamento degli utenti

Se creiamo una matrice quadrata, in cui definiamo il warping path per coppie di utenti otterremo che:

1. Sulla diagonale ho similarità massima (perchè il segnale di riferimento è uguale a quello che stiamo esaminando) e il warping path è la bisettrice (corrispondenza 1:1 fra i sample del segnali)
2. Fuori dalla diagonale la similarità dipende ovviamente dagli andamenti delle due timeseries
3. Al percorso che minimizza le distanze fra samples assegnamo un colore, dato dalla distanza accumulata nel percorso di warping

A questo punto possiamo creare una mappa colore che ci potrà essere utile per visualizzare la similarità tra coppie di utenti.

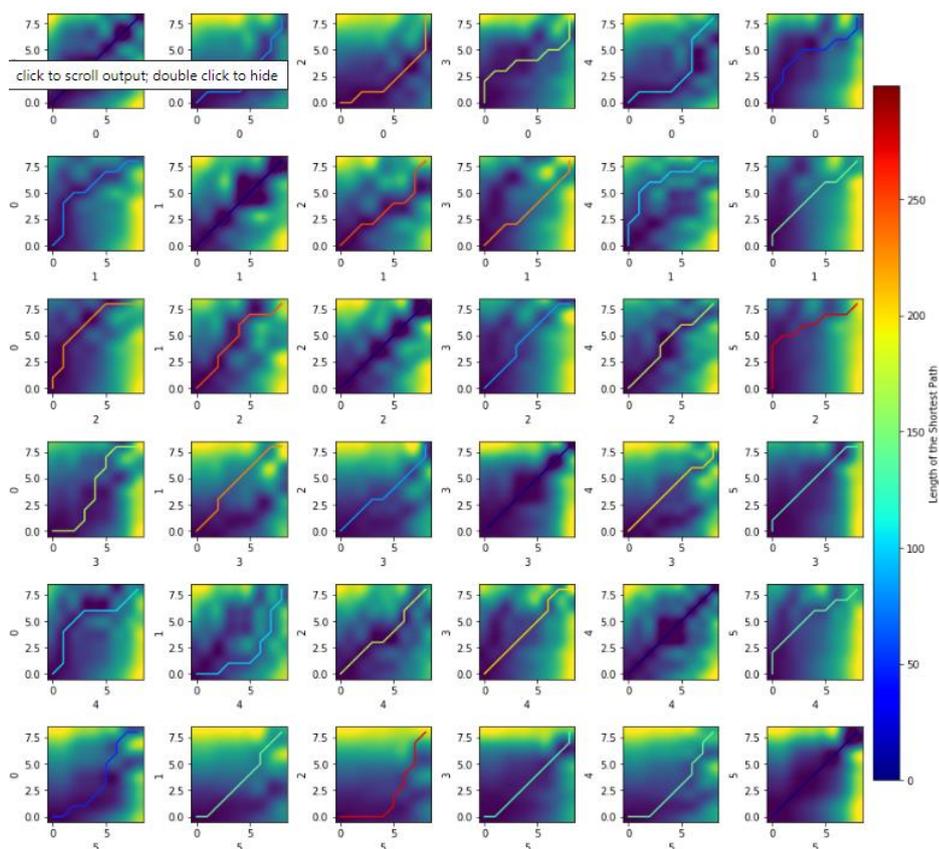


Figura 22 Mappa di colore per rappresentare le somiglianze tra coppie di utenti del sottoinsieme in esame

## Clustering gerarchico

Abbiamo per ora ricavato la similarità di coppie di utenti ma, ai fini del nostro studio, è più importante trovare tipologie di utenti che hanno dei pattern di utilizzo simili<sup>17</sup>: analizziamo i pattern nuovamente con tecniche DTW. La soluzione sembra funzionare bene sui dati delle conversazioni proprio per la loro scarsa densità. Per altri tipi di serie storiche, la funzione DTW potrebbe funzionare in modo peggiore rispetto ad altre metriche come CID (Complexity Invariant Distance), MAE o correlazione. È possibile approfondire le spiegazioni teoriche del clustering gerarchico in bibliografia (Hartigan, J.A., Wong, M.A.), (Bertin, M., Atanassova) o (Roberts, M.E., Stewart). Nella bibliografia è anche possibile approfondire gli aspetti teorici degli algoritmi DTW (C. Myers, L. Rabiner), (Niennattrakul, Vit & Srisai).

Il clustering gerarchico è semplice, flessibile, raffabile (criteri di collegamento) e ci consente di non definire a priori il numero di clusters non dovendo raggruppare in anticipo tutte le traiettorie. Il metodo DTW ci consente di confrontare serie temporali di diversa lunghezza e sembra funzionare con campioni rari. Nel nostro caso vogliamo clusterizzare non l'utente attraverso degli attributi "statici" ma attraverso il loro comportamento dinamico cercando di raggruppare gli utenti con comportamenti simili. Un altro problema importante è la complessità computazionale. In questo caso, come abbiamo anche visto nella pratica, il numero di attività svolte dagli utenti medi è dell'ordine delle decine o centinaia con dislocazione temporale e numerica molto differente tra loro. Vogliamo quindi sviluppare una misura della distanza di distorsione temporale per dati di serie temporali sparse che funzionano su serie temporali codificate di lunghezza di esecuzione, che sono molto più brevi delle loro versioni prima della codifica.

Il focus di questo studio riguarda, principalmente, la fattorizzazione dei comportamenti dinamici degli utenti che ci permetta di considerare non solo gli aspetti "statici" di una loro possibile collocazione all'interno del

<sup>17</sup> sempre utilizzando il concetto di "pattern" descritto in precedenza

nostro parco clienti ma delle loro "intenzioni" inteso come dinamica di comportamento. Valutiamo le prestazioni di DTW per il raggruppamento delle interazioni tra l'agente conversazionale e le migliaia di utenti del nostro studio. Analizziamo quindi tutte le conversazioni arricchite di alcuni attributi che abbiamo derivato per arricchire le conversazioni come, ad esempio, il numero di messaggi di benvenuto, le tipologie di richieste fatte all'agente conversazionali, il numero di volte che l'agente non ha capito la domanda ecc. Formiamo quindi le serie temporali delle attività di ciascuno degli utenti. Utilizzeremo poi tali serie temporali per trovare gruppi di utenti correlati. Per trovare tali gruppi di utenti correlati, raggruppiamo gerarchicamente gli utenti in base alle loro distanze DTW. Usiamo la tecnica single linkage e una soglia di uno per creare i cluster.

Cercheremo quindi di approfondire come, e se, l'analisi DTW modificata secondo le evidenze empiriche possa fornire informazioni significative. L'algoritmo va a fare clustering, individuando pattern simili gli uni agli altri grazie alla lunghezza del warping path: per ogni ramificazione viene calcolata la distanza fra i due cluster sottostanti (non si capisce se distanza mediata per ogni elemento i del cluster A con ogni elemento j del cluster B, o la distanza fra due elementi dei due cluster distinti che distano il più lontano/il più vicino possibile)

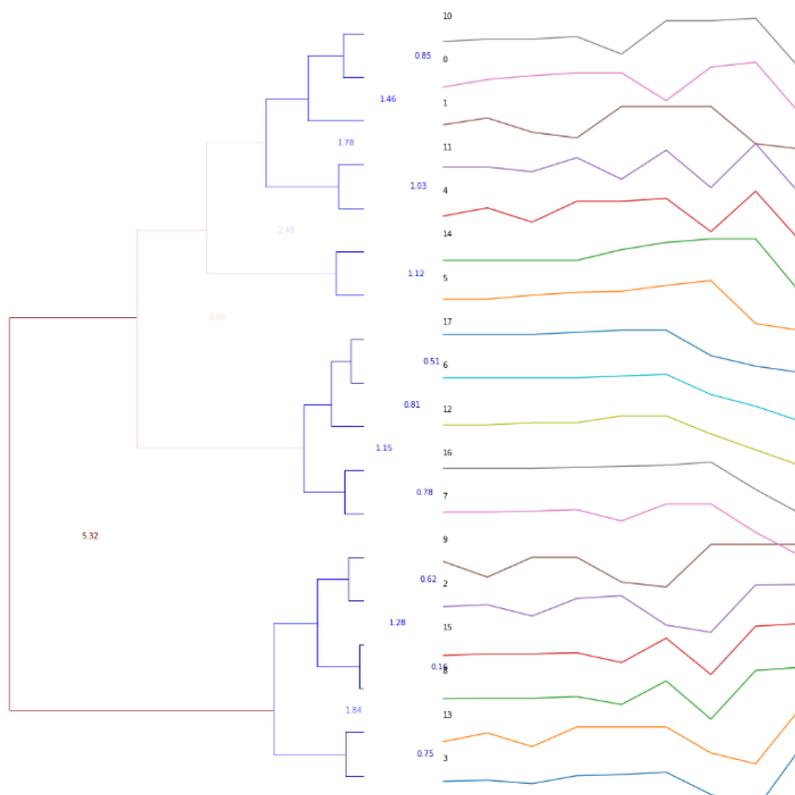


Figura 23 Dendrogramma con gerarchia di cluster

Il dendrogramma in figura rappresenta la gerarchia dei cluster e ci serve per capire dove ha senso "tagliare" i rami, cioè dove la distanza fra un cluster e l'altro comincia ad essere molto piccola. In sostanza due cluster sono **ben definiti** se la distanza fra loro è grande ma quella fra i propri elementi è piccola.

Una misura che definisce la bontà del clustering è il **silhouette index SC**, che intreccia le misure di "compattezza" intrinseca dei cluster con quelle che ne indicano le differenze gli uni dagli altri: questa quantità può assumere un range di valori compresi fra -1 e 1, dove a  $SC = 1$  corrisponde una clusterizzazione completamente sbagliata e a  $SC = -1$  corrisponde invece il caso opposto.

Ai fini della nostra ricerca tagliamo a 3 cluster, subito a valle della prima ramificazione, e calcoliamo il silhouette index SC complessivo per i dati analizzati utilizzando quindi tre algoritmi differenti per valutare il migliore in funzione dell'indice SC.

Nel primo grafico consideriamo il comportamento del cluster ricavato utilizzando un metodo k-means basato sulla distanza euclidea e ricaviamo l'indice SC per questa metodologia:

Euclidean k-means, SC = 0.24408070544658442

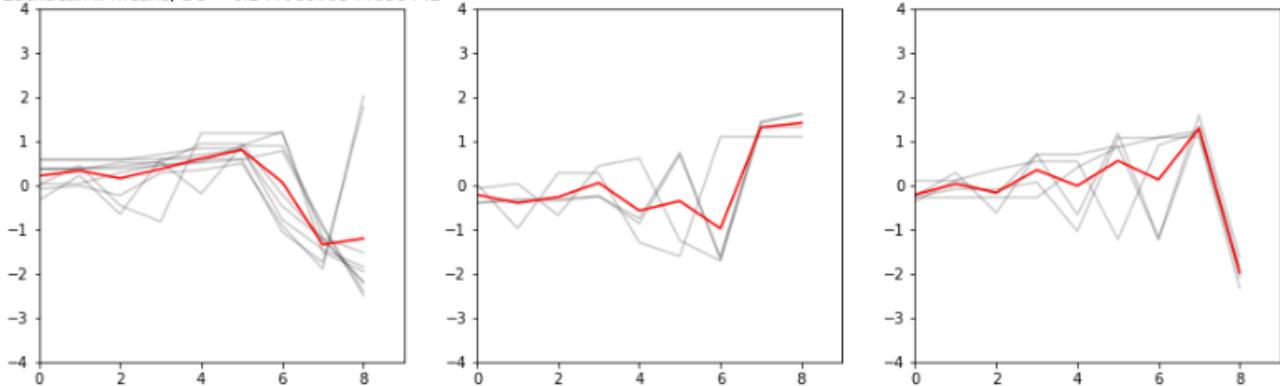


Figura 24 Clustering utilizzando k-means Euclideo

Possiamo vedere<sup>18</sup> che, in questo caso  $SC=0,244$ . Se invece applichiamo la clusterizzazione utilizzando il metodo dtw otteniamo il seguente raggruppamento con  $SC=0,52$ :

DTW k-means, SC = 0.5279890988934546

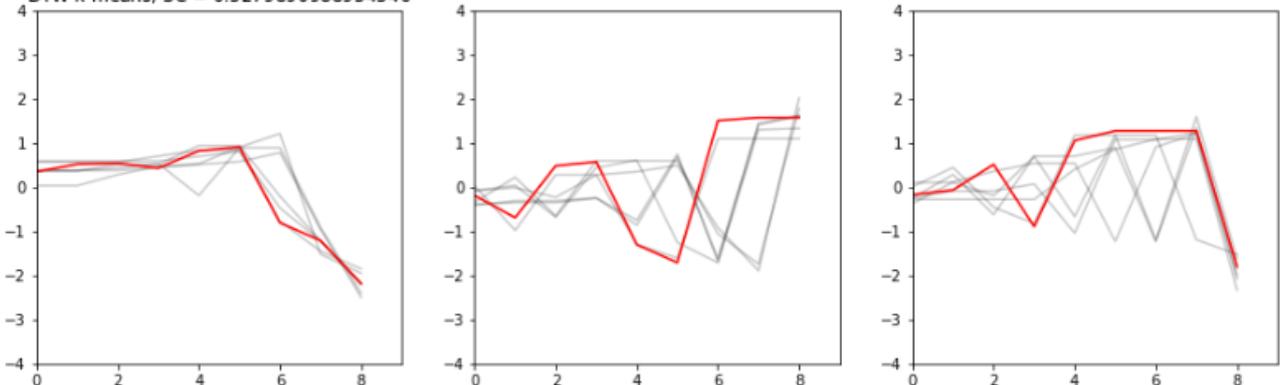
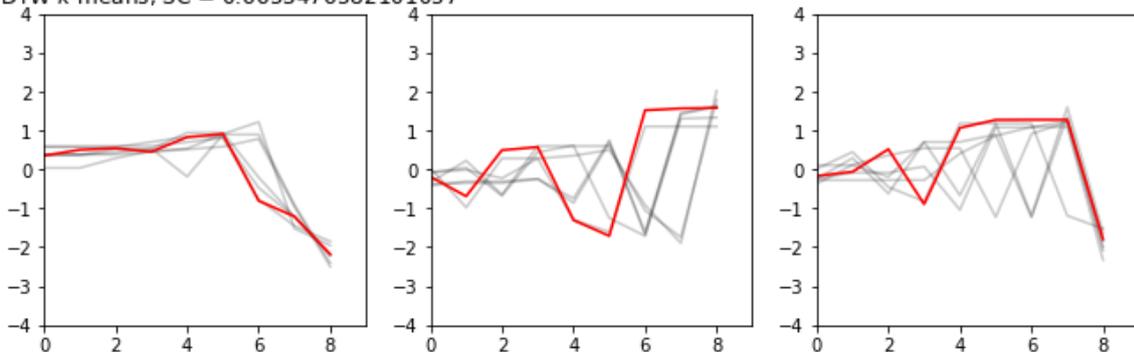


Figura 25 Clustering utilizzando k-means DTW

Nel 2017 (Cuturi M. Blondel M.) hanno pubblicato una versione modificata dell'algoritmo DTW chiamata Soft-DTW che abbiamo utilizzato nell'ultima versione di clusterizzazione degli utenti mostrata nella figura seguente:

Soft-DTW k-means, SC = 0.6653476582101057



<sup>18</sup> Abbiamo omissso il codice Python per brevità ma l'algoritmo è il TimeSeriesKMeans di tslearn <https://tslearn.readthedocs.io/en/latest/#>

Figura 26 Clustering utilizzando k-means Soft-DTW

Possiamo quindi ripetere le tre operazioni tagliando a 4 cluster invece di 3 utilizzando gli stessi algoritmi di cluster usati in precedenza come mostrato nelle figure seguenti:

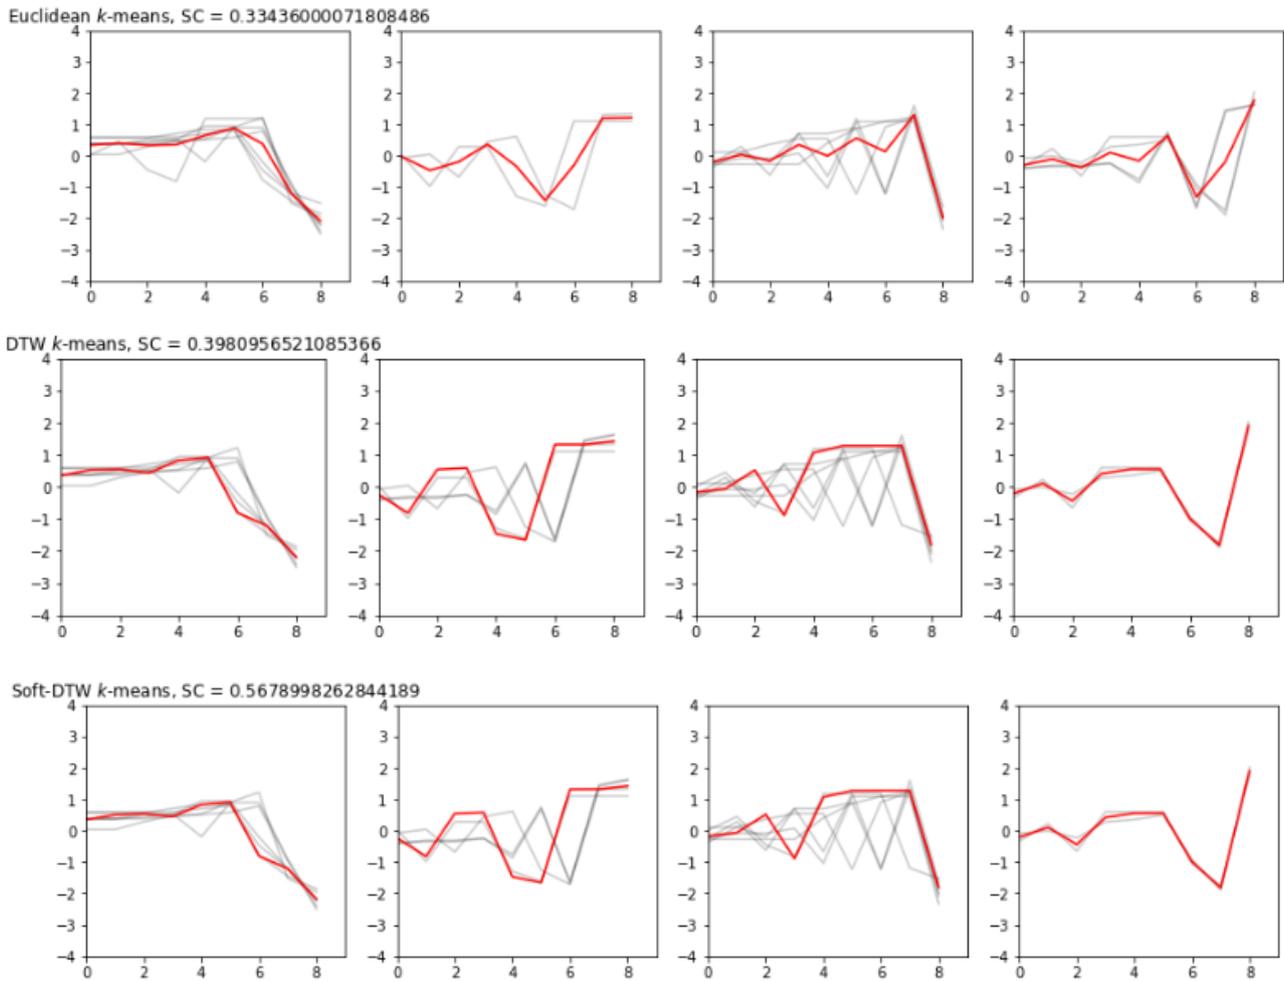


Figura 27 Risultati dei diversi algoritmi di clustering con numero di cluster = 4

Dai conti effettuati risulta che raggruppare i dati in 3 cluster utilizzando il metodo dei "soft" k-means dà un SC = 0.67, perciò corrisponde al clustering migliore.

## Conclusioni

Dal punto di vista dell'azienda è importante definire una metrica che permetta di confrontare le diverse strategie implementabili per ottimizzare le strategie volte a migliorare la user-experience degli utenti. La metrica che abbiamo ipotizzato essere la migliore è la user retention. Questa nella sua semplicità permette di meglio sintetizzare il gradimento degli utenti per il servizio offerto.

Risulta poi altrettanto disporre di adeguati strumenti per raggruppare gli utenti in cluster omogenei. L'omogeneizzazione permetterà di condurre analisi mirate su target specifici di utenti. Analisi che possono riguardare i dialoghi che gruppi di utenti omogenei richiedono al nostro agente conversazionale o anche i comportamenti in modo anche da orientare opportunamente la comunicazione. In questo capitolo abbiamo adattato uno strumento molto usato nel marketing analitico (RFM) al contesto degli agenti conversazionali permettendo di raggruppare gli utenti in funzione delle grandezze obiettivamente più significative per identificare le tipologie di utenti: Recency, Frequency e Usage. Attraverso il confronto di queste tre grandezze per tutti gli utenti siamo in grado di avere una prima suddivisione significativa degli utenti.

Tuttavia è interessante notare come gli algoritmi di clustering basati sul DTW, che dalle nostre ricerche non sono ancora stati applicati a contesti di marketing, siano effettivamente in grado di raggruppare gli utenti sulla base di comportamenti simili. Attraverso tale analisi è possibile confrontare dinamiche che, altrimenti, sarebbero state considerate disomogenee. La differenza con il metodo RFU è che quest'ultimo utilizza solo la dimensione F per dare dinamicità all'analisi. Al contrario il metodo DTW, anche nella sua variante soft-DTW, è stato esplicitamente concepito per analizzare serie temporali e, da una valutazione empirica, sembra effettivamente in grado di cogliere al meglio similarità altrimenti nascoste. Un esempio a questo riguardo, non statisticamente significativo ma, emblematico è dato da un cluster che abbiamo individuato molto particolare. Uno dei cluster individuati dall'algoritmo è dato da un gruppo di utenti con una frequenza di collegamento "bassa"<sup>19</sup> che si sono collegati tra il 16 e il 28 del mese (Novembre, Dicembre e Gennaio) di cui, analizzando i dati nel dettaglio, abbiamo visto che chiedevano unicamente informazioni sul cedolino. Questo comportamento "omogeneo" sarebbe stato difficilmente scopribile con differenti metodologie. A seguito dei risultati dell'analisi DTW si è quindi iniziato ad applicarli sugli utenti reali con ottima soddisfazione da parte dei responsabili incaricati di analizzare il comportamento dell'agente.

---

<sup>19</sup> Nel caso di specie solo 3 volte per ognuno di queste persone





## CAPITOLO 3 Measuring Dialog Quality

“The development of language is part of the development of the personality, for words are the natural means of expressing thoughts and establishing understanding between people.”

**Maria Montessori**

### Introduzione

Gli agenti conversazionali sono in grado, sempre più, di gestire autonomamente conversazioni con gli utenti al fine di fornire agli stessi servizi o informazioni. Un effetto secondario, ma non trascurabile, derivante dall'adozione di questi strumenti è dato dalla raccolta di una quantità pressoché illimitata di dati. Dati che contengono informazioni rilevanti circa gli utenti. Tuttavia, sono informazioni talmente numerose che senza l'adozione di strumenti automatici possono risultare praticamente inutili. Inoltre, proprio a causa della grande numerosità, risulta indispensabile poter fruire di tecniche di analisi non supervisionate in quanto potrebbe risultare economicamente svantaggioso l'analisi manuale di tali dati. Non è certamente trascurabile il fatto che poter ricavare informazioni dai dati provenienti dai dialoghi è di fondamentale importanza anche per l'evoluzione dell'agente conversazionale stesso.

L'obiettivo di questo paper è quello di investigare le possibilità tecnologiche per estrarre informazioni rilevanti dai dialoghi senza la necessità di un addestramento specifico. La maggior parte delle recenti storie di successo del machine learning, ad esempio il deep learning, si basano su una fase di apprendimento supervisionata in cui vengono forniti al sistema “esperimenti”. Esperimenti con risultato noto in modo che la rete neurale, appositamente progettata, sia in grado di imparare attraverso gli esempi. Tuttavia si ritiene che l'adozione di tecniche non supervisionate sia indispensabile dato il costo proibitivo di analizzare manualmente queste informazioni che vengono aggiornate continuamente. Questo è particolarmente vero quando, come nel nostro caso, l'estrazione delle informazioni non deve essere fatta una tantum ma è parte integrante del processo di conduzione del sistema stesso.

Poter analizzare la qualità dei dialoghi risulta fondamentale in quanto è facile immaginare che la soddisfazione degli utenti sia condizionata dalla capacità del bot di “rispondere” alle loro richieste. Possiamo immaginare che il ciclo di vita di un agente conversazionale sia determinato da fasi alterne di “ascolto” e interventi strutturali sul sistema che si susseguono indefinitamente. Nella fase di “ascolto” i tecnici analizzano le conversazioni per capire gli argomenti di interesse, dove l'agente è stato in grado di rispondere e dove no. Nella fase di intervento occorre pianificare gli interventi di miglioramento che possono riguardare la struttura del dialogo, il motore NLP o decidere di introdurre nuovi skills per estendere le funzionalità dello stesso. È però evidente che decidere **su quali elementi** intervenire è un compito altrettanto complesso del decidere **su come** intervenire. La numerosità delle conversazioni e l'eterogeneità degli utenti rende impercorribile la strada “umana” di analizzare le conversazioni singolarmente. Così come nel capitolo precedente abbiamo cercato di raggruppare gli utenti in segmenti omogenei in questo capitolo ci occuperemo di trovare delle tecniche automatiche per clusterizzare i dialoghi con il duplice obiettivo di individuare gli argomenti più importanti per gli utenti e distinguere i dialoghi che **non** performano bene rispetto a quelli ottimali per poter analizzarli in dettaglio.

In questo capitolo cercheremo quindi, analizzando i messaggi inviati dagli utenti, di capire che cosa gli utenti stanno chiedendo. Considerando che ci sia stata una importante fase comunicativa (di cui ci occuperemo nel capitolo successivo) attraverso l'analisi dei dialoghi dovremmo essere in grado di capire se le richieste degli utenti sono in linea con quanto offerto dall'agente conversazionale e promosso dall'azienda. Serve inoltre come strumento per identificare i trend topics o le aree di possibili interventi futuri di funzionalità richieste ma a cui l'agente conversazionale non è stato in grado di rispondere.

Nella seconda parte del capitolo introdurremo un modello teorico che prova a definire un modello formale mirato a misurare la qualità del dialogo. Essere in grado di misurare la qualità di un dialogo ci permette di identificare i dialoghi degli utenti che *non performano secondo le aspettative*. Questo può dipendere da diversi fattori endogeni o esogeni all'agente conversazionale. Poterli identificare ci permette di analizzarli a posteriori estrapolandoli rispetto a quelli che si comportano secondo le attese in modo da poter definire le migliori strategie per il miglioramento delle performance complessive. Ad esempio si potrebbe adottare una campagna informativa mirata nel caso di fattori **esogeni** o una rivisitazione del processo (o del dialogo) in caso di fattori **endogeni**. Esempi di fattori endogeni che potrebbero influenzare l'interazione con l'utente sono un training insufficiente del motore NLP (che potrebbe non riconoscere parole molto usate nel contesto specifico o da un ampio sottoinsieme di utenti), una progettazione non adeguata del dialogo che potrebbe essere troppo spezzettato (non accettare più parametri in una singola interazione) o troppo complesso (troppi parametri per interazione). L'obiettivo è astrarre la misura dell'efficienza del dialogo dai singoli fattori che ne possano incidere la qualità, fornendo un valore numerico in grado comunque di valutarne la performance.

### Letteratura collegata

Negli ultimi anni si è assistito ad una evoluzione significativa delle tecniche nel dominio di elaborazione del testo e del linguaggio naturale, attraverso la rappresentazione vettoriale di parole che permette, implicitamente, una rappresentazione semantica ottenuta senza supervisione (Mikolov et al., 2013b, a; Pennington et al., 2014). Nel giro di pochi anni dalla loro introduzione, tali rappresentazioni si sono evolute consentendo la rappresentazione vettoriale di frasi, documenti ecc. e si basano, sostanzialmente, su un modello di fattorizzazione a matrice che possono essere ricavate da grandi quantità di dati di testo<sup>20</sup>.

Attualmente, sono emerse due scuole di pensiero concorrenti che studiano la rappresentazione ottimale del testo: da un lato, si privilegia l'apprendimento basato su reti neurali profonde (deep learning) che porta a modelli sempre più potenti e complessi, utilizzando reti neurali ricorrenti (RNN Irsoy e Cardie 2014), LSTM (Walkowiak 2019) e modelli di attenzione (Galassi Lippi e Torroni 2019). Queste tecnologie sebbene estremamente complete nella capacità espressiva pagano un costo importante di complessità. La maggiore complessità intrinseca del modello rende questi strumenti molto più lenti, e costosi, da addestrare su grandi set di dati. Occorre anche tenere presente che la qualità del risultato è fortemente influenzata dal set di dati disponibili per l'addestramento per cui diventa impossibile riuscire a garantire una qualità elevata senza investire una quantità ingente di risorse sia tecniche che economiche.

La seconda scuola di pensiero ha approfondito l'utilizzo di modelli più semplici come le fattorizzazioni di matrici (o modelli bilineari) per poter beneficiare del training su set di dati molto più grandi, il che può essere un vantaggio chiave, a favore di un ambiente senza supervisione. Studi recenti hanno dimostrato che l'uso di word-embeddings (vettori di parole) sovraperformano in media gli LSTM (vedere Wieting et al. (2016) per la media semplice, e Arora et al. (2017) per la media ponderata).

### Clustering delle parole

L'obiettivo di questa parte di analisi è quello di analizzare le conversazioni degli utenti al fine di estrarre due tipologie di indicazioni. La prima riguarda l'analisi di quanto gli utenti stanno chiedendo al sistema. Questo ci permette di condurre delle analisi empiriche sulle richieste degli utenti e ci permette di analizzare le informazioni contenute nei dialoghi stessi. Obiettivo di questa prima parte di analisi è capire se, utilizzando tecniche statistiche sia possibile estrarre le informazioni rilevanti ai fini di identificare i topic delle conversazioni.

---

<sup>20</sup> Grazie anche all'enorme quantità di dati e di risorse che aziende come Google®, Amazon® e Microsoft® hanno dedicato a questi strumenti

Analizziamo ora le conversazioni sostenute dagli utenti prendendo come riferimento il nostro agente conversazionale. Dall'introduzione in via sperimentale a marzo del 2019 ci sono state 20750 conversazioni e sono stati scambiati 230259 messaggi di cui 75051 inviati dagli utenti. Per uniformità con il resto della trattazione consideriamo solo i messaggi a partire dalla data di avvio del servizio a tutti gli utenti italiani del 14 novembre 2019 in cui ci sono state 11814 conversazioni e 131808 messaggi di cui 35770 degli utenti.

Ogni messaggio inviato da un utente può essere girato ad un motore NLP per la comprensione dell'intent espresso dall'utente e l'estrazione delle entità associate<sup>21</sup>. Per permettere all'agente conversazionale di gestire i casi in cui il motore NLP non riconosce quanto scritto dagli utenti si è deciso di addestrare il motore NLP in modo che restituisca un intent='none'. Per comprendere empiricamente la diffusione del fenomeno di mancata comprensione dell'intento da parte del motore NLP abbiamo estratto le query degli utenti a cui è stato attribuito l'intento generico 'none'. Abbiamo constatato che ci sono stati 5232 messaggi degli utenti che non sono stati riconosciuti dal sistema. Questi rappresentano circa il 15% dei messaggi complessivi. È da tenere presente che questi messaggi rappresentano frasi che il bot non è stato in grado di comprendere. Tra questi ci possono anche essere quelli per i quali il sistema non è stato addestrato, ovvero l'utente chiede al sistema informazioni non previste a cui, di conseguenza, l'agente non sa rispondere. Di seguito un estratto di tali messaggi:

	query	timestamp	confidence	confidence_perc	intent
0	quali sono i vantaggi di sc	2019-12-12 13:58:27.413	0.106681	< 40%	none
1	non servi a nulla	2019-12-12 13:08:36.697	0.210886	< 40%	none
2	non ci siamo capiti	2019-12-12 13:56:55.787	0.634808	60% - 70%	none
3	non stai capendo nulla	2019-12-12 13:57:28.480	0.681664	60% - 70%	none
4	non servi a nulla	2019-12-12 13:57:39.687	0.210886	< 40%	none

Figura 28 Estratto di messaggi non compresi dal sistema

Un'altra misura empirica ma efficace del funzionamento del sistema può essere data dalla distribuzione della percentuale di confidenza registrata dal motore NLP rispetto alle richieste degli utenti. Estraiamo quindi le query che gli utenti hanno fatto e che il motore NLP è stato in grado di catalogare. Queste sono 18725<sup>22</sup>. Di seguito un estratto:

	query	timestamp	confidence	confidence_perc	intent
0	Ambiente sicurezza	2019-12-12 13:58:28.410	0.257126	< 40%	apptools.searchapp
1	security	2019-12-12 13:58:42.083	0.458537	40% - 60%	greetings
2	security	2019-12-12 13:58:42.270	0.458537	40% - 60%	greetings
3	anteprima cedolino dicembre <del>le entità</del>	2019-12-12 13:08:24.277	0.850126	80% - 90%	payslip.view
4	che vantaggi mi da should cost	2019-12-12 13:59:07.110	0.872905	80% - 90%	search.shouldcost

Figura 29 Estratto delle richieste degli utenti comprese dal motore NLP

Dalla figura possiamo notare che a queste frasi è sempre associato un intent con un relativo confidence factor che rappresenta la confidenza che il sistema attribuisce alla sua previsione. Come si può vedere in figura abbiamo estrapolato dalla base dati gli attributi dei messaggi ritenuti più importanti che comprendono: la query dell'utente, l'intent riconosciuto e la percentuale di confidenza. È da notare che i messaggi 1 e 2 (scritti

<sup>21</sup> Consultare il capitolo 1 per i dettagli

<sup>22</sup> È da tenere presente che non tutte le richieste vengono inviate al motore NLP, alcune vengono elaborate direttamente dal bot

sbagliati) non sono stati riconosciuti correttamente pur avendo una percentuale di confidenza abbastanza elevata. Possiamo estrarre alcune statistiche significative ai fini della nostra indagine così come riportato nella figura seguente.

	count	mean	std	min	25%	50%	75%	max
<b>confidence_perc</b>								
40% - 60%	2315.0	0.499636	0.059631	0.401161	0.451815	0.506430	0.556450	0.599645
60% - 70%	511.0	0.650313	0.028524	0.600420	0.626782	0.647473	0.675009	0.699989
70% - 80%	541.0	0.752230	0.029047	0.700688	0.726706	0.750905	0.777424	0.799949
80% - 90%	797.0	0.853561	0.027997	0.800287	0.830894	0.855923	0.875905	0.899573
90% - 100%	12376.0	0.968524	0.024770	0.900280	0.951814	0.951814	0.997909	1.000000

Figura 30 Distribuzione del confidence range rispetto alle query correttamente riconosciute

Dalla figura possiamo vedere che la stragrande maggioranza delle query sono state riconosciute con una percentuale tra il 90 e il 100%.

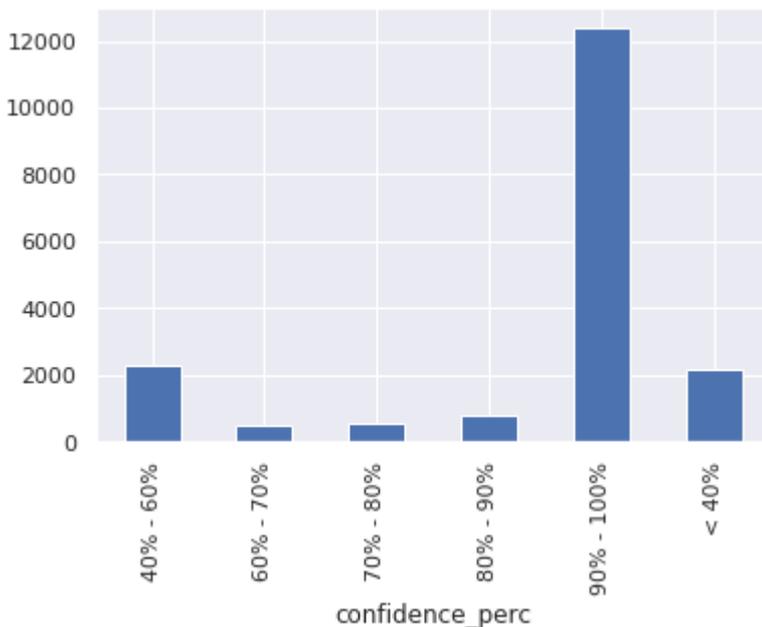


Figura 31 grafico della distribuzione del confidence factor per gli intenti riconosciuti

Avendo a disposizione i dati estratti dalla nostra base informativa possiamo identificare ciò di cui parlano gli utenti. Per fare ciò abbiamo due strade. La prima potrebbe essere quella di utilizzare l'intent riconosciuto dal motore NLP per classificare i dialoghi contenuti all'interno delle conversazioni. Questo può essere fuorviante per due motivi. Il primo è legato al fatto che, come è facile comprendere dalla definizione di agente conversazionale, all'interno di una conversazione possono essere contenuti più dialoghi, magari anche parzialmente sovrapposti per cui la misura dell'intent potrebbe essere fuorviante. Questo è ancora di più vero nel caso in cui l'intent abbia una confidenza bassa. Peraltro sembra anche concettualmente sbagliato utilizzare i dati del sistema per valutare le prestazioni del sistema stesso. Si è proceduto pertanto ad analizzare i dati grezzi delle conversazioni.

Per fare ciò abbiamo utilizzato il linguaggio Python® per l'ampia disponibilità di librerie già pronte con significative funzioni NLP già collaudate e disponibili. Per fare questo abbiamo, ad esempio, utilizzato la



La procedura formale per l'implementazione di TF-IDF presenta alcune lievi differenze nelle differenti implementazioni, ma possiamo descrivere l'approccio generale nel modo seguente.

Dato un insieme di documenti  $D$ , una parola  $w$  e un singolo documento  $d \in D$ , calcoliamo

$$w_d = f_{w,d} * \log\left(\frac{|D|}{f_{w,D}}\right) \quad \text{Equazione 3}$$

dove  $f_{w,d}$  è uguale al numero di volte che  $w$  appare in  $d$ ,  $|D|$  è la dimensione del corpus, e  $f_{w,D}$  è uguale al numero di documenti in cui  $w$  appare in  $D$  (Salton & Buckley, 1988, Berger, et al, 2000).

Supponiamo che  $|D| \approx f_{w,D}$ , questo significa che la dimensione del corpus è approssimativamente uguale alla frequenza di  $w$  su  $D$ . Se  $1 < \log\left(\frac{|D|}{f_{w,D}}\right) < c$  dove  $c$  è una costante molto piccola, allora  $w_d$  sarà minore di  $f_{w,d}$  ma comunque positivo. Ciò implica che  $w$  è relativamente comune sull'intero corpus ma mantiene ancora una certa importanza in tutto  $D$ . Questo vale, ad esempio, per parole estremamente comuni come articoli, pronomi e preposizioni, che da sole non hanno alcun significato rilevante in una query. Parole così comuni ricevono quindi un punteggio TF-IDF molto basso, rendendole sostanzialmente trascurabili per caratterizzare ciò che l'utente chiede.

Al contrario se abbiamo una  $f_{w,d}$  grande e una  $f_{w,D}$  piccola otteniamo un valore di  $\log(|D|/f_{w,D})$  piuttosto grande da cui deriva un  $w_d$  grande. Questo è il caso per noi più importante poiché le parole con alta  $w_d$  definiscono  $w$  come una parola importante in  $d$  in quando non comune in  $D$ . Nel nostro contesto possiamo dire che questo termine ha un grande potere discriminatorio indicando quindi un termine importante che potrebbe caratterizzare la richiesta stessa.

Il codice per TF-IDF è elegante nella sua semplicità. Se prendiamo una query  $q$  composta da un insieme di parole  $w_i$ , calcoliamo  $w_{i,d}$  per ogni  $w_i$  per ogni messaggio  $d \in D$ . Una volta trovati tutti i  $w_{i,d}$ , restituiamo un insieme  $D^*$  contenente documenti  $d$  tale da massimizzare la seguente equazione:

$$\sum_i w_{i,d} \quad \text{Equazione 4}$$

Per i nostri risultati utilizzeremo l'implementazione di TFIDF offerta dalla libreria sklearn<sup>24</sup> libreria molto diffusa che implementa modelli semplici ed efficienti per l'analisi predittiva dei dati. Di seguito un estratto del codice che permette di calcolare TF-IDF su tutte le domande poste al sistema da tutti gli utenti:

```
# Let's train a TfidfVectorizer for extracting features and a NMF model for topic modeling.
vec = TfidfVectorizer(max_features=15000, max_df=0.95, min_df=2, stop_words=stopwords)
userMessages.head(5)
phrases = userMessages.loc[:, "query"].values
features = vec.fit_transform(phrases)

random_state = 0
# number of topics to extract
n_topics = 15

cls = NMF(n_components=n_topics, random_state=random_state)
cls.fit(features)

NMF(alpha=0.0, beta_loss='frobenius', init=None, l1_ratio=0.0, max_iter=200,
     n_components=15, random_state=0, shuffle=False, solver='cd', tol=0.0001,
     verbose=0)
```

<sup>24</sup> <https://scikit-learn.org/stable/>

Figura 34 Codice per creare un vettore Tf-Idf sui messaggi degli utenti

In questo modo possiamo creare un cluster degli argomenti chiesti dagli utenti utilizzando le parole più rilevanti all'interno di una frase. I risultati che abbiamo ottenuto, sintetizzati nella figura seguente, sono molto interessanti:

```
0 organigramma persona cerca enel dipendenti
1 protocollare devo lettera inserire entrare
2 cedolino novembre ottobre vedere dicembre
3 internal firma cercavo inserimento termine
4 accetta dammi news profilo ultime
5 smart working cedolino uscito stipendio
6 exit meeting organizza organizzare riunione
7 paga busta ultima novembre dicembre
8 ferie residue dicembre policy rimaste
9 deskey accedo documento documenti lettera
10 numero telefono desk help informatico
11 job posting shadowing cerco link
12 mostrami collega documenti profilo ultimi
13 eprofile posso vedere coda sangil
14 apri ticket vedere one click
```

Figura 35 Cluster delle discussioni prevalenti

Abbiamo però bisogno di un riscontro per valutare l'effettiva bontà dell'algoritmo utilizzato. Per valutare la ciò abbiamo utilizzato due approcci empirici. Il primo è stato quello di confrontare i cluster trovati con gli skill su cui l'agente conversazionale è stato addestrato. Gli skill implementati sono i seguenti: Payslip (per informazioni sul cedolino), eProfile (per avere informazioni su colleghi e organigramma, Informazioni (per informazioni generali dell'azienda), Meeting (per organizzare riunioni con i colleghi), News (per informazioni relative a jobs, documenti, procedure, ecc.) e deskey (per firma elettronica su documenti). Da un'analisi empirica è facile notare un'ottima sovrapposizione tra quanto trovato e quanto predeterminato in anticipo.

Abbiamo utilizzato anche una seconda metodologia empirica per sfruttare la conoscenza del dominio dei progettisti del servizio. Abbiamo quindi chiesto a 5 persone dell'azienda utilizzatrice del sistema di darci un valore tra 0 e 5 come valutazione soggettiva della sovrapposizione dei cluster trovati rispetto a quanto previsto dal sistema. Abbiamo previsto una scala da 0 nel caso in cui non fosse stata riscontrata nessuna sovrapposizione e 5 in caso di sovrapposizione perfetta. Abbiamo poi fatto la media dei giudizi degli utenti e il risultato finale è stato di un sorprendente 4,9.

Possiamo quindi immaginare che sia possibile definire una metodologia di analisi in grado di inferire le richieste degli utenti analizzando unicamente i dati già presenti senza la necessità di ulteriori iterazioni.

Molto più complesso è determinare l'efficienza e la qualità del dialogo. Ora vedremo un framework teorico che ci permetta di valutare, in tempo reale, la qualità del dialogo stesso analizzando la progressione del dialogo tra utente e sistema e confrontandolo con un dialogo considerato "ideale".

### La qualità del dialogo: due modelli teorici

La seconda parte di questo capitolo è dedicata a definire una metodologia per **inferire la qualità del dialogo** analizzando le conversazioni degli utenti. In questa parte si cercherà quindi di definire un modello teorico in grado di valutare, per una tipologia di dialogo predeterminata, la capacità del bot di convergere o meno verso un target definito anche guidando l'utente in una conversazione "utile". L'obiettivo fondamentale è quello di capire se è possibile definire degli strumenti che siano in grado di derivare delle metriche di efficacia ed efficienza dell'agente conversazionale analizzando esclusivamente i dati evitando cioè di chiedere feedback agli utenti.

Prima di analizzare le metodologie investigate occorre definire il limite di questa ricerca. Entrambe le metodologie investigate necessitano di analizzare un unico dialogo, un dialogo cioè composto unicamente da domande e risposte pertinenti ad un unico argomento. È però facilmente verificabile che i casi reali, per gli agenti conversazionali così come per le interazioni tra umani, sono molto diversi e comprendono casi molto più articolati. Un dialogo, infatti, potrebbe essere intervallato da sotto-dialoghi che, tra umani, servono per arricchire il contesto con informazioni correlate ma non strettamente necessarie. Supponiamo ad esempio di avere un agente conversazionale in grado di prenotare viaggi.

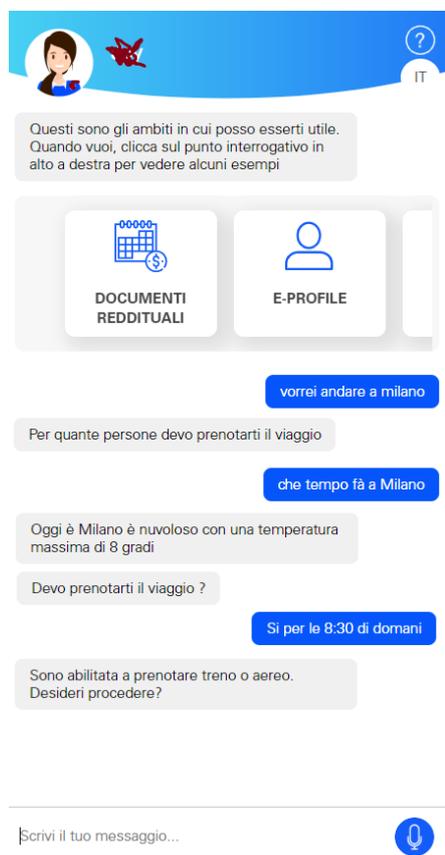


Figura 36 Esempio di dialoghi annidati

Una conversazione potrebbe essere come quella rappresentata in figura<sup>25</sup>. Nel caso di uno skill per la prenotazione di un viaggio le informazioni strettamente necessarie all'agente conversazionale sono esclusivamente quelle relative alla prenotazione: il numero di partecipanti, il mezzo di trasporto, la data e l'ora ecc.. Osservando l'esempio in figura possiamo notare che il flusso logico essenziale viene interrotto per raccogliere informazioni non strettamente necessarie all'esecuzione del dialogo. Questa è una delle caratteristiche distintive di un agente conversazionale che, teoricamente, potrebbero rendere più complesso il nostro modello.

Per semplicità non consideriamo i casi di interruzioni impreviste, di ripetizioni cicliche o altre condizioni più complesse ma decidiamo di limitarci al caso più semplice per non complicare il nostro modello teorico. È infatti possibile dimostrare che tale semplificazione non fa perdere di generalità alla discussione. Per estenderlo ai casi reali sarà infatti sufficiente estrarre il dialogo principale estrapolando il flusso principale dalle interruzioni rendendolo quindi analizzabile separatamente.

Abbiamo provato ad ipotizzare due modelli differenti basati su due approcci completamente differenti: un approccio basato sulla semantica delle frasi e il secondo basato sulla misura dell'accumulo dell'entropia. Per

<sup>25</sup> Tratta da un ambiente in grado di gestire dialoghi annidati

entrambi i modelli esiste un elemento comune che deriva dalla necessità di individuare l'inizio della conversazione. È un problema non banale che, ai fini della nostra ricerca, abbiamo deciso di implementare attraverso un semplice classificatore multi-classe. L'idea alla base è relativamente semplice: si prende il training set utilizzato per l'addestramento del motore NLP associato ai singoli skill e si utilizzano per addestrare un classificatore multi-classe che identifichi lo skill richiesto. Esistono alcuni problemi tecnici legati alla possibile sovrapposizione di domande che possono essere molto simili tra skill diversi ma è un problema concettualmente semplice. La **condizione iniziale** è data dall'avvio di un argomento specifico che identifica uno specifico skill. Nell'esempio considerato ogni singola frase introdotta viene passata al nostro classificatore che identifica il topic in funzione della domanda: ad esempio "dammi il cedolino" o "prenota una sala riunioni". In funzione della classificazione possiamo quindi capire se va in continuazione di un dialogo già in corso o se viene iniziato un nuovo dialogo specifico (meetingRoom, eTravel, payslip ecc.).

Molto più complesso è determinare univocamente la **condizione finale del dialogo**. È infatti molto più complesso identificare la condizione che conclude un dialogo. Teoricamente infatti un dialogo potrebbe anche non interrompersi in quanto, ad esempio un utente si disconnette o non è più interessato allo specifico task nella conversazione. In questo caso, seppure difficile da identificare univocamente, abbiamo due informazioni l'utente non ha completato il task (inefficace) e si è stufato (inefficiente). Per semplificare il funzionamento del nostro algoritmo senza perdere in generalità abbiamo deciso di adottare le seguenti definizioni formali. Chiamiamo  $C$  una conversazione tra un utente e un agente conversazionale. Una conversazione è data da una sequenza ordinata di dialoghi omogenei  $D_i$ . In questo caso intendiamo come omogenei dialoghi che trattano lo stesso argomento (ad esempio la prenotazione di una sala riunioni, di un viaggio, informazioni sullo stipendio, organigramma ecc.). Formalmente  $C = \{D_1, \dots, D_n\}$ . Ogni dialogo è composto da un insieme di domande poste dall'utente e risposte inviate dell'agente conversazionale<sup>26</sup>. Ogni dialogo è quindi composto da un insieme ordinato<sup>27</sup> di coppie  $\{q, a\}$ . Per semplicità supponiamo che l'agente conversazionale fornisca sempre una, e una sola, risposta all'utente. Escludiamo quindi i casi di malfunzionamento in cui l'agente non risponde o i casi in cui l'agente invii più di una risposta ad una domanda. Questo semplifica molto la trattazione senza togliere nulla in generalità. Entrambe le metodologie analizzeranno quindi ogni  $C_i$  appartenenti a  $D$ . Consideriamo quindi  $C_i$  un insieme finito di coppie  $\{q_t, a_t\}$  in cui inizio e fine sono chiaramente identificati.

Un agente conversazionale  $X$  è un insieme di skill  $\{S_i\}$ . Uno skill  $S$  è uno specifico ambito in cui l'agente conversazionale è in grado di operare. Possiamo quindi dire che, nel nostro caso, uno skill  $S$  è in grado di gestire più task  $\tau_i$  per cui  $S = \{\tau_1, \dots, \tau_n\}$ . Un task  $\tau$  è caratterizzato da un obiettivo  $g$  e da un insieme  $I$  di informazioni necessarie per completare  $\tau$ . Possiamo quindi definire un dialogo  $D$  come quell'insieme di  $\{q_t, a_t\}$  che permette ad un utente di raggiungere  $g$  all'interno di uno skill  $S$ . Vediamo ora di approfondire le due metodologie.

### Modello semantico

È un modello relativamente semplice che sfrutta il lavoro fatto dalla comunità scientifica che già a partire dal 2003 ha iniziato a studiare la possibilità di rappresentare le parole di una frase come vettori (Bengio, Ducharme, Vincent e Jauvin 2003). Tuttavia è nel 2013 che (Mikolov, Chen e altri) hanno dimostrato l'efficacia di rappresentare le parole di una frase all'interno di uno spazio vettoriale. L'idea che sta dietro word2vec è relativamente semplice e si basa sulla semplice assunzione che il significato di una parola lo si può inferire dalla disposizione spaziale della stessa all'interno delle frasi. Senza entrare nella descrizione dell'algoritmo che possiamo trovare in bibliografia possiamo immaginare che due parole che sono normalmente circondate

<sup>26</sup> Da questa analisi escludiamo gli agenti proattivi cioè quelli che, autonomamente, inviano messaggi agli utenti

<sup>27</sup> In base al tempo

da parole simili possono essere considerate come sinonimi e, di conseguenza, avere lo stesso significato semantico. Un esempio può essere la parola “Italia” che, se la interpretiamo come nazione<sup>28</sup> può essere sinonimo di Stato e, di conseguenza, possono essere considerati sinonimi anche (Francia, Spagna, Inghilterra, Roma, ecc.). In figura è mostrato un esempio peso dalla nostra implementazione dell’algoritmo:

```
# Look up top 6 words similar to 'ireland'
w1 = ["ireland"]
model.wv.most_similar (positive=w1,topn=6)

[('australia', 0.8157126307487488),
 ('dublin', 0.7486730217933655),
 ('hawaii', 0.7353441119194031),
 ('scotland', 0.7316787838935852),
 ('spain', 0.7251657843589783),
 ('edinburgh', 0.7239943146705627)]
```

Figura 37 Sinonimi trovati utilizzando word2vec

Abbiamo quindi pensato di identificare una metrica per la valutazione della “bontà” del dialogo che si basi, sostanzialmente, sulla **distanza semantica** di una conversazione di un utente rispetto alla condizione “ottima”. Come si può vedere dalla figura date due parole contenute all’interno di un corpus, utilizzando la rappresentazione vettoriale, è possibile calcolare una distanza rispetto ai “sinonimi”. Possiamo implicitamente vedere l’importanza del training set direttamente dalla figura. Dato il training set utilizzato, nel nostro caso molto piccolo, l’affinità semantica tra “ireland” e “australia” è superiore (0,81) rispetto a “ireland” e “dublino” che è solo di 0,74.

Tuttavia è facile dimostrare che attraverso una opportuna **selezione del set di training** possiamo creare uno spazio vettoriale in grado di definire una metrica in base alla quale misurare parole, frasi, frasi reciproche e qualsiasi altra componente linguistica. Un’alternativa è rappresentata da **lda2v** che combina un argomento con il modello di incorporamento, come descritto in (Syamala 2019). Un altro approccio che non abbiamo approfondito all’interno di questa ricerca, si basa su BERT o modelli simili di trasformatori<sup>29</sup> che hanno dimostrato di funzionare bene anche con modelli multilingua. In particolare quest’ultimo sembra essere molto promettente per la capacità di sfruttare modelli già costruiti aggiungendo solo gli elementi distintivi potendo quindi creare un training in più fasi. Lasciamo questo filone a possibili evoluzioni di questa ricerca.

Vediamo un esempio di somiglianza di parole con un modello costruito sul nostro corpus come in figura:

<pre># Look up top 6 words similar to 'firma' w1 = ["firma"] model.wv.most_similar (positive=w1,topn=6)  [('digitale', 0.8841439485549927),  ('firmare', 0.8645956516265869),  ('assegnati', 0.8069562315940857),  ('protocollo', 0.7999913692474365),  ('debbo', 0.7920989990234375),  ('valutazione', 0.7857944965362549)]</pre>	<pre># Look up top 6 words similar to 'organigramma' w1 = ["organigramma"] model.wv.most_similar (positive=w1,topn=6)  [('ebitda', 0.7770674228668213),  ('logo', 0.764962375164032),  ('organizzazione', 0.7629048824310303),  ('interviste', 0.7371212840080261),  ('capacit', 0.7316884398460388),  ('sud', 0.7307910919189453)]</pre>
--	---

Figura 38 Parole simili nel nostro contesto

Possiamo anche calcolare la somiglianza “semantica” tra due parole:

<sup>28</sup> Dipende anche dal training set utilizzato per la creazione del model word2vec

<sup>29</sup> Utilizza il meccanismo di attenzione usato nei modelli Encoder-Decoder.

```
# similarity between two different words
model.wv.similarity(w1="cedolino",w2="cud")
```

```
0.736952
```

```
# similarity between two identical words
model.wv.similarity(w1="ferie",w2="ferie")
```

```
0.99999994
```

Figura 39 Somiglianza tra parole

Possiamo anche capire quali parole non corrisponde “logicamente” ad un gruppo come mostrato nella figura seguente:

```
: # Which one is the odd one out in this list?
model.wv.doesnt_match(["ferie","cud","riunione"])
```

```
: 'riunione'
```

```
: # Which one is the odd one out in this list?
model.wv.doesnt_match(["organigramma","collega","riunione","cedolino"])
```

```
: 'riunione'
```

Figura 40 Parole che non appartengono logicamente ad un elenco

Torniamo ora di definire un metrica che ci permetta di valutare un intero dialogo.

Ipotizziamo quindi un dialogo  $D = \{(q_t, a_t)\}$  con un agente conversazionale che abbia l’obiettivo di chiudere uno specifico task  $\tau$ . Possiamo intuitivamente immaginare che la sequenza di domande non possa essere troppo “distante” rispetto ad un dialogo tipo che chiameremo “happy path”. Da questo deriva l’idea alla base del nostro algoritmo: se riusciamo a modellare un “happy path” ottimo attraverso un insieme finito di esempi possiamo pensare di ottenerne una rappresentazione vettoriale da cui possiamo derivarne una distanza semantica con le query richieste dall’utente. Possiamo intuitivamente immaginare che se la distanza, con il progredire della conversazione, diminuisce si perde **focus** rispetto all’obiettivo.

Se  $\forall a_i \in D$  calcoliamo la distanza semantica rispetto al nostro happy path che chiamiamo  $d_i$  otterremo un vettore di valori  $d = (d_1, \dots, d_n)$ . Possiamo quindi introdurre una funzione di trasformazione  $Q(d) \rightarrow \mathbb{R}$  che ci permetta di ottenere un valore numerico  $q$  che ci potrà dare una informazione numerica sulla qualità del dialogo. Una delle caratteristiche della funzione di trasformazione è che deve privilegiare un andamento crescente della distanza semantica e penalizzare la presenza di frasi semanticamente simili. Quest’ultimo è un fattore discriminante molto importante nella valutazione del dialogo. Abbiamo infatti notato, ed è anche facilmente intuibile, che quando il bot non capisce, l’utente prova a riformulare la domanda cambiando i termini cercando però di mantenere lo stesso concetto. Dal punto di vista concettuale questo può essere ricondotto a tre casi particolari. Il primo è che l’agente conversazionale non è effettivamente in grado di dare una risposta in quanto fuori dal proprio dominio di conoscenza<sup>30</sup>. Un altro caso è quando il bot sarebbe in grado di rispondere  $q_t \in \{S_i\}$  ma la  $q_t$  non è stata compresa dal bot. Il primo caso, per definizione, non rientra nelle ipotesi semplificatrici che abbiamo adottato per il nostro studio. Il secondo deve comportare una

<sup>30</sup> Che possiamo essere rappresentato dall’insieme degli skills.

penalizzazione nella nostra funzione di trasformazione in quanto rappresenta, evidentemente, un caso di bassa qualità dell'addestramento.

### Accumulo dell'entropia

Un approccio complementare che abbiamo investigato per valutare la qualità del dialogo si basa sull'intuitivo concetto che quando un discorso cresce poco a poco, aumenta la probabilità del rumore, o meglio, la probabilità di perdere la giusta struttura del discorso (il suo significato). È una specie di entropia applicata alle parole (o frase o qualunque struttura linguistica). Recentemente questa entropia linguistica è stata applicata alle recensioni d'opinione, vedi il lavoro di Liu(2016) o quello più recente di Freneda(2019), che hanno adattato un approccio incrementale dell'entropia di Shannon proposto prima da Caplin (2013). In generale avremo due casi possibili. Un discorso il cui **progresso è regolare**, avrà un basso incremento dell'entropia del linguaggio. Al contrario mentre un **discorso confuso** esploderà in una mancanza di significato.

La formula dell'entropia è semplicemente la formula di Shannon:

$$\sum_i p(w_i) \log(p(w_i)), \text{ dove } p(w_i) = \frac{\text{numero di occorrenze di } w_i}{\text{numero di occorrenze di tutte le } w}. \text{ Equazione 5}$$

Nel nostro caso abbiamo stimato che questo sistema, seppure molto interessante dal punto di vista teorico, risulta poco applicabile al nostro contesto. Nei lavori di Liu e Freneda il progresso incrementale che viene valutato si basa su un numero elevato di occorrenze. Nel nostro contesto il numero di interazioni tra utente e agente conversazionale sono talmente limitate (da 3 a 6 in media) che i valori dell'entropia calcolata sono così limitati che ci hanno impedito di avere un indice sufficientemente selettivo. Lasciamo quindi questo interessante algoritmo per possibili evoluzioni future.

### Conclusioni

Il nostro obiettivo è stato quello di esplorare possibilità in grado di permetterci di misurare la qualità del dialogo. La qualità del dialogo, come è facilmente intuibile, è uno dei fattori determinanti perché gli utenti continuino ad utilizzare l'agente conversazionale. È quindi importante analizzarne costantemente il funzionamento in modo da garantire una evoluzione costante in modo da aumentare la qualità percepita dagli utenti.

Abbiamo visto che, grazie allo sviluppo di tecniche sempre più sofisticate, sia possibile valutare oggettivamente la qualità del sistema utilizzando unicamente i dati già presenti nel sistema senza richiedere feedback agli utenti. Confrontando alcuni esempi di feedback lasciati dagli utenti reali durante il lancio del sistema abbiamo notato alcuni fattori determinanti. Il primo è l'esiguità dei feedback ottenuti. Nei primi 2 giorni di lancio<sup>31</sup> ci sono state 2333 conversazioni con 7933 messaggi inviati dagli utenti con soli 35 feedback (circa l'1,5% delle conversazioni). Analizzando i feedback (90% positivi) abbiamo anche visto che tali feedback risultano essere incongruenti. Abbiamo infatti provato ad analizzare alcune conversazioni a campione e confrontando le risposte durante le conversazioni con la valutazione del feedback abbiamo riscontrato (nel 36% dei casi) una valutazione incongruente. Abbiamo infatti osservato conversazioni in cui il bot non è stato in grado di rispondere a cui è stato assegnato feedback positivo e casi in cui il bot è stato in grado di rispondere (quasi) a tutto ricevere feedback negativo. Per una adeguata valutazione sarebbe stato necessario contattare l'utente e capire le motivazioni del feedback. Tuttavia data l'esiguità delle risposte si è deciso di soprassedere.

Al contrario abbiamo sottoposto i risultati del nostro lavoro teorico ai responsabili tecnici del servizio e la loro valutazione è stata estremamente positiva.

---

<sup>31</sup> 14 e 15 novembre

Ci sono importanti evoluzioni possibili di questo lavoro. Da un punto di vista di NLP un settore promettente sembra essere quello di investigare le potenzialità offerte dai trasformatori stile BERT che permettono, teoricamente, di beneficiare di un set praticamente infinito di corpus già pre-addestrati aumentando così in modo significativo la capacità di “comprendere” la semantica delle parole. Anche la funzione di trasformazione del valore merita un approfondimento sia pratico che teorico.

Nonostante queste ampie possibilità di studio e, potenzialmente, di miglioramento i risultati ottenuti sono già molto soddisfacenti e facilmente trasferibili all’industria.





## Capitolo 4 Adopting a Conversational Agent as a new communication channel: The effects of cross channel competition

“Everyone designs who devises courses of action aimed at changing existing situations into preferred ones.” **Herbert Simon**

### Abstract

È ormai innegabile l’influenza che i media hanno nella formazione dei comportamenti di acquisto degli utenti: viaggi, logistica, cibo e intrattenimento sono solo alcuni dei settori che hanno recentemente subito una profonda trasformazione. Oggi gli utenti maturano le proprie decisioni di acquisto principalmente online attraverso il meccanismo delle reviews che amplifica le “percezioni” degli utenti condizionandone inevitabilmente le scelte di acquisto. Questo vale anche per le aziende di servizi in cui la concorrenza si combatte principalmente online dove l’esposizione mediatica è sempre più pervasiva. Tale evoluzione impone alle aziende una sempre maggiore attenzione nell’ottimizzare le interazioni con gli utenti. Sia per conoscere le loro abitudini e le loro esigenze sia per aggiornarli continuamente con messaggi positivi. Diventa pertanto imperativo fornire ad essi il maggior numero di canali possibili attraverso cui interagire, in modo bidirezionale, con la dovuta qualità.

In questo capitolo proveremo a studiare come l’introduzione di una nuova modalità di accesso ai servizi possa modificare i comportamenti degli utenti e di come i fornitori dei servizi di accesso possano modificare tali comportamenti attraverso la gestione strategica di due parametri: la comunicazione e la qualità del servizio offerto. Proveremo quindi a capire come il reinforcement learning possa essere utilizzato per definire autonomamente i parametri che l’azienda può determinare in un gioco di strategia. La nostra ricerca ipotizza che la probabilità di adozione del nuovo modello di fruizione dei servizi da parte degli utenti dell’azienda dipenda dalla qualità percepita dagli stessi. Vedremo anche come la comunicazione possa influire sull’adozione del nuovo canale online valutando anche gli effetti di questa su di un comportamento inevitabilmente inerziale degli utenti che sono restii a modificare le proprie abitudini. Nel modello abbiamo ipotizzato che tale comportamento inerziale possa bilanciare, almeno parzialmente, l’effetto di stimolo introdotto dalla comunicazione.



## Introduzione

Il successo legato all'introduzione di un agente conversazionale è influenzato da diversi fattori, tecnici ed economici, che devono essere considerati per garantirne i risultati sia in funzione dei target che degli investimenti necessari alla realizzazione e alla progressiva adozione da parte degli utenti.

Il nostro lavoro si basa sull'analisi dell'introduzione di un agente conversazionale all'interno di una importante azienda italiana analizzando oltre 20 mila conversazioni<sup>32</sup> reali con circa 230 mila messaggi di cui 75 mila degli utenti. L'obiettivo è quello di determinare una metodologia che ci definisce la relazione tra gli investimenti e l'adozione da parte degli utenti.

Per semplificare la trattazione abbiamo immaginato di modellare l'introduzione di un nuovo agente conversazionale come l'ingresso di un competitor all'interno di un mercato chiuso governato da un monopolista. In questa ipotesi abbiamo un mercato identificato dai dipendenti dell'azienda che interagiscono con la stessa attraverso due differenti canali di comunicazione forniti da due divisioni aziendali in concorrenza tra loro per ampliare il market share definito, nel nostro caso, dagli accessi ai rispettivi servizi. Abbiamo anche pensato di modellare il prezzo come la qualità percepita dagli utenti nella interazione. Gli utenti hanno quotidianamente bisogno di accedere ai servizi aziendali, con l'introduzione dell'agente conversazionale viene data loro la possibilità di scegliere secondo una loro funzione di utilità e allocare le loro esigenze di interagire con l'azienda, che considereremo finite<sup>33</sup>, secondo le loro preferenze. Le aziende possono incidere sul "prezzo" attraverso investimenti che possono modificare il sistema e migliorare la qualità percepita dagli utenti (velocità, livello di comprensione, completezza, ecc.). Il mercato è quindi identificato dai dipendenti dell'azienda e, sotto queste ipotesi, possiamo adottare il modello duopolistico in un modello di interazione strategica in cui le due divisioni competono strategicamente in un gioco non cooperativo a fasi ripetute adeguando il prezzo per conquistare quote mercato.

Un fattore non trascurabile nella scelta dei consumatori è dato dalla pubblicità che è rappresentata, in questo caso, dalla comunicazione aziendale. La comunicazione è in grado di influenzare il comportamento degli utenti. Per misurare l'effetto della comunicazione abbiamo ipotizzato solo due canali di accesso al servizio: l'agente conversazionale e la intranet aziendale di seguito "web". Possiamo quindi ipotizzare di modellare gli effetti della comunicazione in un mercato duopolistico, in cui porzioni di consumatori mostrano una inerzia latente nel modificare i propri comportamenti di acquisto. La pubblicità svolge contemporaneamente il doppio ruolo decisivo sia nel provare a ridurre tale inerzia attraverso la consapevolezza che nel miglioramento del valore percepito del marchio (persuasione).

Nel lancio di un nuovo canale per la fruizione di un servizio da parte dell'impresa è importante considerare la comunicazione. La comunicazione, nel nostro caso, ha due finalità: comunicare l'esistenza di un nuovo canale di comunicazione e fornire agli utenti gli elementi per decidere di quali fruire.

Nel nostro studio, la comunicazione implementa un "avviso favorevole" per gli attributi dell'agente conversazionale che il servizio ritiene possa aumentare la loro probabilità di adozione da parte degli utenti. Una nota favorevole riguardo a un attributo è una qualsiasi azione (parola, immagine, video, articolo ecc.) che possa spostare l'attenzione degli utenti verso quell'attributo. La ripetizione di queste note aumenta il peso soggettivo che gli utenti assegnano a un particolare attributo. Nel nostro contesto, le due aziende in

---

<sup>32</sup> A partire dal lancio del servizio

<sup>33</sup> Supponiamo che ogni utente abbia una necessità minima finita di accedere ai servizi dell'azienda ma che non esista un numero massimo di volte

concorrenza utilizzano il proprio budget per massimizzare la propria quota di mercato<sup>34</sup>. Lo fanno attraverso ciò che si può considerare come "*rinforzo positivo*" nella comunicazione.

I modelli di concorrenza pubblicitaria e i suoi effetti sul comportamento dei consumatori e sulle performance del mercato hanno due ampie scuole. Una considera la pubblicità come un canale che fornisce informazioni ai consumatori, consentendo loro di fare scelte razionali riducendo la differenziazione dei prodotti. L'altra identifica la pubblicità come un dispositivo che persuade i consumatori mediante differenziatori immateriali e/o psicologici creando una differenziazione tra i prodotti (Comanor e Wilson 1974), che a volte potrebbe non essere reale (Tirole 1990).

Tuttavia, la pubblicità nella letteratura esistente svolge un ruolo prevalentemente unidimensionale. Ad esempio, un ampio gruppo di pubblicazioni relativo alla pubblicità informativa la considera uno strumento per la diffusione di informazioni, annunciando l'esistenza di un marchio, soluzioni fruibili, attributi importanti, prezzo, qualità, ecc. (Ovvero, Nelson 1970, 1974; Butters 1977; Grossman e Shapiro 1984). D'altra parte abbiamo notato una relativa scarsità di letteratura sulla pubblicità persuasiva, volta a convincere le persone ad acquistare un particolare prodotto o marchio (Koh e Leung 1992).

Sebbene vi siano situazioni in cui uno dei ruoli pubblicitari (consapevolezza e persuasione) viene utilizzato separatamente dai professionisti del marketing (ad es., Solo funzioni informative nella pubblicità al dettaglio localizzata, nei confronti della pubblicità televisiva), le aziende spesso usano la pubblicità come mix di elementi al contempo informativi e persuasivi.

Possiamo considerare il seguente esempio. Utilizzare un agente conversazionale permette di usufruire di un servizio senza la necessità di conoscere a priori le modalità attraverso le quali è possibile fruirne. Viene cioè effettuato uno "shadowing" della tecnologia molto più evoluta rispetto a qualsiasi altra tecnologia attualmente disponibile. Non c'è bisogno di essere un esperto né di informatica né della procedura per poter interagire con il sistema. È infatti sufficiente rispondere alle domande che il sistema propone o comporre adeguatamente le richieste. Il tutto utilizzando il linguaggio naturale che, fin dall'infanzia, è la metodologia che utilizziamo per interagire con l'ambiente circostante. Gli esperti di computer, i sociologi e gli psicologi, hanno iniziato a confrontarsi sui vantaggi e gli svantaggi delle modalità di interazione attraverso un agente conversazionale. Interessante il lavoro di Sarah Bankins e Paul Formosa del 2019. In questo lavoro si studia le modalità di interazione tra umani e AI immaginando una evoluzione possibile che "***transform notions of workplace technology from being a tool to being an active partner***". È facile immaginare che l'azienda<sup>35</sup> che eroga il servizio attraverso il bot pubblicizzerà il suo vantaggio, che è la facilità di accesso e l'ubiquità, e questo potrebbe permetterle di addebitare ai consumatori un prezzo più elevato in termini di efficacia del funzionamento<sup>36</sup>. Occorre quindi convincere gli utenti che il prezzo pagato per una interazione conversazionale vale il prezzo più alto rispetto ad altre modalità di accesso. Allo stesso modo, i concorrenti pubblicizzano la loro velocità nell'esecuzione dei compiti tralasciando la complessità del dover imparare una funzione specifica che magari useranno saltuariamente con ampia discontinuità.

L'"unique selling proposition" non è un concetto nuovo ed è stato introdotto da Rosser Reeves già negli anni '40. Reeves, in breve, afferma che una campagna pubblicitaria riuscita professa una proposta unica per i consumatori e questo li convince, attraverso la distorsione della realtà, a cambiare marchio. Questa nozione

---

<sup>34</sup> *Gli utenti complessivi del servizio*

<sup>35</sup> *Nel nostro caso una funzione aziendale e non un'azienda in senso stretto. Ma per i nostri scopi continueremo a chiamarla azienda non togliendo niente in generalità.*

<sup>36</sup> *È possibile dimostrare che l'utilizzo di una funzione dedicata, se si esclude la fase di apprendimento, è più efficiente di una interfaccia conversazionale.*

indica che tutti gli attributi di un prodotto possono essere ricapitolati in due categorie: un tratto **distintivo** in una categoria e il **resto** in un'altra, con le aziende che pubblicizzano solo il tratto distintivo.

Le campagne pubblicitarie delle aziende sono concepite con l'obiettivo di vendere di più i loro prodotti ma assumono, spesso, due ruoli fondamentali. Il primo è fornire ai consumatori informazioni sugli attributi che meglio identificano il prodotto pubblicizzato. Il secondo, forse ancora più importante, è quello di convincere i consumatori che questo è il prodotto che stanno cercando ed è da preferire rispetto ad altre alternative. Nella letteratura di marketing, quest'ultimo è noto come *effetto persuasivo* della pubblicità mentre il primo è noto come pubblicità informativa. Entrambi i tipi di pubblicità mirano a cambiare la scelta dei consumatori e ad aumentare la quota di mercato. Ad esempio, un annuncio pubblicitario tipico conterrà informazioni relative al prodotto o al marchio (ad esempio, bozza, birra chiara, luce), ma allo stesso tempo la strategia creativa contiene elementi che non hanno nulla a che fare con il prodotto in sé, ma aiuta a costruire il cosiddetto effetto marchio.

Sappiamo che le preferenze dei consumatori possono essere rappresentate dai pesi soggettivi del vettore nello spazio degli attributi dei prodotti che influenzano la loro scelta. Nella nostra analisi, i consumatori<sup>37</sup> sono estremamente razionali nel senso che la loro scelta può essere manipolata dalle imprese<sup>38</sup> solo come conseguenza di una serie di comunicazioni mirate a spostare l'attenzione dei consumatori da una caratteristica del prodotto a un'altra a favore dell'azienda che eroga il prodotto specifico. Nel nostro modello, alterare i pesi soggettivi associati agli attributi permette di valutare l'influenza degli stessi nell'adozione del servizio. È evidente che ci possono essere altri fattori endogeni dei prodotti che influenzano le scelte dei consumatori su cui le aziende possono intervenire per ampliare il loro market share. Tra questi la qualità del servizio, la velocità ecc.

Esaminiamo gli effetti incrociati della pubblicità sui prezzi, sui quali la letteratura di marketing non è stata in grado di convergere su una posizione univoca. Alcuni studi sperimentali (Moriarty 1983, Bemmaor e Mouchoux 1991) ed econometrici (Bolton 1989 e Popkowski-Leszczyc e Rao 1989) indicano che la pubblicità tende ad aumentare la sensibilità al prezzo. Tuttavia, ci sono alcuni (Staelin e Winer 1976, Ghosh et al. 1983, Krishnamurthi e Raj 1985, Boulding et al. 1994) che indicano il contrario.

Kauland Wittink (1995) suggerisce che le prove contrastanti dipendono dal tipo di pubblicità: prezzo o non prezzo. In questo documento, daremo per scontato che la direzione dell'effetto pubblicitario sui prezzi dipende dall'entità dell'inerzia latente nel comportamento di acquisto dei consumatori. In particolare, se una grande parte dei consumatori è bloccata in un determinato marchio, in modo tale da mostrare forti tendenze di acquisto inerziale, allora l'impatto di bassi livelli di pubblicità sui prezzi è negativo. Tuttavia, questo impatto è positivo per alti livelli di pubblicità (vedi, ad esempio, Kanetkar et al. 1992, Mitra e Lynch 1995). L'effetto della pubblicità sui prezzi è regolato dalle dimensioni relative dell'elasticità pubblicitaria della considerazione del consumatore e da quella dell'avviamento persuasivo.

Modelliamo quindi la comunicazione di due o più aziende ai consumatori con l'invio di messaggi in modo tale che alla fine della campagna di comunicazione l'atteggiamento dei consumatori possa cambiare rispetto a un prodotto. La ripetizione della comunicazione è importante perché ha un effetto persuasivo oltre che per massimizzare la diffusione del messaggio permettendo a tutti di vederne almeno uno.

Nel nostro modello di duopolio, la pubblicità non ha un ruolo difensivo da svolgere. Nessuna quantità di pubblicità può impedire ai consumatori di un marchio di prendere in considerazione l'altro marchio, se l'altro marchio sceglie di seguirlo con la pubblicità. È quindi dimostrabile che, anche in un gioco simmetrico, esistono equilibri asimmetrici (pubblicitari), in cui solo un'azienda pubblicizza, fissa un prezzo più elevato e acquisisce

---

<sup>37</sup> I dipendenti dell'azienda

<sup>38</sup> I fornitori del bot e del web

anche una maggiore quota di mercato. Un'implicazione dell'esistenza di equilibri pubblicitari asimmetrici nel nostro modello statico sembra suggerire che programmi pubblicitari continui *possano dominare le politiche nei mercati* in cui i consumatori mostrano forti tendenze all'acquisto inerziale.

Dobbiamo distinguere due tipi di strategie pubblicitarie. Il primo tipo di pubblicità è orientato a creare una sinergia. Questo si verifica quando la comunicazione di un'azienda spinge su un determinato attributo per aumentarne il peso associato, ma al contempo aumenta i pesi associati a quell'attributo per tutte le altre imprese. Nell'altro tipo, le aziende enfatizzano la comunicazione per aumentare solo il peso attribuito ai propri attributi. Il nostro focus è su quest'ultimo, che richiede che i pesi siano indipendenti tra le aziende.

Abbiamo provato a inserire la comunicazione all'interno di un *gioco a fasi ripetute*. Nella prima fase si svolgerà la pubblicità e le aziende cercano di convincere i consumatori. Nella seconda fase le imprese fisseranno il prezzo per massimizzare il loro market share che, nel nostro caso è la retention degli utenti. Il prezzo sarà funzione della strategia che l'agente decide di implementare per rispondere alle politiche del concorrente. Gli elementi che può influenzare sono quindi il prezzo e, per semplificare la trattazione, gli investimenti pubblicitari. Terminata la seconda fase il gioco si ripeterà all'infinito. Nel nostro caso specifico abbiamo adottato la ragionevole ipotesi che il mercato non presenti barriere. Questo vuol dire che un utente può passare liberamente da un servizio ad un altro senza nessun tipo di penalizzazione.

Il nostro obiettivo è quello di costruire una rete Q-Learning che, in queste ipotesi, sia in grado di definire la migliore strategia di risposta alle scelte adottate dalla concorrenza analizzando i casi reali.

### Letteratura correlata

La letteratura sulla pubblicità è divisa in molti rami. Un ramo studia **l'effetto della pubblicità sulla concorrenza** e scoraggia l'ingresso di nuove imprese. Relativi a questo ramo sono quegli articoli che studiano l'effetto della pubblicità sulla concorrenza dei prezzi. La pubblicità mira a spostare la domanda dei consumatori per il prodotto delle imprese. Pertanto, ciò porta a una concorrenza sui prezzi, data l'elasticità incrociata e la curva della domanda. Per ulteriori informazioni sulla pubblicità e la concorrenza, consultare il sondaggio di Comanor e Wilson (1979). Esistono diversi studi che approfondiscono questo aspetto e sul fatto che le aziende possono fissare prezzi più alti non solo a causa delle loro spese pubblicitarie, ma anche a causa degli attributi dei loro prodotti e delle preferenze dei consumatori prima che avvenga la pubblicità. Uno studio ben noto su questo argomento è Schmalensee (1983). In questo studio viene presentato un modello di pubblicità in due fasi come un modo per scoraggiare l'ingresso. In questo modello viene dimostrato come per il monopolista storico non è mai ottimale aumentare la pubblicità al fine di scoraggiare l'ingresso del nuovo concorrente.

Un altro ramo della letteratura scientifica sulla pubblicità studia la **comunicazione persuasiva**. La persuasione usata nella pubblicità ha radici comuni in Psicologia ed Economia. In Psicologia, ci sono state diverse definizioni relative al concetto di persuasione. Ciò che accomuna queste definizioni è lo sforzo impresso dal comunicatore per modellare e cambiare l'atteggiamento dell'ascoltatore trasmettendo una serie di messaggi (verbale o non verbale, ragionevole o non ragionevole). Il termine 'atteggiamento' è anche definito da molti autori (Fazio, 1989; Perloff, 2003) ma seguiamo la definizione di Petty e Wegener (1998), *“L'atteggiamento è la valutazione complessiva di un oggetto o problema da parte di una persona, e il cambiare atteggiamento significa che la valutazione di una persona viene modificata da un valore, spesso la sua valutazione iniziale, a un altro”*.

Nel mondo economico, Kaldor che già nel 1950 è stato il primo a sostenere l'idea che la pubblicità è manipolativa e riducendo la concorrenza porta inesorabilmente alla riduzione del benessere. Molti studi anche approfonditi hanno inequivocabilmente dimostrato come la pubblicità possa distorcere la realtà inducendo erroneamente i consumatori a credere che prodotti identici siano diversi, perché la decisione di quale marchio acquistare dipende dalla percezione dei consumatori piuttosto che dalle effettive

caratteristiche fisiche del prodotto. Questo comporta che i prezzi dei prodotti fortemente pubblicizzati possano aumentare ben oltre il loro costo di produzione. La letteratura della pubblicità come segnale contenente informazioni sugli attributi di un prodotto risale addirittura al 1974 con Nelson. Successivamente Kihlstrom e Riordan nel 1984 hanno fatto un ulteriore passo in avanti modellando l'idea di Nelson sulla concorrenza del mercato in cui le spese pubblicitarie sono un segnale di qualità. Questo spinge i produttori di alta qualità a pubblicizzare maggiormente in quanto hanno un ritorno più elevato alla pubblicità. Come sottolinea McFadden nel suo lavoro *"Econometric models for probabilistic choice among products"* del (1980), l'atteggiamento e la percezione influenzano il comportamento del mercato mentre cambiano la probabilità della scelta delle alternative. La relazione tra atteggiamenti e percezione, da un lato, e attributi oggettivi, dall'altro, può essere interposta o semplicemente separabile. In entrambi i casi, gli attributi oggettivi dei prodotti hanno un'interconnessione con la misurazione psicologica.

Grossman e Shapiro (1984) sono stati i primi a studiare la pubblicità nei mercati con prodotti differenziati, in cui l'unica fonte di informazione dei consumatori sono le pubblicità, che presentano informazioni accurate sugli attributi dei prodotti. Sottolineano inoltre, correttamente, che il motivo della pubblicità eccessiva è quello di influenzare le preferenze dei consumatori, chiamata pubblicità persuasiva, sebbene non le abbiano studiate in modo più dettagliato. Fehr e Stevik con il loro lavoro *"Persuasive advertising and product differentiation"* del 1998 hanno distinto tre tipi di pubblicità persuasiva. 1) migliorare il valore di un prodotto agli occhi del consumatore; 2) indurre i consumatori ad attribuire maggiore importanza alle differenze già esistenti tra i prodotti; 3) una competizione tra aziende in cui ognuna tenta di attrarre i consumatori modellando le loro preferenze per adattarsi alle caratteristiche del suo prodotto. Becker e Murphy (1993) presentano un modello in cui gli annunci pubblicitari entrano nell'utilità dei consumatori come "beni" o "cattivi". Nel loro modello semplice, la pubblicità **augmenta l'utilità marginale di un bene**.

Un'altra branca della letteratura scientifica sulla pubblicità si concentra sulla pubblicità introduttiva, il ruolo della pubblicità per presentare un prodotto ai clienti. Investire nella pubblicità in questi modelli aumenterà la domanda del prodotto man mano che aumenterà la parte del mercato che è a conoscenza del prodotto. Questo filone, seppure concettualmente interessante, non permette tuttavia una significativa distinzione in quanto qualsiasi tipo di pubblicità serve più o meno questa funzione.

È anche interessante anche il lavoro di Skaperdas e Vaidya in cui nel loro articolo *"Persuasion as a Contest"* del 2008 modellano la persuasione **come una sfida** in cui la probabilità di convincere il pubblico dipende dalle risorse spese dalle parti in competizione. Il loro obiettivo principale è quello di ricavare le funzioni di successo della sfida utilizzate in letteratura dal processo inferenziale di un pubblico che osserva le prove prodotte dai concorrenti che cercano di convincere il pubblico della correttezza delle rispettive opinioni. Nel nostro modello, invece, le aziende orientano la propria comunicazione per **migliorare la percezione del proprio servizio**, al fine di conquistare una quota di mercato più elevata.

Su un percorso pertinente, tuttavia diverso dalla pubblicità, Gabaix e Laibson (2006) presentano un modello di competizione tra le imprese in cui ogni impresa cerca di nascondere alcuni attributi del suo prodotto. Nel loro modello, il prodotto o il servizio delle imprese è diviso in "bene di base" e "componenti aggiuntivi" e le imprese sono interessate a nascondere alcuni dei loro attributi di componenti aggiuntivi per sfruttare i consumatori miopi con l'aiuto di schemi di marketing.

Questo documento è organizzato come segue. Introduciamo prima il modello teorico in cui le aziende competono per conquistare quote di mercato in concorrenza e le ipotesi relative. Tra i parametri su cui l'azienda può intervenire c'è il prezzo, con investimenti nella tecnologia, oppure in comunicazione per cambiare i pesi che i consumatori attribuiscono agli attributi di ciascun prodotto.

## Il Modello

Nel nostro modello consideriamo due divisioni aziendali, nel seguito aziende, che competono per proporre ai loro **clienti**, i dipendenti dell'azienda di seguito **mercato**, il loro **servizio** (nel seguito prodotto).

I prodotti in questione sono i due modi alternativi per accedere ad un determinato servizio aziendale comune. In questo caso ipotizziamo che il fattore di scelta per un utente sia il tempo effettivamente speso nella fruizione del servizio che chiameremo **prezzo**<sup>39</sup>. Tale prezzo è influenzato da una serie di fattori che lo rendono oggettivamente differente nei due casi. È anche facile ipotizzare che tale prezzo, nel caso dell'agente conversazionale, sia influenzato dalla qualità percepita come ipotizzato nel capitolo precedente. Semplicità nell'accesso, facilità nella fruizione, complessità delle procedure per il raggiungimento del servizio sono quindi alcuni dei fattori che determinano il prezzo finale. Ai fini della nostra discussione abbiamo chiamato l'insieme correlato di questi attributi **prezzo**. Ipotizziamo che per modificare tale prezzo siano necessari investimenti da parte delle aziende per cui, all'interno di ogni singolo step nella competizione questo non possa variare. Tuttavia, in funzione delle azioni della concorrenza sarà possibile, con gli opportuni investimenti, variare il prezzo.

Possiamo quindi riformulare il nostro problema nel modo seguente: Due aziende competono per vendere sul mercato i loro prodotti distinti, non omogenei e sostitutivi. Etichettiamo i loro rispettivi prodotti con un indice  $i = \{1,2\}$  dove l'azienda  $i$  vende il prodotto  $i$  ad un prezzo  $p_i$ .

Dato il contesto possiamo ipotizzare che i costi marginali di produzione sia uguale per entrambi i prodotti e pari a zero<sup>40</sup>. Abbiamo quindi un insieme di potenziali consumatori con gusti, attitudini e propensione all'innovazione molto eterogeneo. Supponiamo che ciascuno di essi acquisti un'unità di prodotto da una delle aziende. La massa totale di questi consumatori è normalizzata a uno per comodità.

Infine immaginiamo che *non esistano costi di transizione*. Gli utenti sono infatti liberi di passare da un prodotto ad un altro senza pagare nessun tipo di penalizzazione.

Sotto queste ipotesi abbiamo quindi un duopolio in cui due aziende, 1 e 2, producono un prodotto differenziato con **costi marginali di produzione** identici e costanti pari a zero. Dato lo specifico contesto possiamo ipotizzare che non ci sia collusione. Le aziende sono neutrali al rischio e si impegnano in un gioco non cooperativo in più fasi.

Le imprese competono su un mercato di dimensioni fisse,  $N$ , di cui una parte,  $\sigma_1$ , detenuto dalla ditta 1 e  $\sigma_2 = N - \sigma_1$  detenuto dalla ditta 2. Potremmo quindi interpretare  $\frac{\sigma_1}{N}$  e  $\frac{\sigma_2}{N}$  come le quote di mercato delle rispettive aziende.

Ogni prodotto è caratterizzato da  $n$  attributi distintivi. Identifichiamo con  $X_i$  il vettore degli attributi del prodotto  $i$  con  $i=1,2$ . I consumatori associano un vettore di pesi  $W_i$  per ogni attributo del prodotto. È importante supporre che  $w_i$  sia indipendente da  $w_j$ . Questo ci permette di considerare che la pubblicità di una società influenzerà solo la percezione del proprio prodotto.

Possiamo quindi introdurre una funzione di utilità multi attributo  $u(\cdot): W \times X \rightarrow R$  che è definita per i consumatori sull'insieme di attributi e sui loro pesi soggettivi. Supponendo un comportamento razionale degli utenti ne consegue che gli attributi di ciascun prodotto vengono valutati in modo obiettivo, ma le aziende utilizzano la pubblicità per modificare la percezione di questi attributi nella valutazione totale dei consumatori in modo tale che il loro prodotto venga preferito. Questo è noto come **distorsione della realtà** (**reality distortion**) che permette alla pubblicità capacità di convincere i consumatori distorcendo il loro senso

<sup>39</sup> Non essendo un dato numerico è soggetto ad un bias interpretativo da parte degli utenti. Nella nostra trattazione, semplicità, lo considereremo come un dato che un'azienda può influenzare solo attraverso investimenti necessari per migliorarne la qualità, la velocità ecc.

<sup>40</sup> In realtà sempre più questi servizi vengono erogati in Cloud in modalità SaaS (Software as a Service) per cui in futuro il costo marginale potrebbe non essere nullo.

delle scale di attributi in modo tale da ritenere che il prodotto reclamizzato sia da preferire anche rispetto al prezzo. Normalizziamo i valori dei pesi attribuiti nell'intervallo [0,1]. Evidentemente, se il peso è zero per un qualsiasi attributo, i consumatori non si preoccupano di quel particolare attributo.

Pertanto, l'utilità ex ante dei consumatori di acquistare un'unità di prodotto dall'impresa  $i$  è:

$$U_i = w_i x_i + (1 - w_i)(1 - x_i) - p_i \text{ con } i \in \{1,2\} \quad \text{Equazione 6}$$

Il peso attribuito al prezzo è uno in quanto le imprese non possono nascondere ai consumatori. In questo modo, ad esempio, gli utenti possono chiedersi quanto vale una interazione vocale o la fruizione attraverso il cellulare rispetto al prezzo del marchio  $i$ .

Il lavoro di Hauser e Wernerfelt del 1990 descrive la scelta del marchio come un processo in due fasi: in primo luogo, un consumatore forma il suo insieme di considerazioni (che può essere influenzato dagli sforzi pubblicitari delle aziende) e decide se includere uno o entrambi i marchi nell'insieme delle possibili alternative di acquisto. Quindi viene effettuato l'acquisto effettivo valutando solo l'insieme di aziende considerate in base alla qualità percepita e ai rispettivi prezzi.

Le imprese inviano simultaneamente annunci ai consumatori per modificare il peso che hanno attribuito agli attributi dei loro prodotti. È intuitivo che ogni impresa cerchi di pubblicizzare il suo miglior attributo per enfatizzarlo rispetto agli altri. Possiamo identificare la strategia pubblicitaria di ogni azienda con  $\gamma_i$ . Ai fini del nostro studio abbiamo supposto che il costo marginale di un annuncio sia normalizzato a uno e il vettore di strategie pubblicitarie comuni è indicato con  $\Gamma=(\gamma_1, \gamma_2)$ . La quantità di pubblicità  $\gamma$  può essere interpretata come pagine all'interno della intranet aziendale, il numero di messaggi sui social network specializzati, le campagne informative su una rivista ecc.. Nel nostro caso ci limiteremo alla comunicazione interna, sia strutturata che no.

**Definizione 1.2.1** Definiamo la pubblicità come una funzione di comunicazione  $\Phi_i(w_i, \gamma_i)$  per l'impresa  $i$ , secondo la quale il vettore di peso dei consumatori  $W_i$  per il prodotto  $i$  viene aggiornato dopo ogni campagna di comunicazione. Pertanto le utilità dopo la pubblicità diventano:

$$U_i = \Phi_i(w_i, \gamma_i)x_i + (1 - \Phi_i(w_i, \gamma_i))(1 - x_i) - p_i \quad \text{Equazione 7}$$

$i \in \{1,2\}$

Nel nostro caso ipotizziamo che le aziende utilizzino gli stessi mezzi di comunicazione e, di conseguenza, hanno le stesse proprietà. L'efficacia della funzione di comunicazione dipende anche da quanto siano sofisticati o ingenui i consumatori. Se i consumatori vengono manipolati facilmente dalla pubblicità, sono più ingenui. Nella letteratura pubblicitaria, Pre-testing<sup>41</sup> è una branca della ricerca di mercato per l'analisi dell'efficacia degli annunci prima della loro pubblicazione. Possono analizzare le pubblicità e dirigere il flusso di attenzione durante una pubblicità. (Young, 2005)

Possiamo ipotizzare la concavità di  $\Phi_i(w_i, \gamma_i)$  in quanto è facile immaginare che i pesi associati agli attributi di un prodotto possano aumentare con la pubblicità ma solo fino a un determinato livello, raggiungendo nel tempo una sorta di saturazione che rende il messaggio progressivamente più debole e incapace di aumentare ulteriormente il peso. Questo è il punto in cui i consumatori sono stufo della pubblicità e non ci crederanno più (Becker e Murphy, 1993). Becker e Murphy, tra molti altri, sostengono che gli inserzionisti forniscono programmi di raccolta di utilità gratuiti per compensare gli spettatori per averli esposti agli annunci.

<sup>41</sup> Anche conosciuta come Coy testing

### Reinforcement learning e dinamica della formazione del prezzo

Per catturare la dinamica della formazione sequenziale del prezzo prendiamo un duopolio in i prezzi vengono determinati in mosse ripetutamente sequenzialmente indefinitamente (Maskin e Tirole, 1988). Di seguito descriviamo questo ambiente, la nostra impostazione di base e il suo comportamento di equilibrio.

La competizione tra due imprese  $i=\{1,2\}$  avviene in un tempo discreto ripetuto all'infinito indicizzato da  $t=\{1,2,3,\dots,n\}$ . Le rettifiche del prezzo avvengono in sequenza: a sua volta, ogni impresa regola il suo prezzo  $p_t^i \in P$ , dove in periodi di numero dispari l'impresa 1 regola il suo prezzo e in periodi di numero pari lo regola l'impresa 2. Il prezzo è una variabile discreta compresa tra 0 e 1 e con  $k$  intervalli di dimensioni uguali {quindi i risi sono presi da un set discreto  $p = \{0, \frac{1}{k}, \frac{2}{k}, \dots, 1\}$ . Al momento  $t$ , il profitto dell'impresa  $i$  è dato da:

$$\pi^i(p_t^i, p_t^j) = (p_t^i - c^i)D^i(p_t^i, p_t^j) \quad (8)$$

Dove  $c^i$  è il suo costo marginale e  $D^i(p_t^i, p_t^j)$  la funzione di domanda che dipende dal proprio prezzo e da quello del concorrente. Possiamo immaginare che non ci siano costi fissi e che la curva di profitto sia strettamente concava. Le imprese attualizzano i profitti futuri con un fattore di sconto  $\delta \in [0,1)$  e l'obiettivo di massimizzazione di ogni impresa può essere riscritto nel modo seguente:

$$\max \sum_{s=0}^{\infty} \delta^s \pi^i(p_{t+s}^i, p_{t+s}^j) \quad (9)$$

Nel nostro caso di base, seguiamo *Maskin e Tirole* nell'imporre il presupposto di Markov: le strategie dipendono solo da variabili che sono direttamente rilevanti per il payoff, che in questo caso è limitato al precedente prezzo del concorrente  $p_{t-1}^j$  e non include, ad esempio, la comunicazione o la storia dei prezzi. La strategia dell'impresa  $i$  è quindi una funzione di reazione dinamica  $R^i(\cdot)$ , dove a sua volta  $p_t^i = R^i(p_{t-1}^j)$ .

Nel seguito ci limiteremo al caso semplice impostazione di beni omogenei con domanda lineare e costo marginale zero, che è anche il caso di base di Maskin e Tirole. La domanda ha un'intercetta e una pendenza pari a 1 tale che:

$$D^i(p_t^i, p_t^j) = \begin{cases} 1 - p_t^i & \text{se } p_t^i < p_t^j \\ 0,5(1 - p_t^i) & \text{se } p_t^i = p_t^j \\ 0 & \text{se } p_t^i > p_t^j \end{cases} \quad (10)$$

Supponendo che ci sia un costo marginale  $c^i$  pari a zero, abbiamo come monopolio o prezzo collusivo che massimizza il profitto congiunto  $p^c = 0,5$ . Non approfondiremo queste tematiche che esulano dalla trattazione. Una coppia di strategie  $(R^1, R^2)$  è un equilibrio di Nash se per tutti i prezzi lungo il percorso di equilibrio vale la seguente condizione valore-funzione per entrambe le aziende:

$$V^i(p^j) = \max_p \left[ \pi^i(p, p_j) + E_{p_j'} [\delta \pi^i(p, p_j') + \delta^2 V^i(p_j')] \right] \quad (11)$$

Dove la funzione di reazione  $R^i(p^j)$  è una scelta massimizzante per l'azienda  $i$  e l'aspettativa sulla risposta del concorrente  $p^j$  è presa rispetto alla distribuzione di  $R^j(p)$ .

Un equilibrio di Nash qui è il risultato statico di Nash in cui le aziende hanno sempre un prezzo o un incremento al di sopra del costo marginale, sebbene esistano più equilibri per un fattore di sconto sufficientemente elevato.

### Reinforcement learning

L'algoritmo di apprendimento applicato qui è un adattamento del Q-learning all'interazione sequenziale. Il Q-learning è un modello di reinforcement learning semplice ma ben definito che mira a massimizzare il valore attuale netto delle ricompense future attese per ambienti con interazioni ripetute. Originariamente è stato

proposto da Watkins (1989) per risolvere i processi decisionali di Markov sconosciuti, che sono processi stocastici a tempo discreto in cui le azioni influenzano sia la ricompensa attuale sia lo stato successivo in un ambiente altrimenti stazionario. Di seguito le specifiche sono discusse in dettaglio, seguite da una nota sui suoi limiti teorici e le sfide nel nostro contesto.

**Definizione**

Gli algoritmi di **reinforcement learning** consistono in due moduli interagenti: un modulo di apprendimento che elabora le informazioni osservate e un modulo di selezione dell'azione che bilancia l'utilizzo (scegliendo il prezzo ottimale attualmente percepito) con l'esplorazione (scegliendo forse un altro prezzo, per imparare cosa succede).

**Modulo di apprendimento** – Il Q-learning stima una funzione  $Q^i(p^i,s)$  che imposta lo stato  $S$ . Assumendo un insieme di stati discreto  $Q^i$  nel nostro caso è una matrice  $|P \times S|$ . Dopo aver osservato i propri profitti e il nuovo stato  $s'$ , l'algoritmo aggiorna la voce  $Q^i(p^i,s)$  in base alla seguente relazione ricorsiva:

$$1. Q^i(p^i,s) \leftarrow (1-\alpha) \cdot \text{vecchia stima} + \alpha \cdot \text{stima osservata}, \tag{12}$$

$$2. \text{vecchia stima} = Q^i(p^i,s)$$

$$3. \text{stima osservata} = \pi(p^i, s) + \delta \pi(p^i, s') + \delta^2 \max_p (Q^i(p, s'))$$

dove  $\alpha \in (0,1)$  è un parametro di passo che determina il peso attribuito alla stima osservata rispetto al suo vecchio valore e  $\delta \in [0,1)$  è di nuovo un fattore di sconto.

Si noti che la stima osservata è composta da tre componenti: profitto diretto  $\pi(p^i,s)$ , profitto del periodo successivo  $\pi(p^i,s')$  quando si realizza il nuovo stato  $s'$  (scontato per un periodo) e il valore  $Q$  massimo  $\max_p Q^i(p,s')$  più alto possibile in questo nuovo stato  $s'$  (scontato per due periodi).

Inizialmente, i valori  $Q$  sono imprecisi, ma nel tempo diventano stime sempre migliori delle conseguenze a lungo termine della scelta di  $p^i$  nello stato  $s$ , consentendo la convergenza.

Secondo il presupposto di Markov, lo stato presente  $s$  e quello futuro  $s'$  sono equivalenti al prezzo attuale e a quello nuovo del concorrente. Possiamo quindi affermare che il Q-learning mira a risolvere una condizione di programmazione dinamica.

**Modulo Action Selection** - Nel bilanciare esplorazione e sfruttamento, l'algoritmo adotta una politica probabilistica di selezione dell'azione. Usiamo una procedura di esplorazione semplice chiamata  $\epsilon$ -greedy: con probabilità  $\epsilon_t$   $\epsilon_t \in [0,1]$  viene selezionato un prezzo a caso (esplorazione) e con probabilità  $1-\epsilon_t$  viene selezionato il prezzo ottimale attualmente percepito (sfruttamento), quindi

$$p_t^i = \begin{cases} \sim U\{P\} & \text{con probabilità } \epsilon_t \\ = \operatorname{argmax}_p Q^i(p, s_t) & \text{con probabilità } 1 - \epsilon_t \end{cases} \tag{13}$$

dove  $U\{P\}$  è una distribuzione uniforme discreta sull'insieme delle azioni  $P$ . In caso di legami non utilizzati sfruttamento, l'algoritmo randomizza su tutte le azioni ottimali percepite. Si noti che nel modulo di apprendimento, ogni volta viene aggiornata una sola voce all'interno della matrice  $Q$ .

Tale apprendimento tabulare porta ad un processo di apprendimento lento, e anche l'esplorazione  $\epsilon$ -greedy non è ottimizzata. Durante l'esplorazione viene selezionato qualsiasi prezzo in modo casuale. Ai fini di questa ricerca abbiamo implementato l'algoritmo non ottimizzato sfruttando la potenza di calcolo offerta dal cloud. Così come con il modulo di apprendimento anche il modulo di selezione dell'azione potrebbe essere migliorato utilizzando tecniche più sofisticate.

Di seguito viene fornito un semplice pseudocodice dell'algoritmo utilizzato per le simulazioni:

1. Impostare i parametri della domanda e di apprendimento; Inizializzare le Q-functions;
2. Inizializzare randomicamente i valori  $\{p_t^1, p_t^2\}$  per  $t=\{1,2\}$ ;
3. Inizializzare  $t=3, i=1$  e  $j=2$ ;
4. Per ogni periodo:
  - a. Aggiornare  $Q^i(p_{t-2}^i, p_{t-2}^j)$  secondo l'equazione (5)
  - b. Impostare  $p_t^i$  secondo l'equazione (6) e impostare  $p_t^j = p_{t-1}^j$
  - c. Aggiornare  $t \leftarrow t+1$  e  $\{i \leftarrow j, j \leftarrow i\}$
5. Fintanto che  $t=T$  (numeri di periodi specificato)

### Considerazioni

Quando un singolo agente Q-learning deve affrontare un concorrente a strategia fissa, è garantito che converga alla strategia ottimale, date le condizioni moderate sul parametro  $\alpha$  e il tasso di esplorazione  $\epsilon_t$  (Watkins e Dayan, 1992; Tsitsiklis, 1994). L'algoritmo sequenziale Q-learning che abbiamo sviluppato potrebbe quindi convergere alla strategia ottimale se l'avversario mantiene una strategia fissa.

Tuttavia, l'algoritmo Q-learning potrebbe non convergere verso un comportamento ottimale nel nostro ambiente, poiché rimane vulnerabile all'adattamento e alla sperimentazione del suo avversario. Più in generale, gli agenti che si adattano simultaneamente al comportamento degli altri affrontano un problema di apprendimento dinamico (Busoniu, Babuska e De Schutter, 2008; Tuyls e Weiss, 2012), in cui la loro migliore risposta cambia mentre gli altri cambiano le proprie strategie. La convergenza garantisce che gli algoritmi di apprendimento del rinforzo per singolo agente non siano più validi.

Inoltre, il Q-learning si limita a giocare strategie pure, ma il MPE identificato da Maskin e Tirole richiede strategie miste che possono essere o fuori equilibrio (nel caso del prezzo focale) o lungo il percorso dell'equilibrio (nel caso dei cicli di prezzo di Edgeworth). Mentre non è in grado di apprendere nessuno degli equilibri perfetti del sottogioco mentre gli equilibri imperfetti di Nash del sottogioco rimangono fattibili. Significa solo che la teoria non è in grado di dire quanto dovrebbe comportarsi bene. In assenza di garanzie teoriche forniamo una comprensione empirica attraverso simulazioni.

### La simulazione

Per poter valutare le prestazioni dell'algoritmo, osserviamo quanto questo sia redditizio e quanto sia ottimale rispetto al comportamento ottenibile con la migliore risposta.

#### Redditività

I valori nella matrice Q sono stime di profitti futuri scontati quando si imposta il prezzo  $p_i$  dato il prezzo attuale della concorrenza  $p_j$ . Mentre i valori inizialmente risultano essere molto imprecisi, i profitti futuri attesi stimati ed effettivi convergono se convergono i valori Q. Pertanto, possiamo semplicemente prendere i valori Q osservati per acquisire il grado di redditività:

$$\text{Redditività } Q_t^i(p_{t-1}^i, p_t^j) \approx \sum_{s=0}^{+\infty} \delta^s \pi(p_{t+s}^i, p_{t+s}^j) \quad (14)$$

Dove  $p_t^i = R^i(p_{t-1}^i)$  e  $p_t^j = R^j(p_{t-1}^j)$  quando l'impresa  $i$  o l'impresa  $j$  regolano il loro prezzo, con  $R^i$  e  $R^j$  le funzioni di reazione dinamica basate sull'equazione (8) nel modulo di selezione dell'azione. Nella simulazione, confrontiamo questa redditività con il valore attuale netto di tutti i profitti futuri nell'ambito della massimizzazione del profitto congiunto e in base a un benchmark competitivo.

Il benchmark di massimizzazione del profitto congiunto è derivato in modo semplice nel nostro caso prendendo il prezzo di monopolio  $p^C = 0,5$ , fornendo a ciascuno di essi un profitto per periodo di  $\pi^i = 0,125$  e un valore attuale netto di tutti i profitti futuri di  $0,125/(1-\delta)$ . Un benchmark competitivo è tuttavia meno semplice. Un candidato ovvio può sembrare il risultato statico di Nash di prezzi pari al costo marginale (o un incremento sopra). Tuttavia, l'ambiente sequenziale rende la determinazione del prezzo a (o un incremento superiore) il costo marginale non ottimale per la sottopartita: se una qualsiasi azienda si discosta e addebita prezzi più alti, anche l'altra impresa starebbe meglio deviando dai prezzi bassi. Mentre il costo marginale è ancora un punto di riferimento interessante a fini pratici, prendiamo il punto di riferimento competitivo più conservativo che si avvicina al ciclo di prezzi Edgeworth più competitivo identificato da Maskin e Tirole (1988): le imprese riducono progressivamente i prezzi fino a raggiungere il limite inferiore, dopo il quale un'impresa ripristina i prezzi a un incremento superiore al prezzo di monopolio e il ciclo riparte. Si presume che la prima impresa che osserva il prezzo più basso reimposti il ciclo dei prezzi.

### Ottimalità

Un risultato è un equilibrio di Nash se e solo se entrambe le imprese si comportano in modo ottimale, nel senso che nessuna impresa può adottare una strategia migliore data la strategia dell'altra impresa. Per catturare questo grado di ottimalità, definiamo  $\Gamma_t^i$  come il rapporto tra profitti futuri stimati e scontati con la migliore risposta:

$$\Gamma_t^i = \frac{Q_t^i(p_t^i, p_t^j)}{\max_p Q_t^{i*}(p, p_t^j)}$$

Dove  $Q_t^{i*}$  è la Q-function ottimale data la strategia corrente del competitor nel periodo t.  $Q_t^{i*}$  non è osservata dall'algoritmo. Tuttavia, poiché controlliamo la simulazione, possiamo derivarla utilizzando la programmazione dinamica: mantenendo fissa la funzione Q del concorrente, eseguiamo il loop su tutte le coppie azione-stato fino a quando l'equazione (7) converge.  $\Gamma_t^i$  ha la seguente interpretazione: mostra quanto gli utili futuri attesi stimati sono inferiori rispetto agli utili futuri nella migliore risposta.

Quando l'algoritmo apprende una strategia di miglior risposta, produce quindi  $\Gamma_t^i = 1$ . Un risultato è un equilibrio di Nash se e solo se  $\Gamma_t^i = 1$  vale per entrambi gli algoritmi.

Si noti che  $\Gamma_t^i$  non tiene conto solo del comportamento della miglior risposta nel periodo successivo, ma anche del possibile sfruttamento fuori equilibrio del suo concorrente in stati che altrimenti non sarebbero mai visitati. Affinché  $\Gamma_t^i$  sia affidabile, il parametro  $\alpha$  o il tasso di esplorazione  $\epsilon_t$  devono diminuire sufficientemente. Ciò consente a  $Q^i$  di convergere e diventare una stima affidabile degli utili futuri reali.

### Simulazione

Nel nostro modello abbiamo realizzato una rete prototipale che implementa il meccanismo di Q-learning semplificato. Purtroppo la sua applicazione ai dati reali, seppure teoricamente possibile, non è stata possibile per la mancanza di un numero sufficiente di campioni in grado di garantire la convergenza. Occorre aspettare di avere un numero molto più elevato di situazioni da cui inferire la migliore strategia possibile per determinare il prezzo che gli investimenti ottimali nella pubblicità. Tuttavia per verificare, almeno in linea teorica, la bontà del modello abbiamo avviato alcune simulazioni descritte nel seguito.

Per l'esercizio di simulazione, esaminiamo gli intervalli di prezzo  $k = \{6, 12, 24\}$ , dove  $k = 6$  è l'esempio illustrativo in Maskin e Tirole (1988) e l'intervallo di prezzo più basso in cui esistono sia l'MPE a prezzo fisso sia il ciclo di prezzi. Per valutare la distribuzione delle prestazioni, simuliamo per ogni intervallo di prezzo 1000 iterazioni. Nella nostra simulazione di base, il parametro stepsize  $\alpha = 0,3$  e il fattore di sconto  $\delta = 0,95$  sono stati impostati in modo arbitrario. Ogni serie dura  $T = 1000(k + 1)^2$  periodi, che è 1000 volte la dimensione della matrice Q. La probabilità di esplorazione  $\epsilon_t = (1 - \theta)^t$ , dove  $\theta$  è impostata tale che la probabilità di esplorazione diminuisca gradualmente dal 100% allo 0,1% a metà corsa, raggiungendo lo

0,0001% alla fine per consentire la convergenza. Infine, i valori Q vengono inizializzati tutti a zero (i risultati non sono sensibili all'inizializzazione). Consideriamo quindi il caso in cui l' algoritmo Q-learning affronta una strategia tit-for-tat di base in cui l'avversario imposta il prezzo di monopolio se lo fa anche il Q-learning, ma in caso contrario lo riduce.

Simulando un concorrente a strategia fissa occorre definire chiaramente le regole che abbiamo implementato per questo algoritmo. Il concorrente a strategia fissa si comporta quindi nel modo seguente: imposta il prezzo di massimizzazione del profitto congiunto se il Q-discente ha un prezzo uguale o superiore a tale prezzo, ma lo riduce di 1 altrimenti.

La figura 1 mostra i risultati per  $k = 6$ . Da questa possiamo vedere che Q-learning (impresa 1) impara rapidamente ad aderire alla strategia di massimizzazione del profitto congiunto, con  $Q^i$  della redditività finale che converge al livello di massimizzazione del profitto congiunto per entrambe le aziende in tutte le fasi. Impara anche a comportarsi in modo ottimale, con  $\Gamma^1 = 1$  in tutte le sessioni.

Questo risultato non è tuttavia un equilibrio. Questo perché l' algoritmo Q-learning non apprende la strategia di punizione fuori equilibrio necessaria per consentire al concorrente con strategia fissa di comportarsi in modo ottimale. Siccome il Q-learning mantiene la strategia finale fissa possiamo notare che il competitore a strategia fissa ha un'ottimalità media finale pari a  $\Gamma^2 \approx 0,75$ . Strategie fisse alternative possono tuttavia garantire che l' algoritmo Q-learning apprenda una strategia di punizione stabilizzante.

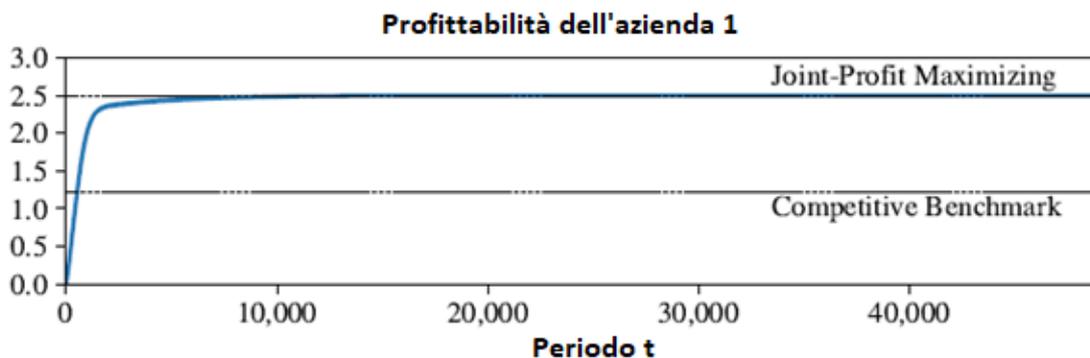


Figura 41 Profittabilità Azienda 1 (Q-Learning)<sup>42</sup>

## Conclusioni

È ormai dimostrato in moltissimi lavori scientifici che nel gioco della persuasione basata sugli attributi nella pubblicità esiste una strategia pubblicitaria ottimale in grado di stabilire i valori di pubblicità e prezzo in grado di ottimizzare i profitti in un gioco competitivo a più fasi. In questo studio abbiamo provato a capire come derivare questi valori utilizzando una metodologia innovativa derivata dall'Intelligenza Artificiale.

Vi è una crescente preoccupazione che algoritmi di determinazione dei prezzi sempre più sofisticati possano ad un certo punto, inevitabilmente, essere in grado di imparare a evitare pressioni concorrenziali e ottenere profitti più elevati a spese dei consumatori. Tuttavia, questa preoccupazione si basa spesso su un'interpretazione libera e intuitiva dell'intelligenza artificiale.

Tuttavia anche nel nostro semplificato modello di duopolio basato sulla concorrenza a fasi successive, possiamo vedere che gli algoritmi di Q-learning possono apprendere strategie che permettono di ottimizzare le scelte di investimento. Questo ci permette di spostare il focus degli studi dalla formalizzazione di un modello matematico statico verso la raccolta di dati da un lato e verso l'individuazione di algoritmi di machine learning sempre più sofisticati. Se il numero di prezzi discreti aumenta, il Q-learning converge sempre più in

<sup>42</sup>  $Q_t^1$  nel tempo calcolato come media di tutte le iterazioni contro un concorrente a strategia fissa e  $k=6$

cicli di prezzi asimmetrici redditizi. Oggi esistono modelli di rete neurale che permettono una modellizzazione più immediata in grado di fornire una previsione sui parametri ottimali anche nel nostro modello di duopolio. Abbiamo voluto investigare il campo del reinforcement learning, seppure molto più complesso e “affamato” di dati per verificare la possibilità della creazione di una strategia derivata dal comportamento del competitor.

Seppure i pochi dati a disposizione non ci permettono una risposta definitiva siamo convinti che, con adeguata potenza di calcolo e un numero sufficiente di dati il Q-learning potrà sia suggerire le migliori strategie ma anche identificare comportamenti collusivi. Ciò può fornire agli accademici la base per migliorare la comprensione dei mercati e alle autorità di poter meglio sorvegliare fenomeni anomali sia per comportamenti collusivi che per la formazioni di prezzi sospetti.







## Bibliography

- Allianz SE. (2017). "The Future of Work: Harry und Allie."
- ARAG. (2019). "ARAG Reiseassistent – Chatbot jetzt ausprobieren." (<https://www.arag.de/reiseassistent/>)
- Sanjeev Arora, Mikhail Khodak, Andrej Risteski, Christiane Fellbaum. Extending and Improving Wordnet via Unsupervised Word Embeddings
- Gary S. Becker and Kevin M. Murphy. A simple theory of advertising as a good or bad. *The Quarterly Journal of Economics*, 108(4):941–964, November 1993.
- Bengio Y., Ducharme R., Vincent P., Jauvin C., A Neural Probabilistic Language Model, *Journal of Machine Learning Research* 3 (2003) 1137–1155
- Branchenkompass Insurance. 2017. Versicherer wollen raus aus dem Stimmungstief – Befragung von 85 Vorstandsmitgliedern und Führungskräften aus deutschen Versicherungsunternehmen: F.A.Z.-Institut für Management-, Markt und Medieninformationen GmbH.
- Sarah Bankins & Paul Formosa (2019) When AI meets PC: exploring the implications of workplace social robots and a human-robot psychological contract, *European Journal of Work and Organizational Psychology*.
- Cuturi M., Blondel Mathieu, 2017, Soft-DTW: a Differentiable Loss Function for Time-Series, *Proceedings of the 34 th International Conference on Machine Learning*, Sydney, Australia, PMLR 70, 2017.
- Barrett, M., Davidson, E., Prabhu, J., and Vargo, S. L. 2015. "Service Innovation in the Digital Age: Key Contributions and Future Directions." *MIS Quarterly*, (39:1), pp. 135-154.
- Bertin, M., Atanassova, I., Larivire, V., Gingras, Y.: The invariant distribution of references in scientific papers. *Journal of the Association for Information Science and Technology* 67(1), 164177 (January 2016)
- Caplin, Andrew, and Mark Dean. Behavioral implications of rational inattention with shannon entropy. No. w19318. National Bureau of Economic Research, 2013
- William S. Comanor and Thomas A. Wilson. Advertising and market power, volume 144. Harvard University Press, 1974.
- William S. Comanor and Thomas A. Wilson. The effect of advertising on competition: A survey. *Journal of Economic Literature*, 17(2):453–476, June 1979.
- E. Keogh. Exact indexing of dynamic time warping. In *Proceedings of the 28th international conference on Very Large Data Bases, VLDB '02*, pages 406–417, 2002.
- Russel Fazio, Martha Powell, and Carol Williams. The role of attitudes accessibility in the attitude-to-behavior process. *Journal of Consumer Research*, 16(3):280–288, December 1989.
- Fresneda, Jorge E., and David Gefen. "A semantic measure of online review helpfulness and the importance of message entropy." *Decision Support Systems* 125 (2019): 113117.
- Galassi, Lippi e Torrioni, Attention, please! A Critical Review of Neural Attention Models in Natural Language Processing, arxiv 2019
- Hartigan, J.A., Wong, M.A.: Algorithm as 136: A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)* 28(1), 100– 108 (1979)
- Liu, Xiaofeng, et al. "Increment entropy as a measure of complexity for time series." *Entropy* 18.1 (2016): 22.

- Nils Henrik von der Fehr and Kristin Stevik. Persuasive advertising and product differentiation. *Southern Economic Journal*, 65(1):113–126, July 1998.
- Irsoy, Ozan and Cardie, Claire. Deep Recursive Neural Networks for Compositionality in Language. *Advances in Neural Information Processing Systems*, 096—2104, 2014
- Nicholas Kaldor. The economic aspects of advertising. *The Review of Economic Studies*, 18(1):1–27, 1950.
- Richard E. Kihlstrom and Michael H. Riordan. Advertising as a signal. *Journal of Political Economy*, 92(3):427–450, June 1984.
- Koh, W. T. H., H. M. Leung. 1992. *Persuasive Advertising*. Department of Business Policy, National University of Singapore.
- Lucente, M. 2002. “Conversational Interfaces for e-Commerce Applications.” *Communications of the ACM* (43:9), pp. 59–61.
- Xavier Gabaix and David Laibson. *Shrouded attributes, consumer myopia, and information suppression in competitive markets*. *The Quarterly Journal of Economics*, 121(2):505–540, May 2006.
- Gene M. Grossman and Carl Shapiro. Informative advertising with differentiated products. *The Review of Economic Studies*, 51(1):63–81, January 1984.
- Maskin, E. and Tirole, J. (1988) “A Theory of Dynamic Oligopoly II: Price Competition, Kinked Demand Curves and Edgeworth Cycles”, *Econometrica*, 56(3), pp. 571-599
- Daniel McFadden. Econometric models for probabilistic choice among products. *The Journal of Business*, 53(3):S13–S29, July 1980.
- C. Myers, L. Rabiner, and A. Rosenberg, “Performance tradeoffs in dynamic time warping algorithms for isolated word recognition,” *Acoustics, Speech, and Signal Processing* [see also *IEEE Transactions on Signal Processing*], *IEEE Transactions on*, vol. 28, no. 6, pp. 623–635, 1980. [Online]. Available: [http://ieeexplore.ieee.org/xpls/abs\\_all.jsp?arnumber=1163491](http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1163491)
- Phillip Nelson. Advertising as information. *The Journal of Political Economy*, 82(4):729–754, July-August 1974.
- Niennattrakul, Vit & Srisai, Dararat & Ratanamahatana, Chotirat. (2012). Shape-based template matching for time series data. *Knowledge Based Systems - KBS*. 26. 10.1016/j.knosys.2011.04.015.
- Oracle Corporation. 2016. “Can Virtual Experiences Replace Reality? The Future Role for Humans in Delivering Customer Experience.”
- Richard M. Perloff. *The dynamics of persuasion: communication and attitudes in the 21st century*. Communication. Taylor & Francis, New York and London, 4th edition, 2010.
- Richard E. Petty and Duane T. Wegener. *The handbook of social psychology*, volume 1 and 2. McGraw-Hill, 5th edition, 1998.
- Roberts, M.E., Stewart, B.M., Airoidi, E.M.: A model of text for experimentation in the social sciences. *Journal of the American Statistical Association* 111(515), 988–1003 (2016)
- Ross, J. W., Sebastian, I. M., Beath, C., Mocker, M., Moloney, K. and Fonstad, N. 2016. “Designing and Executing Digital Strategies.” in *Proceedings of the 14th International Conference on Information Systems*.
- Sakoe, H. and Chiba, S., Dynamic programming algorithm optimization for spoken word recognition, *IEEE Transactions on Acoustics, Speech and Signal Processing*, 26(1) pp. 43– 49, 1978, ISSN 0096-3518

- Richard Schmalensee. Advertising and entry deterrence: An exploratory model. *Journal of Political Economy*, 91(4):636–653, August 1983.
- Salton, G. & Buckley, C. (1988). Term-weighting approaches in automatic text retrieval. In *Information Processing & Management*, 24(5): 513-523.
- Schuelke-Leech, B. A. 2018. "" Technological Forecasting and Social Change (129), pp. 261–274.
- Shabariram, C. P., Srinath, V., Indhuja, C. S. and Vidhya, M. 2017. "Ratatta: Chatbot Application Using Expert System." *International Journal of Advanced Research* (7:3), pp. 8–14.
- Shawar, A. and Atwell, E. 2005. "A Chatbot System as a Tool to Animate a Corpus." *ICAME Journal: International Computer Archive of Modern and Medieval English Journal* (29), pp. 5–24.
- M. Syamala and N. J. Nalini, "LDA and Deep Learning: A Combined Approach for Feature Extraction and Sentiment Analysis," 2019 10th International Conference on Computing, Communication and Networking Technologies (ICCCNT), Kanpur, India, 2019, pp. 1-5.
- Stergios Skaperdas and Samarth Vaidya. Persuasion as a contest. *Economic Theory*, Symposium:1–22, September 2009.
- Tesauro, G. and Kephart, J.O. (2002) "Pricing in Agent Economics Using Multi-Agent Q-Learning", *Autonomous Agents and Multi-Agent Systems*, 5, pp. 289-304
- Tsitsiklis, J.N. (1994) Asynchronous Stochastic Approximation and Q-Learning, *Machine Learning*, 16(3), pp. 185-202
- Tuyls, K. Weiss, G. (2012) \Multiagent Learning: Basics, Challenges, and Prospects", *AI Magazine*, 33(3), pp. 41-52
- Vodafone Tobi 2019, <https://www.vodafone.it/portal/Privati/Vantaggi-Vodafone/Applicazioni/TOBi>
- Walkowiak T. Gniewkowski, M., Evaluation of vector embedding models in clustering of text documents, *Proceedings of the International Conference on Recent Advances in Natural Language Processing (RANLP 2019)*, 2019, 1304--1311,
- Watkins, C.J.C.H. and Dayan, P. (1992) "Q-Learning", *Machine Learning*, 8(3), pp. 279-292
- John Wieting, Mohit Bansal, Kevin Gimpel, Karen Livescu: Charagram: Embedding Words and Sentences via Character n-grams. *CoRR abs/1607.02789* (2016)
- Willcocks, L. and Lacity, M. (2016), *Service Automation: Robots and the Future of Work*, Steve Brooks Publishing, UK, forthcoming.
- Winkler, R., & Soellner, M. 2018. "Unleashing the Potential of Chatbots in Education: A State-Of-The-Art Analysis." In *Academy of Management Proceedings*, pp. 1–40.
- Liu, Xiaofeng, et al. "Increment entropy as a measure of complexity for time series." *Entropy* 18.1 (2016): 22.