



**UNIVERSITÀ DEGLI STUDI DI PADOVA**

**DIPARTIMENTO DI FILOSOFIA, SOCIOLOGIA, PEDAGOGIA E  
PSICOLOGIA APPLICATA**

**Corso di laurea magistrale in  
Psicologia Clinico Dinamica**

**Tesi di laurea magistrale**

**SENTIMENT ANALYSIS E REAZIONE NEI SOCIAL NETWORK: STUDIO  
ESPLORATIVO DEI TWEET SULLE PROTESTE DI TRIESTE**

**Sentiment Analysis and reactions in social networks: exploratory study of tweets on the  
Trieste protests**

***Relatore:***

Prof. Paolo Francesco Cottone

***Laureando:***

Alessandro Candiracci

***Matricola:***

1206669

Anno Accademico 2021/2022

# Indice

Indice	1
Introduzione	3
Capitolo 1: Social media e sentiment analysis	5
Capitolo 1.1: Propagazione delle informazioni	5
Capitolo 1.2: Machine Learning	9
Capitolo 1.3: Sentiment Analysis	12
Capitolo 2: Metodo	19
Capitolo 2.1: Data Mining	19
Capitolo 2.2: Elaborazione Testuale	20
Capitolo 2.3: BERT	22
Capitolo 2.4: Sentiment Analysis	25
Capitolo 3: Risultati	27
Capitolo 4: Discussioni	35
Conclusioni	39
Bibliografia	41



## Introduzione

Negli ultimi anni è aumentato l'utilizzo dei social network, come Twitter e Facebook, per condividere opinioni e idee sui fatti di cronaca. Nell'ottobre del 2021, una parte del dibattito nei social si è concentrata e infiammata sulle vicende di Trieste, spaccando l'opinione pubblica. In quel periodo il capoluogo del Friuli-Venezia-Giulia era diventato il simbolo della resistenza contro le nuove misure introdotte dal green pass, che prevedevano l'obbligo di presentare il certificato anche sul luogo di lavoro. La mattina del 15 ottobre i portuali di Trieste, guidati dal portavoce Stefano Puzzer, presidiano il porto della città insieme a migliaia di persone che si uniscono alla protesta. La posizione dei manifestanti è inflessibile: "L'unica apertura che possono avere nei nostri confronti è togliere il Green pass" dichiara Puzzer alla stampa. Anche dopo la proposta da parte delle autorità triestine di pagare i tamponi necessari ai lavoratori per poter continuare a lavorare, le proteste continuano giorno dopo giorno. Sui social vengono pubblicati messaggi di supporto per i manifestanti: "Trieste chiama, Ancona risponde" è un esempio. Anche da Padova, Genova, Parma e molte altre città parte lo slogan di incoraggiamento. Il 17 ottobre, Puzzer decide di dimettersi dal ruolo di vicepresidente del Coordinamento dei Lavoratori Portuali di Trieste (CLPT) e dichiara che, nonostante le sue dimissioni, le proteste continueranno fino al 20 ottobre. Dal punto di vista mediatico, le acque si calmano anche se i malumori nella città sono ancora forti e le proteste vanno avanti senza sosta. Nel frattempo, il numero di contagi a Trieste sale esponenzialmente facendo crescere la preoccupazione della giunta comunale. A riaccendere il dibattito è la decisione del sindaco Dipiazza: il primo novembre vengono vietate le proteste in piazza Unità a causa dell'aumento dei contagi. Inoltre, la mattina del 2 novembre, Puzzer si presenta a sorpresa in piazza del Popolo con un tavolo, con un cartello che cita "Papa", e quattro sedie con altrettanti fogli che indicano "Mario Draghi", "Comunità Europea", "Usa" e "Russia". La voce si diffonde sui social e cominciano ad affluire nella piazza persone pronte a protestare insieme all'ex vicepresidente del CLPT. A causa di questa iniziativa, il questore di Roma emetterà il Daspo nei confronti di Stefano Puzzer.

Con questa premessa, il presente lavoro ha come scopo quello di studiare i tweet riguardanti le vicende di Trieste, pubblicati tra il 29 ottobre 2021 e il 4 novembre 2021. Nella prima parte si presenterà una rassegna degli studi che hanno indagato come possono diffondersi le informazioni nei social media e gli elementi chiave per comprendere le dinamiche nel comportamento di condivisione degli utenti. Inoltre, verranno presentate le tecniche impiegate per effettuare le analisi sui dati ricavati in questo studio. Nella seconda parte verrà illustrato il metodo con cui sono stati estratti i tweet e le procedure di elaborazione e categorizzazione del testo. Infine, verranno presentati e discussi i risultati emersi dallo studio, effettuando un confronto rispetto con la letteratura esistente.

# Capitolo 1: Social media e sentiment analysis

## 1.1 Propagazione delle informazioni nei social media

Nel 2020, il 36.5% delle persone ha dichiarato che una delle principali motivazioni per cui utilizza i social media è quella di informarsi sugli eventi che ogni giorno accadono nel mondo<sup>1</sup>. Comprendere i fattori chiave che influenzano la propagazione di un certo tipo di informazioni piuttosto che di altri è fondamentale per capire quali contenuti hanno più probabilità di diventare virali. Quando le persone vengono in contatto con i post pubblicati dagli utenti di un social media, entrano in gioco diverse modalità di risposta emotiva, che possono spingere le persone a condividere ciò che hanno appena visto.

Per comprendere queste dinamiche, va considerato il ruolo che giocano gli utenti con un numero elevato di follower e che di conseguenza beneficiano di una maggiore visibilità. Questa tipologia di utenti viene definita come utenti influenti, dove con influenza si intende "la capacità di provocare potenziali comportamenti degli altri e di diffondere efficacemente le informazioni" (Jianqiang et al. 2017). In linea generale, essi sono molto attivi nei social network e contribuiscono alla propagazione di informazioni cercando di pubblicare post accattivanti per massimizzare il numero di repost. Inoltre, è più probabile che i post di questi utenti vengano condivisi (Remy et al. 2013) e, il numero di follower, influisce positivamente sulla scala di propagazione dei contenuti (Burnap et al. 2014). Aggiornare attivamente il proprio profilo mantiene l'attenzione del pubblico, il coinvolgimento dei propri follower e la credibilità delle informazioni che vengono condivise (Hu et al. 2019). Grazie alla fiducia di cui godono, gli utenti influenti possono influenzare e indurre altri a condividere o commentare i propri contenuti (Xu et al. 2018). Per quanto riguarda la tonalità emotiva dei messaggi condivisi, essi tendono ad esprimere opinioni caratterizzate da negatività, con la prevalenza di emozioni come rabbia, paura, disgusto e tristezza (Kanavos et al. 2018). Questo tipo di dato è confermato anche dallo studio condotto da Chung e Zeng (2018) i

---

<sup>1</sup> <https://datareportal.com/reports/digital-2021-global-overview-report>

cui risultati mostrano che gli utenti i cui tweet siano caratterizzati da emozioni di rabbia e paura tendano a guadagnare più popolarità e visibilità.

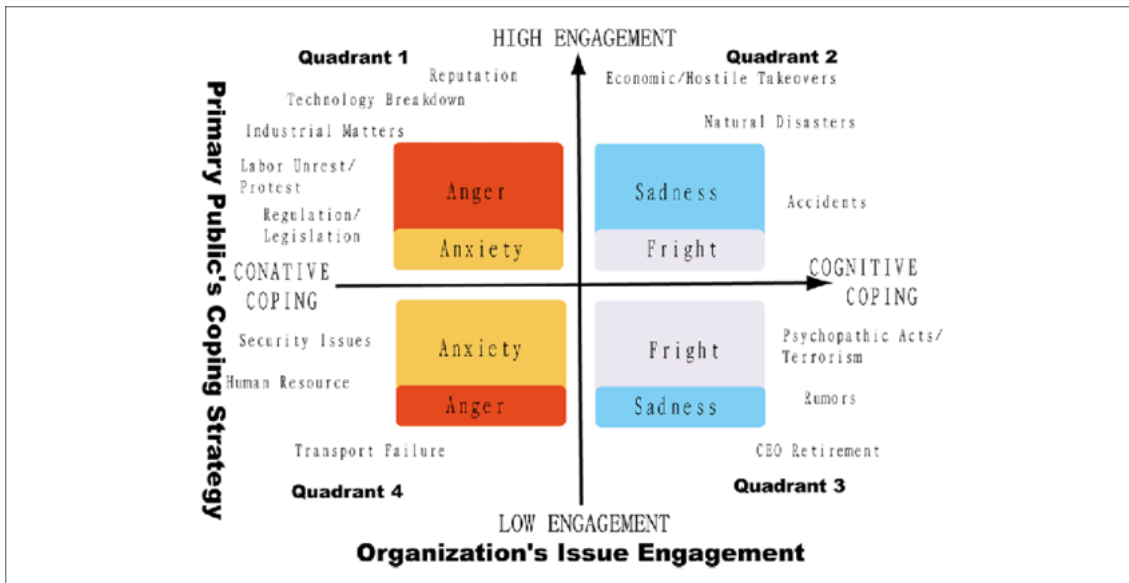
In seconda istanza, è necessario analizzare il ruolo dei fattori emotivi, come il sentimento trasmesso dal post (positivo o negativo), e come essi incidono sulla probabilità che un messaggio venga condiviso. Nel caso delle news, per esempio, sono i contenuti più negativi ad ottenere più visibilità (Wu e Shen 2015, Fan et al. 2014) mentre, per quanto riguarda i consigli pratici, è più probabile che siano i post con maggior positività ad avere la meglio su quelli negativi (Berger e Milkman, 2012). In generale, i post con parole che esprimono più emotività tendono a diventare più virali di quelli con parole meno emotive (Lee e Hong 2016). I contenuti caratterizzati da emozioni positive tendono a diventare virali perché vengono condivisi principalmente per dare una certa presentazione di se stessi oppure per affermare il proprio status sociale, con l'intento di mostrare un'immagine positiva agli altri (Berger e Milkman 2012). Invece, riguardo la viralità dei contenuti negativi, essa può essere spiegata grazie alla teoria del bias di negatività, che suggerisce come le persone tendano a prestare più attenzione alle informazioni che sono caratterizzate da emozioni negative rispetto alle informazioni caratterizzate da emozioni positive (Vaish et al. 2008). Anche se online le parole positive sono utilizzate più frequentemente rispetto alle parole negative, queste ultime vengono percepite come più peculiari e originali (Hornik et al. 2015).

Un altro aspetto da considerare è quello che riguarda il livello di attivazione che le emozioni possono provocare in un individuo e come questo possa influenzare i processi di elaborazione cognitiva. Secondo la teoria dell'attivazione, le emozioni come rabbia e ansia sono caratterizzate da una maggiore eccitazione, mentre emozioni come la tristezza sono caratterizzate da una bassa eccitazione o deattivazione (Barrett e Russell 1998). Inoltre, secondo il modello funzionale cognitivo (CFM) di Nabi (2003), la rabbia porta ad una elaborazione euristica e più approfondita delle informazioni. Ansia e paura, al contrario, possono spingere le persone ad evitare i pericoli, percepiti come potenzialmente dannosi e di conseguenza elaborare in maniera più superficiale le informazioni. Pertanto, il livello di attivazione provato può riflettersi nel

comportamento di condivisione degli utenti dei social media (Li et al., 2017). Per esempio, provare tristezza influisce negativamente sul comportamento di condivisione delle informazioni, mentre è più probabile che le persone condividano informazioni sulla crisi quando provano emozioni ad alta attivazione (R. Chen, 2014). In maniera analoga, i contenuti che evocano emozioni attivanti hanno una maggiore probabilità di diventare virali (Berger e Milkman 2012).

In una situazione di emergenza, le persone tendono a condividere informazioni frequentemente per far fronte all'instabilità causata dai cambiamenti (Oh et al. 2010). Tra i tentativi di identificare le emozioni esperite dalle persone coinvolte in eventi caratterizzati da incertezza, Jin et al. (2007) propongono il modello di mappatura integrata delle crisi (ICM). Tale modello cerca di descrivere le emozioni provate dal pubblico, in base alle strategie di coping messe in atto da esso e dal grado di coinvolgimento delle organizzazioni (Jin et al. 2007). Con pubblico, gli autori intendono i gruppi di persone che rispondono alle seguenti caratteristiche: sono i più colpiti dalla crisi, hanno interessi comuni e possiedono un'influenza a lungo termine sulla reputazione e sul funzionamento dell'organizzazione coinvolta (Figura 1.1). L'asse delle ascisse ha come estremi il conative coping e il cognitive coping. Il primo concerne le misure che vengono adottate dalle persone per cercare di cambiare la situazione, il secondo quelle utilizzate per cercare di cambiare l'interpretazione di ciò che sta accadendo. L'asse delle ordinate invece fa riferimento al livello di coinvolgimento delle istituzioni e va da un elevato impegno organizzativo, con priorità data all'allocazione delle risorse per affrontare la crisi, e un basso impegno organizzativo, in cui l'istituzione dedica relativamente meno risorse, sforzi ed energie per affrontare l'emergenza. I due assi formano i quattro quadranti del modello e in ciascuno di essi sono contenute le emozioni dominanti che possono essere causate dall'interazione tra le strategie di coping e il livello di gestione della crisi:





*Figura 1.1 Modello ICM Jun et al. 2007*

Quadrante 1: coinvolgimento elevato e conative coping. La rabbia aumenta quando il pubblico ritiene responsabile l'organizzazione. Inoltre le persone possono sentirsi ansiose quando ritengono che l'organizzazione non stia facendo abbastanza. La strategia del pubblico è guidata dalla tendenza all'azione, dalla sensazione che si possa e si debba fare qualcosa per la situazione.

Quadrante 2: coinvolgimento elevato e cognitive coping. L'emozione primaria è la tristezza, mentre quella secondaria è la paura. Sono crisi in cui il pubblico non ha possibilità d'azione e può contare esclusivamente sull'intervento delle organizzazioni.

Quadrante 3: basso coinvolgimento e cognitive coping. Il pubblico si rende conto che non è possibile fare nulla per risolvere l'emergenza e che le istituzioni non stanno agendo o non stanno allocando risorse sufficienti per gestirla. La tristezza domina rispetto alla paura a causa della situazione disperata.

Quadrante 4: basso coinvolgimento e conative coping. L'ansia è causata dalla percezione del basso coinvolgimento e della possibile inerzia dell'organizzazione. A primo impatto, il pubblico può sentirsi ansioso perché sente che l'organizzazione non sta facendo abbastanza. Con il tempo l'ansia può trasformarsi in rabbia, che spinge il pubblico a prendere in mano la situazione. Il modello è stato successivamente testato

prendendo in esame quattordici casi di emergenza avvenuti negli Stati Uniti. In seguito ad un'analisi dei commenti del pubblico e delle dichiarazioni delle organizzazioni in merito alle situazioni prese in esame, gli autori hanno revisionato l'ipotesi originale definendo una nuova configurazione sulla base dei dati raccolti. (Figura 2.2)

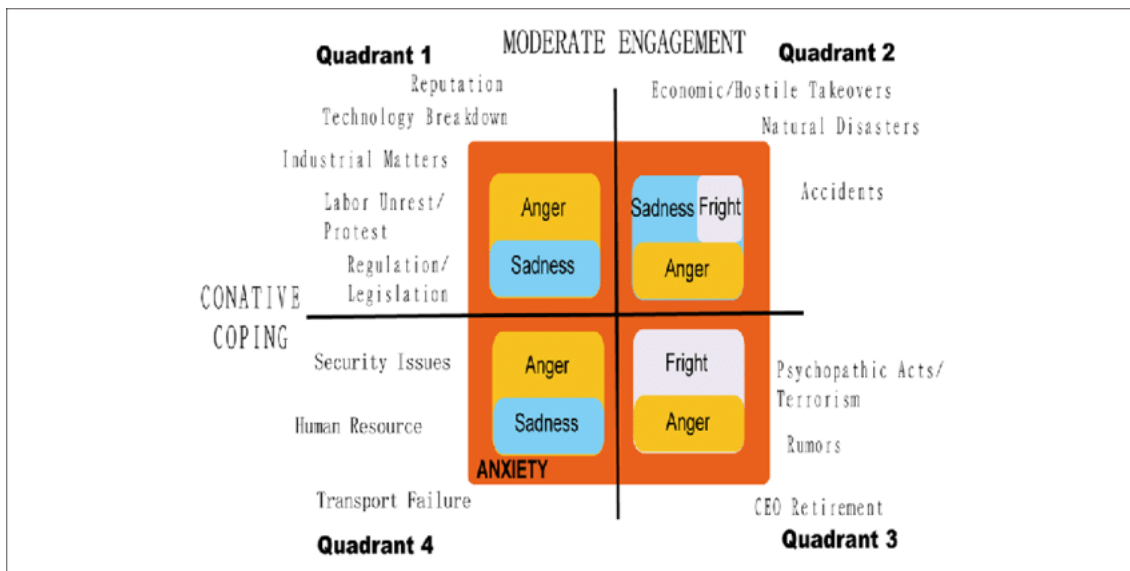


Figura 2.2 Modello ICM revisionato Jun et al. 2012


## 1.2 Machine Learning

Il Machine Learning è il campo di studi che si occupa di creare sistemi informatici che apprendono e migliorano le proprie performance in maniera autonoma, sulla base dell'esperienza e dei dati che vengono utilizzati. Nasce come branca dell'Intelligenza Artificiale ma esiste un'importante differenza tra le due: l'intelligenza artificiale implica un agente che esegua interazioni con l'ambiente al fine di raggiungere determinati obiettivi, mentre un'applicazione Machine Learning nasce con lo scopo di eseguire previsioni su osservazioni ottenute in maniera passiva e successivamente generalizzarle su dati mai visti prima (Alpaydin 2010). Tradizionalmente, gli approcci al Machine Learning vengono divisi in tre categorie:

- Apprendimento supervisionato: consiste nell'ottimizzazione di un modello matematico che ha l'obiettivo di associare delle informazioni fornite come input ad un determinato output nella maniera più precisa possibile. A seconda del tipo di risultato è possibile distinguere gli algoritmi di regressione, che restituiscono un valore compreso in un determinato intervallo, e di classificazione, che invece sono limitati ad un insieme finito di valori.
- Apprendimento non-supervisionato: consiste nel cercare delle somiglianze o delle discrepanze in un dataset non classificato. L'obiettivo dell'algoritmo è ricavare una struttura nei dati, identificando le caratteristiche in comune tra le informazioni ricevute e regolandosi in base alla presenza o assenza di tali punti in ogni nuovo input analizzato.
- Apprendimento rinforzato: consiste nello sviluppo di un algoritmo che sia in grado di intraprendere azioni in un ambiente. Ogni volta che questo raggiunge un determinato obiettivo viene "ricompensato" e lo scopo del *training* è quello di massimizzare le ricompense ricevute.

Nella scorsa decade, grazie ai progressi nello sviluppo di algoritmi Machine Learning e all'introduzione dell'elaborazione tramite GPU (Graphic Processing Unit), è stato possibile l'impiego su vasta scala di modelli che utilizzano tecniche di deep learning (Hinton et al. 2011). Il Deep Learning è un sottocampo del Machine Learning che ha l'obiettivo di raggiungere un apprendimento automatico avanzato (Schmidhuber 2015) utilizzando le artificial neural network (ANN), sistemi computazionali che si ispirano al funzionamento del cervello. L'apprendimento si basa su un processo bottom-up in cui i concetti più complessi vengono compresi a partire dai concetti più semplici e ciò "consente a modelli computazionali composti da più livelli di elaborazione di apprendere rappresentazioni di dati con più livelli di astrazione" (LeCun et al. 2015). Un'architettura basata su tecniche di Deep Learning è costituita da un insieme di unità interconnesse chiamate neuroni artificiali, pensate per agire come i neuroni biologici. Esse comunicano tramite delle connessioni che, simulando il funzionamento delle sinapsi, trasferiscono le informazioni da un neurone all'altro. Nello specifico, ogni neurone ha il compito di ricevere un segnale, elaborarlo applicando una

funzione non-lineare e inviare il risultato al neurone successivo (Figura 1.1). Con l'avanzare del processo di apprendimento il modello regola differentemente l'impatto dell'elaborazione di ciascun neurone basandosi sulla rilevanza che ognuno di essi possiede nella determinazione del risultato corretto. Una ANN progettata in questo modo prende il nome di Deep Neural Network (DNN).



*Figura 1.1 Esempio di un'architettura deep neural network<sup>2</sup>.*

In una rete DNN, il processo di apprendimento può essere di tipo supervisionato o non supervisionato e, generalmente, questa procedura si svolge seguendo un ordine stabilito:

1. Fase di pre-processing: i dati designati per l'apprendimento vengono trasformati e mappati in adeguate matrici numeriche così da poter essere forniti in input al modello. Nel caso di un apprendimento supervisionato, il dataset viene suddiviso negli insiemi di training e test. Per ogni istanza di questi dati è già presente la rispettiva etichetta di classificazione, indispensabile per il processo di training. Nel caso di un apprendimento non supervisionato i dati non hanno alcuna etichetta.

---

<sup>2</sup> <https://github.com/ashishpatel26/Tools-to-Design-or-Visualize-Architecture-of-Neural-Network>

2. Inizializzazione del modello: I parametri della rete DNN vengono inizializzati con valori generati casualmente oppure, tramite un processo di trasferimento, vengono importati da un altro modello.

3. Training: si ripartisce ulteriormente il set di training in batch, che possono essere di lunghezza variabile. Ogni dato di un batch viene fornito in ingresso al modello, che calcola una funzione che assegna al dato un punteggio. In seguito alla previsione effettuata viene calcolata una funzione di costo che valuta la differenza tra i valori predetti e quelli attesi. Sulla base del risultato di questa funzione il modello aggiorna progressivamente i propri parametri (backpropagation). Lo scopo della rete DNN è quello di minimizzare il valore della funzione di costo.

4. Test: Terminato il processo di training il modello viene testato sui dati che non sono stati utilizzati nella fase precedente. In quest'ultima fase vengono processati i dati di test e si eseguono le stime sulla qualità delle predizioni del modello.

Patel et al. (2020) definiscono tre parametri con cui è possibile valutare una rete DNN: la generalizzabilità, la trainability e l'espressività. La generalizzabilità è la precisione con cui la rete elabora risultati corretti sui dati non appartenenti al dataset di training; la trainability è la rapidità con cui la rete può essere addestrata; l'espressività, infine, consiste nella capacità della rete di stimare la propria performance.

### **1.3 Sentiment Analysis**

Le DNN hanno trovato applicazione in molti ambiti tra cui il natural language processing (NLP), disciplina in cui l'attenzione è rivolta all'interazione tra computer e linguaggio naturale, sia esso verbale o scritto (Choudhury 2003). Un dato testuale può essere affrontato in differenti modi in base alle informazioni che si vogliono estrarre e agli obiettivi di ricerca: Di cosa parla il testo? Come si può tradurre in un'altra lingua? Che emozioni trasmette? Come può essere riassunto? Per ogni compito NLP vengono usati approcci e algoritmi diversi al fine di raggiungere e migliorare la precisione dei risultati.

Dall'inizio del 2000, una delle aree di ricerca NLP che ha visto crescere la propria popolarità è la Sentiment Analysis (Messaoudi et al. 2022). Nota anche come opinion mining, la Sentiment Analysis è la disciplina che tramite l'elaborazione del linguaggio naturale, analisi del testo e linguistica computazionale identifica, estrae, quantifica e studia sistematicamente gli stati affettivi e le informazioni soggettive contenuti nelle produzioni linguistiche scritte e verbali (Liu 2012). Ad oggi, gli approcci esistenti possono essere classificati in due categorie principali: quelli basati sul Machine Learning e quelli che adottano altre tecniche di NLP (Messaoudi et al. 2022). Grazie alla diffusione di Internet e dei social media, questa materia ha guadagnato molta popolarità tra i ricercatori di diversi domini per la sua applicabilità in un'ampia gamma di campi come psicologia, linguistica, salute pubblica e gestione aziendale (Pang e Lee 2008). In generale, la sentiment analysis è studiata a tre livelli (Liu 2012):

- Document analysis: Il compito a questo livello è classificare se un intero documento di opinione esprime un sentimento positivo o negativo (Pang et al. 2002). Ad esempio, data una recensione di un prodotto, si determina se la recensione esprime un'opinione complessivamente positiva o negativa. Ciò presuppone che ogni documento esprima opinioni su una singola entità (es. un singolo telefono), pertanto non è applicabile ai documenti che valutano o confrontano più entità.
- Sentence analysis : il compito a questo livello si limita alle frasi e determina per ognuna di esse, se l'opinione espressa è positiva, negativa o neutra. Con neutra di solito si identifica una frase che non esprime nessuna opinione. A questo livello è strettamente correlata la classificazione della soggettività (Wiebe et al. 1999), la quale distingue le frasi oggettive, che esprimono informazioni fattuali dalle frasi soggettive, che esprimono opinioni e idee personali. La soggettività non è equivalente al sentimento poiché molte frasi oggettive possono avere delle opinioni implicite. Per esempio "Abbiamo comprato una Fiat Multipla il mese scorso e il tergitristallo è caduto" indica un fatto ma a livello implicito cela un sentimento negativo.

- Entity level e aspect level: è il livello più complesso di sentiment analysis. Invece di guardare i costrutti linguistici (documenti, paragrafi, frasi, clausole, ecc.), si considera direttamente l'opinione stessa. Si basa sull'idea che questa consista in un sentimento (positivo o negativo) diretto verso un obiettivo. Ad esempio, la frase "nonostante l'ultimo modello non sia granché, adoro ancora la Apple" ha complessivamente un tono positivo, ma ci sono delle sfumature negative che bisogna analizzare. Infatti l'opinione è positiva per il brand (Apple), ma negativa per il prodotto. In definitiva, l'obiettivo di questo livello di analisi è scoprire i sentimenti su determinate entità e/o su specifici aspetti della stessa. In questa prospettiva è possibile produrre una sintesi strutturata di opinioni sulle entità e può essere utilizzata per tutti i tipi di analisi qualitative e quantitative.

La maggior fonte di informazioni quando si parla di sentiment analysis deriva dalle "sentiment word" (Liu 2012). Queste sono parole che sono comunemente usate per esprimere sentimenti positivi o negativi come "buono", "meraviglioso", "sorprendente", "cattivo", "terribile", ecc... Inoltre vanno considerate nella loro interezza le frasi che veicolano un senso positivo o negativo come i modi dire (es. "liscio come l'olio"). Un elenco di tali parole e frasi è comunemente definito "sentiment lexicon" (vocabolario del sentimento) e, nel corso degli anni, i ricercatori hanno continuato a progettare algoritmi per creare vocabolari sempre più precisi e accurati. Un buon sentiment lexicon è necessario ma non sufficiente per la sentiment analysis dato che il linguaggio può presentare forme espressive articolate e ambivalenti che per un algoritmo sono difficili da decifrare:

- Una parola può indicare sentimenti opposti in diversi contesti. Per esempio la parola terribile ha una connotazione tipicamente negativa ma può anche essere usata in senso positivo tipo "questo antizanzare è terribile, uccide tutte le zanzare che si avvicinano". Il giudizio espresso nei confronti dell'antizanzare è positivo.

- Una frase contenente “sentiment word” può essere neutrale. Questo è il caso delle domande (interrogative) e delle frasi condizionali che non sempre contengono un'opinione. Ad esempio "Qualcuno può dirmi una buona bicicletta da comprare?" oppure "Se riuscirò a trovare una buona bicicletta, la comprerò". Entrambe le frasi contengono la parola "buono" (positiva) ma nessuna delle due esprime di fatto un'opinione.
- Le frasi sarcastiche con o senza “sentiment word” sono difficili da analizzare, ad esempio: “Che giornata fantastica! Ho perso il portafoglio con tutti i documenti”.
- Molte frasi pur non avendo “sentiment word” possono esprimere comunque un'opinione. La frase “la batteria del mio telefono dura due ore in tutto” implica un sentimento negativo nei confronti del telefono, che dura poco.

La grande quantità di dati testuali generata sui social network è una grande risorsa per la sentiment analysis e consente ai ricercatori di estrarre informazioni utili su attitudini, comportamenti e modelli decisionali degli utenti.

Gaspar et al. (2016) hanno analizzato il caso dello scoppio di un focolaio di *escherichia coli* (EHEC) in Germania nel 2011. Oltre al contenuto emotivo espresso nei tweet, gli autori hanno analizzato anche il contenuto dei messaggi cercando di identificare possibili strategie di coping adottate dagli utenti. I risultati mostrano che le espressioni negative vengono usate più spesso da utenti che percepiscono la situazione e gli eventi associati come una minaccia da affrontare. Questo tipo di elaborazione fa parte del processo adattivo che favorisce un approccio attivo nell'affrontare la situazione. Viceversa, espressioni positive, come scherzare, suggeriscono che la situazione non è percepita così seriamente come dovrebbe essere e possono indicare una mancanza di risorse per gestire la situazione o forme più passive di coping.

Loureiro e Alló (2020) hanno analizzato i tweet relativi ai cambiamenti climatici raccolti da Spagna e Regno Unito durante i primi sei mesi del 2019, al fine di scoprire le preoccupazioni più recenti su questo argomento e le relative politiche energetiche. I risultati mostrano che, in generale, le energie rinnovabili sono percepite come molto



positive in entrambi i paesi. Nello specifico, le conversazioni sul tema del cambiamento climatico sono meno negative nel Regno Unito rispetto alla Spagna, dove il sentimento più evocato è la paura.

Öztürk e Ayvaz (2018) hanno indagato le opinioni e i sentimenti dell'opinione pubblica nei confronti della crisi dei rifugiati siriani, utilizzando la sentiment analysis per analizzare i tweet in turco e inglese. I risultati mostrano che i tweet turchi sono leggermente più positivi nei confronti di siriani e rifugiati, anche se il sentimento generale rimane equamente distribuito quasi equamente tra le tre categorie considerate (positivo, neutrale, negativo). D'altra parte, i tweet inglesi sono caratterizzati in gran parte da sentimenti neutri e una percentuale maggiore di sentimenti negativi rispetto ai tweet turchi.

Lwowski et al. (2020) hanno integrato la sentiment analysis dei tweet con le coordinate geospaziali del luogo da cui essi venivano pubblicati creando un modello in grado di analizzare la stabilità emotiva di una città. Il calcolo della traiettoria delle emozioni permette di risalire ad un evento socialmente rilevante (per esempio una festività o una situazione di emergenza) che potrebbe far sì che le persone in una città diventino eccessivamente espressive nella sfera sociale di Twitter. Rilevando i picchi emotivi nei tweet, gli autori sono stati in grado di identificare correttamente dieci eventi su undici che si sono verificati durante il periodo di tempo preso in considerazione.

Uban et al. (2021) hanno presentato uno studio sul rilevamento automatico dei disturbi mentali basato su marcatori linguistici, mirato a individuare precursori di depressione, anoressia e autolesionismo. Partendo da 3 dataset costruiti con i messaggi raccolti da diversi gruppi di Reddit, gli autori hanno sviluppato un modello deep learning in grado di intercettare gli utenti che sono a rischio di sviluppare una determinata condizione patologica. Per effettuare le predizioni sono stati considerati diversi livelli linguistici dei messaggi pubblicati, tra cui il contenuto, lo stile di scrittura dell'utente, il tono e l'intensità delle emozioni trasmesse.

Su et al. (2020) hanno esaminato le differenze nelle caratteristiche emotive dei

post di Weibo in quattro fasi diverse della pandemia di COVID-19: il periodo iniziale, l'esplosione del focolaio, la fase di stabilizzazione, e il periodo di prevenzione e controllo. Sono state prese in considerazione 11 categorie di parole: paura, delusione, senso di colpa, nostalgia, rabbia, panico, benedizione, fede, amore, lode e sorpresa. I risultati mostrano che gli utenti della piattaforma hanno espresso più parole di paura, delusione, senso di colpa, rabbia nel periodo del focolaio rispetto al periodo iniziale. Inoltre, le persone hanno usato più parole nostalgiche nel periodo di prevenzione e controllo rispetto agli tre periodi. L'uso di parole positive è stato significativamente maggiore nei periodi successivi alla fase iniziale, fatto che suggerisce una maggiore coesione grupale con una crescente attenzione nei confronti delle misure di prevenzione.

In conclusione, la sentiment analysis è una tecnica molto versatile che può essere utilizzata per condurre analisi quantitative e qualitative. In questo studio, l'obiettivo è quello di esplorare le risposte pubblicate su Twitter riguardanti le proteste di Trieste estraendo le caratteristiche emotive dei tweet pubblicati dagli utenti e indagando il comportamento di condivisione delle informazioni.



## Capitolo 2: Metodo

### 2.1 Data Mining

I dati utilizzati in questo studio sono stati raccolti usando *tweepy*, una libreria di Python, che collegandosi all'API di Twitter consente il download di *tweet* in formato JSON. Oltre al testo sono incluse altre informazioni come il nome dell'autore, la data di creazione, il geotag, ecc... la lista completa dei parametri è disponibile nella sezione apposita della pagina dell'API.<sup>3</sup>

Esistono diverse tipologie di *tweet* che possono essere pubblicate sul Social Network. Per l'analisi sono stati considerati unicamente i *tweet* e i *retweet*. Il primo è un messaggio che può includere vari tipi di media come link, foto, video, ecc... mentre il secondo è la condivisione del contenuto scritto da un altro utente, in cui non viene fatto alcun tipo di aggiunta.

Il periodo preso in considerazione intercorre tra il 29 ottobre 2021 e il 4 novembre 2021 compresi. In quei giorni Trieste era tornata sotto la luce dei riflettori a causa del divieto di proteste emanato dal sindaco della città e dell'iniziativa di Stefano Puzzer, recatosi a Roma in Piazza del Popolo per richiedere un incontro con le persone "al potere" e discutere delle restrizioni imposte con il Green Pass.

Per identificare i *tweet* centrati sulle vicende collegate al capoluogo friulano è stata utilizzata la seguente *query*: "lang:it trieste (protest OR Green Pass OR novax OR contagi)". Questa stringa permette di recuperare i *tweet* in italiano che comprendono nel testo la parola Trieste e una qualsiasi delle parole incluse nella parentesi, senza distinzione tra maiuscole e minuscole.

I dati testuali ottenuti sono stati salvati in un database insieme al numero che identifica in maniera univoca il *tweet* e all'istanza che consente di determinare se l'oggetto scaricato sia un *retweet* oppure no. Prima di procedere all'elaborazione testuale e alla *sentiment analysis*, è stata effettuata una procedura di ottimizzazione per

---

<sup>3</sup> <https://developer.twitter.com/en/docs/twitter-api/v1/data-dictionary/object-model/tweet>

eliminare i contenuti pubblicati degli account cancellati o bloccati. In questi casi, il testo originale viene sovrascritto con una frase standard in inglese che comunica che l'account non esiste più o è stato bloccato. Il *database* finale è composto da 72597 elementi unici, suddivisi come riportato in tabella 2.1.

## 2.2 Elaborazione testuale

Elaborare il testo al fine di ottenere una sequenza leggibile da un algoritmo è uno degli aspetti più importanti per una corretta analisi con tecniche di Machine Learning. Inoltre è il problema principale che si affronta nel lavorare con contenuti pubblicati sui social network, nei quali abbandonano simboli, link, emoji, hashtag, ecc...

Data	Tweet iniziali	Tweet finali
venerdì 29/10/2021	6402	6395
sabato 30/10/2021	8956	8952
domenica 31/10/2021	5815	5807
lunedì 01/11/2021	17639	17626
martedì 02/11/2021	18962	18949
mercoledì 03/11/2021	10845	10833
giovedì 04/11/2021	4039	4035
Totale	72658	72597

*Tabella 2.1 Tweet estratti divisi per data.*

Queste espressioni veicolano una bassa quantità di informazioni semantiche e, nella forma naturale con cui vengono inseriti o generati, rappresentano una potenziale fonte di disturbo, che può influenzare negativamente la qualità delle valutazioni dell'algoritmo. Nel caso specifico di Twitter, per esempio, se un utente condivide delle foto, video o degli articoli nel testo del *tweet* apparirà l'url del media. Un ulteriore problema è rappresentato dai *retweet* o dei *tweet* in risposta ad altri utenti che presentano nel testo il nome dell'utente che ha pubblicato il contenuto originale. L'username non è composto necessariamente da nome e cognome della persona che ha

creato l'account ma può essere una qualsiasi combinazione di parole e numeri, dati poco informativi e spesso fuorvianti.

Per ovviare a questo problema sono state applicate ai *tweet* delle sostituzioni testuali utilizzando Regular Expression (RE), una libreria di Python che consente di rintracciare le espressioni regolari, delle sequenze di simboli che identificano un insieme di stringhe. Lo scopo di questa procedura è convertire le possibili fonti di disturbo in una forma normalizzata, la quale non altera la sintassi della frase e rende il contenuto più accessibile. Gli elementi identificati sono stati sostituiti seguendo i criteri riportati in tabella 2.2. Punteggiatura, caratteri maiuscoli e *stopword* non sono stati modificati o rimossi per rispettare le caratteristiche del modello utilizzato per la sentiment analysis.

Elemento	Formato	Forma normalizzata	Esempio	Traduzione
Data	gg/mm/aaaa	data	<b>31/10/2021</b> : tasso di contagi alle stelle	<b>Data</b> : tasso di contagi alle stelle
Email	Esempio@esempio.es	email	Scrivetemi pure a <b>xxxx@xxxx.xx</b>	Scrivetemi pure a <b>email</b>
Numero percentuale	XX.X%	percentuale	L'inflazione negli Stati Uniti è al <b>7,3%</b>	L'inflazione negli Stati Uniti è al <b>percentuale</b>
Soldi	X.XX€	denaro	Oggi ho perso <b>50€</b>	Oggi ho perso <b>denaro</b>
Orario	Mm:hh	ora	Ho perso la corriera delle <b>13:10</b>	Ho perso la corriera delle <b>ora</b>

Numero	X.X	numero	Oggi ho fatto <b>10</b> km	Oggi ho fatto <b>numero</b> km
Collegamento Ipertestuale	https://esempi o/[...]	url	Non ci credo! Guardate questo video <b>https://[...]</b>	Non ci credo! Guardate questo video <b>url</b>
Utente di Twitter	@utente	utente	<b>@MarioRossi</b> mi sa che domani ci chiudono	<b>Utente</b> mi sa che domani ci chiudono
Hashtag	#hashtag	hashtag	Forza, resistiamo! <b>#Trieste</b>	Forza, resistiamo! <b>Trieste</b>
Emoji*	😊	Significato emoji	Oggi sto proprio bene! 😊	Oggi sto proprio bene! <b>Faccina con occhi sorridenti</b>

Tabella 2.2 Tabella delle operazioni di elaborazione testuale<sup>4</sup>

## 2.3 BERT

BERT, acronimo di *Bidirection Encoder Representation from Transformers*, è un modello *deep learning* impiegato nel campo del *Natural Language Processing* (NLP), sviluppato da Devlin et al. (2018) e rilasciato da Google. Nella realtà quotidiana veniamo in contatto con questa tecnologia ogni qualvolta utilizziamo il motore di ricerca. I suggerimenti che ci appaiono nel menù a tendina mentre digitiamo nella barra di testo sono merito dell'elaborazione di un software in cui viene utilizzato BERT, che compila automaticamente dei suggerimenti semanticamente validi man mano che digitiamo le parole<sup>5</sup>.

Per la creazione di BERT, gli autori si sono basati sull'implementazione originale del modello *transformer* di Vaswani et al. (2017), limitandosi alla parte

<sup>4</sup> il significato di Emoji è stato ottenuto tramite la libreria Python "Emoji"

<sup>5</sup> <https://blog.google/products/search/search-language-understanding-bert/>

dell'encoder. Per quanto riguarda la struttura di un input, essa è costituita da una coppia di frasi in cui vengono inseriti dei *token* prestabiliti:

- [CLS]: viene posizionato all'inizio dell'input per segnalare la posizione da cui iniziare la classificazione;
- [SEP]: viene posizionato tra le due frasi e alla fine dell'input per segnalare la posizione in cui finire la classificazione;

Le parole vengono divise in token definiti come *sub-word* e la sequenza generata in questo modo viene processata assegnando ad ognuno di essi tre valori vettoriali (Figura 2.1):

- *Token embedding*: un vettore che identifica uno specifico *token*;
- *Segment embedding*: un vettore che rappresenta a quale delle due frasi appartiene la parola;
- *Positional embedding*: un vettore che rappresenta la posizione che la parola occupa all'interno della frase.

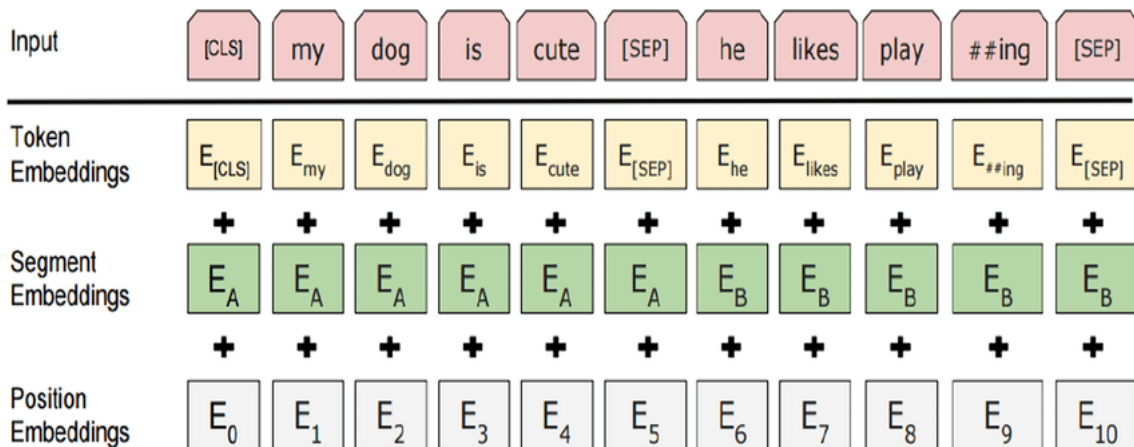


Figura 2.1 Rappresentazione degli embedding di un input (Devlin et al. 2018).

La rappresentazione finale dell'input è data dalla somma dei tre *embedding* precedentemente descritti. È importante sottolineare che i *token* non sono processati in maniera sequenziale ma per ognuno di essi viene generato simultaneamente un vettore



di output. Questo tipo di elaborazione in parallelo è possibile grazie al *segment embedding* e al *positional embedding* che permettono di mantenere le informazioni strutturali della frase.

Per quanto riguarda il processo di *training*, esso è suddiviso in due diverse procedure: *pre-training* e *fine-tuning*.

1) *Pre-training*: l'obiettivo è addestrare BERT affinché possa comprendere cos'è un linguaggio e le relazioni tra le parole che lo compongono. Il modello viene addestrato simultaneamente su due compiti NLP non supervisionati:

- *Masked Language Model* (MLM): una percentuale di *sub-word* prefissata viene sostituita in maniera casuale da un *token* [MASK]. Questa è una procedura di mascheramento statica e l'obiettivo dell'algoritmo è quello di prevedere quali siano le parole più adatte per sostituire il *token* [MASK] nel contesto della frase analizzata;
- *Next Sentence Prediction* (NSP): lo scopo in questo compito è quello di prevedere se la seconda frase ricevuta come input può essere una continuazione valida della prima.

2) *fine-tuning*: è una fase di *training* supervisionato in cui BERT viene addestrato per risolvere specifici compiti NLP. Con questo processo lo strato di output viene modificato affinché possa restituire una predizione valida rispetto al compito da risolvere. Richiede un tempo di elaborazione minore e una mole di dati inferiore rispetto alla fase di *pre-training* dal momento che i parametri più interni dell'architettura sono già stati regolati.

L'impatto di BERT sulla comunità scientifica è stato tale che, ad un anno dal rilascio, erano già stati pubblicati più di 150 studi con il fine di valutarne le prestazioni o di migliorarne le caratteristiche di *training* (Rogers et al. 2020). Tra questi viene introdotto da Liu et al. (2019), il *robust organized BERT approach* (roBERTa), una

procedura di *pre-training* di BERT che impiega strategie di *training* ottimizzate, il 1000% in più di dati e una maggiore potenza di calcolo.

## 2.4 Sentiment Analysis

FEEL-IT (Bianchi et al. 2021) è un modello Machine Learning che permette di effettuare operazioni di sentiment analysis su dati testuali in lingua italiana. E' stato ottenuto effettuando l'operazione di fine-tuning su umBERTo, l'adattamento italiano con procedure ottimizzate del modello roBERTa (Parisi et al. 2020).

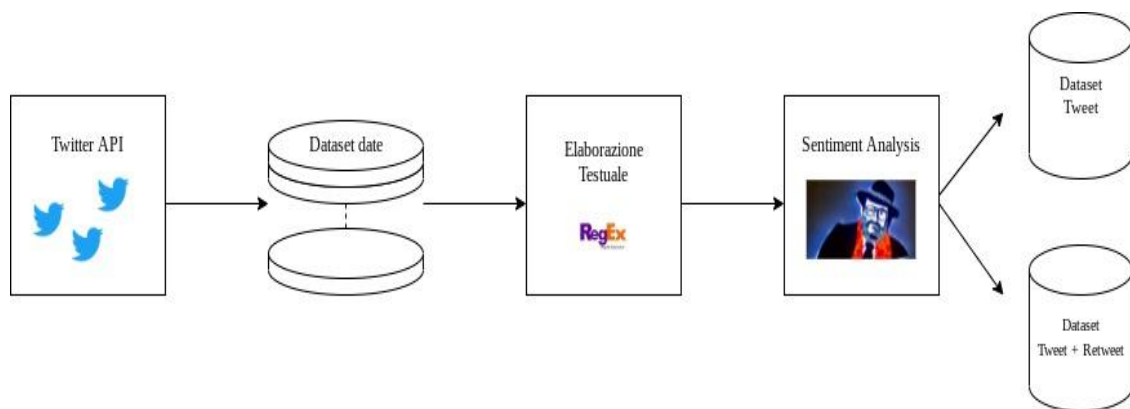
Il dataset utilizzato è composto da 2037 tweet annotati manualmente dagli autori dello studio. Utilizzando come riferimento teorico le emozioni basilari descritte da Ekman (1992), ad ogni post è stata assegnata una tra le seguenti quattro emozioni: rabbia (*anger*), tristezza (*sadness*), paura (*fear*) e felicità (*joy*).

Esistono due versioni del modello: FEEL-IT-emotion e FEEL-IT-sentiment. La prima restituisce un output composto da quattro valori percentuali che rappresentano la probabilità con la quale l'input è associato ad ogni emozione. La seconda, invece, restituisce la probabilità rispetto alla polarità di un tweet (positiva e negativa), ed è stata progettata condensando i valori associati a *sadness*, *anger* e *fear* per determinare la probabilità negativa e considerando unicamente *joy* per la probabilità positiva.

In questo studio è stata utilizzata la versione FEEL-IT-emotion per due motivazioni. In primo luogo, lo spettro emotivo restituito come output fornisce una descrizione migliore degli elementi analizzati, permettendo un'indagine più approfondita dei dati presi in considerazione. In secondo luogo, è possibile ottenere una panoramica generale del sentimento dei tweet, in termini di positività e negatività, seguendo le modalità descritte in precedenza.

Il modello è stato implementato utilizzando Python mentre l'analisi è stata effettuata impostando il programma in Google Colab, che offre come servizio la possibilità di elaborare i dati tramite una GPU esterna, con una maggiore potenza di calcolo, aumentando di molto la velocità di esecuzione del modello. Ad ogni *tweet* è stata associata l'emozione con la probabilità più alta e sono stati creati due database,

uno con i *retweet* e uno senza. La procedura completa utilizzata in questo studio è illustrata in Figura 2.2.



*Figura 2.2 Processo di estrazione e elaborazione dei dati.*

### Capitolo 3: Risultati

Per analizzare i punteggi della classificazione emotiva del dataset con retweet (CR) e del dataset senza retweet (SR) sono state prese in esame le due condizioni separatamente. Per prima cosa sono stati analizzati i punteggi delle emozioni del dataset SR. I dati sono riassunti nella tabella 3.1, in cui sono riportate le classificazioni dalla sentiment analysis suddivise per data. La rappresentazione grafica della distribuzione emotiva nel periodo di tempo considerato è riportata in figura 3.1.

Data	Paura	Rabbia	Tristezza	Gioia	Totale
29/10	262	918	230	216	1626
30/10	231	933	207	264	1635
31/10	131	751	132	271	1285
01/11	382	2428	255	326	3391
02/11	304	1920	276	290	2790
03/11	182	1103	182	229	1696
04/11	195	625	127	236	1183
Totale	1687	8678	1409	1832	13606

Tabella 3.1 Dati delle categorie emotive nel dataset senza retweet (SR)

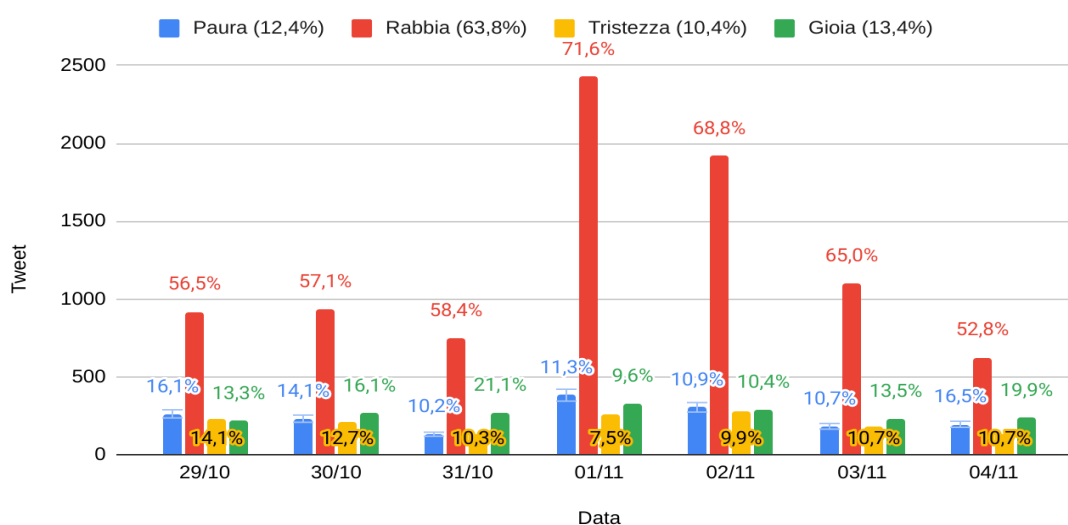


Figura 3.1 Distribuzione delle emozioni del dataset SR

Insieme al numero di tweet, ogni colonna riporta anche la frequenza di ogni categoria rispetto al giorno di pubblicazione. In legenda è riportata la percentuale complessiva di ogni emozione etichettata nel dataset. Su 13606 tweet, la maggior parte dei tweet è stata pubblicata il 01/11 e il 02/11 con un totale di 6181 tweet (45,4%).

La rabbia è l'emozione più rilevata con un totale di 8678 tweet (63,8%). Risulta la categoria con la maggior frequenza in ogni data raggiungendo il picco il 01/11 (71,6%). Nei giorni successivi la percentuale scende fino ad arrivare al 52,6% il 04/11. La tristezza è l'emozione con il minor numero di tweet nel dataset, con un totale di 1409 etichette (10,4%). E' la categoria che presenta il minor numero di osservazioni rispetto al totale in ogni giornata, ad eccezione del 29/10 (14,1%) in cui è la gioia ad essere meno diffusa (13,3%). La paura è presente in 1687 tweet, ricoprendo il 12,4% delle osservazioni totali, con una percentuale maggiore nelle giornate del 29/10 (16,1%), 30/10 (14,1%) e 04/11 (16,5%). Infine, la gioia è stata classificata in 1832 tweet (13,4%), con maggiore frequenza nel 31/10 (21,1%) e nel 04/11 (19,9%).

Per quanto riguarda il dataset CR (tabella 3.2), esso è composto da 72597 tweet, di cui la maggior parte pubblicati tra il 01/11 e il 02/11 (50,4%). Anche durante le giornate del 30/10 e del 03/11 si è verificato un leggero aumento dell'attività di pubblicazione (12,3% e 14,9% rispettivamente). La rappresentazione grafica della distribuzione emotiva nel periodo di tempo considerato è riportata in figura 3.2.ù

Data	Paura	Rabbia	Tristezza	Gioia	Totale
29/10	931	3702	838	924	6395
30/10	1026	5575	1506	845	8952
31/10	1448	3339	390	630	5807
01/11	2201	13080	657	1688	17626
02/11	2698	11638	1515	3098	18949
03/11	1112	7521	739	1461	10833
04/11	660	2374	440	561	4035
Totale	10076	47229	6085	9207	72597

*Tabella 3.2 Dati delle categorie emotive nel dataset senza retweet (SR)*




Figura 3.1 Distribuzione delle emozioni del dataset SR

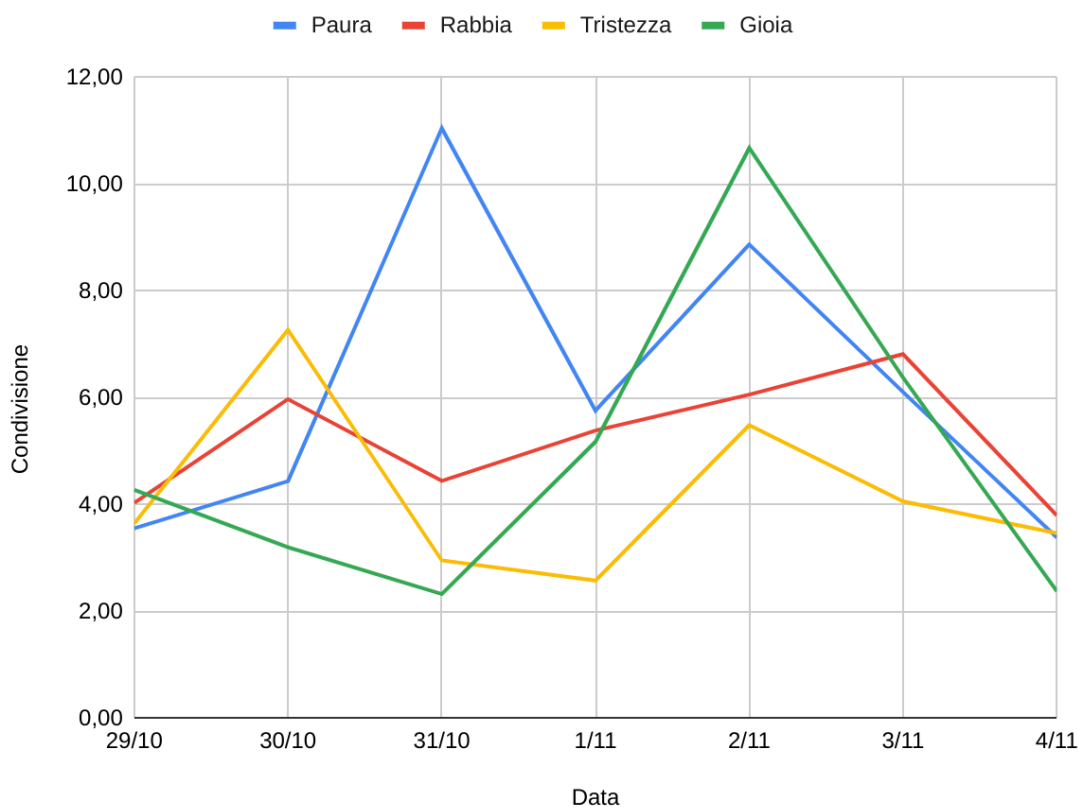
Anche in questo caso, la rabbia è l'emozione più classificata con un totale di 47229 tweet (65,1%). Essa risulta la categoria con la maggior frequenza in ogni data, raggiungendo il picco il 01/11 (74,2%). La tristezza è l'emozione con il minor numero di tweet nel dataset, con un totale di 6085 elementi (8,4%). E' la categoria che presenta il minor numero di osservazioni rispetto al totale in ogni giornata, ad eccezione del 30/10 (16,8%). La paura è presente in 10076 tweet, ricoprendo il 13,9% delle osservazioni totali, con una percentuale maggiore nelle giornate del 31/10 (24,9%), 04/11 (16,4%). Infine, la gioia è stata classificata in 9207 tweet (12,7%), con maggiore frequenza in data 02/11 (16,3%).

Infine, sono state analizzate le informazioni sulla condivisione delle emozioni mettendo in rapporto il numero dei tweet contenuti nel dataset CR con quelli nel dataset SR (tabella 3.3). La rappresentazione grafica dell'andamento della condivisione delle emozioni grafiche è presentata in figura 3.3. In termini di attività di condivisione, le giornate del 02/11 (6,79) e del 03/11 (6,39) sono state quelle in cui si registrano i valori più alti, mentre i valori più bassi si possono osservare in data 29/10 e 04/11 (rispettivamente 3,93 e 3,41). La paura è stata l'emozione maggiormente condivisa il

31/10 con un numero di tweet circa 11 volte maggiore rispetto al dataset SR.

Data	Paura	Rabbia	Tristezza	Gioia	Totale tweet
29/10	3,55	4,03	3,64	4,28	3,93
30/10	4,44	5,98	7,28	3,20	5,48
31/10	11,05	4,45	2,95	2,32	4,52
01/11	5,76	5,39	2,58	5,18	5,20
02/11	8,88	6,06	5,49	10,68	6,79
03/11	6,11	6,82	4,06	6,38	6,39
04/11	3,38	3,80	3,46	2,38	3,41

*Tabella 3.3 Rapporto del numero di tweet del dataset CR e del dataset SR*



*Figura 3.3 Andamento delle condivisioni delle emozioni nei tweet*

Ad eccezione del 30/10, la tristezza è l'emozione che risulta meno ripubblicata in ogni giornata. Per quanto riguarda la gioia, è possibile osservare un incremento nella

condivisione tra le giornate del 01/11 e 03/11, con un picco in data 02/11 (10,68). Infine, il numero di repost dei tweet classificati come rabbia rimane costante durante il periodo considerato, con il valore minore in data 04/11 (3,8). La rappresentazione grafica dell'andamento della condivisione delle emozioni classificate è riportata in figura 3.3.

Oltre all'analisi effettuata con FEEL-it-emotion, sono state raccolte le 10 parole utilizzate più di frequente nei tweet pubblicati dagli utenti in ogni data, escludendo quelle utilizzate nella query di ricerca dell'API (Trieste, contagi, manifestazioni, greenpass, novax), dato che sono la condizione con la quale i tweet sono stati identificati. Inoltre, non sono state considerate le parole utilizzate per l'elaborazione testuale (utente, numero, data, ecc...), dal momento che sono elementi inseriti unicamente allo scopo di migliorare l'elaborazione del modello deep learning. I dati ottenuti in questo modo sono riassunti nelle tabelle dalla 3.4 alla 3.10.

Parola	Ripetizioni
indice	1717
abbassato	1126
contagi	862
manifestazioni	717
nogreenpass	687
portuali	636
ospedale	594
corteo	539
indice	533
covid	515

Tab. 3.4 Frequenza parole 29/10

Parola	Ripetizioni
contagi	2289
covid	989
aumento	882
vaccino	772
indice	771
medici	760
locali	744
effetti	743
manifestazioni	742
avversi	740

Tab. 3.5 Frequenza parole 30/10



Parola	Ripetizioni
contagi	1918
casi	1136
provincia	948
peggiore	914
ospedali	693
covid	554
pass	478
portuali	433
abbassato	411
indice	409

Tab. 3.6 Frequenza parole 31/10

Parola	Ripetizioni
piazza	3684
manifestazioni	3231
sindaco	2894
prefetto	2732
manifestare	2636
contagi	1709
Unità	1596
vietate	1547
indice	1546
libertà	1544

Tab. 3.7 Frequenza parole 01/11

Parola	Ripetizioni
prefetto	2013
manifestazioni	1933
piazza	1861
indice	1684
sindaco	1678
Roma	1667
Puzzer	1543
contagio	1076
portuale	954
forza	907

Tab. 3.8 Frequenza parole 02/11

Parola	Ripetizioni
Roma	2575
Puzzer	2501
protesta	2359
divieto	1854
piazza	1791
portuale	1284
manifestazione	1219
piazza	988
contagio	952
nogreenpass	926

Tab. 3.9 Frequenza parole 03/11

Parola	Ripetizioni
posti	1071
manifestazioni	609
Puzzer	569
contagi	533
covid	450
terapie	442
intensive	442
Roma	436
effetti	420
indice	402

Tab. 3.10 Frequenza parole 04/11



## Capitolo 4: Discussione

I risultati prodotti grazie alla sentiment analysis permettono di fare alcune importanti osservazioni sui dati ricavati da Twitter. Innanzitutto, nei giorni precedenti al 01/11 l'attività di pubblicazione è la più bassa riscontrata nel dataset considerando sia i tweet sia i retweet. E' possibile osservare un aumento in termini di pubblicazioni e in termini di condivisione durante le giornate del 01/11 e 02/11. L'incremento del dibattito online su Trieste in queste giornate può essere spiegato dalla decisione del sindaco Dipiazza di bloccare le proteste e dall'apparizione di Stefano Puzzer in piazza a Roma. E' possibile che i due eventi abbiano attirato l'attenzione del pubblico stimolando le persone a pubblicare le proprie opinioni su ciò che stava accadendo. Nei giorni successivi l'attività scende in maniera graduale sino ad arrivare ad un numero di tweet simile a quelli dei giorni precedenti alle notizie. Inizialmente, l'evento che ha scatenato l'ira dei manifestanti è stata l'introduzione del green pass sul luogo del lavoro. Successivamente il divieto di creare assembramenti in Piazza Unità ha riacceso la rabbia nei confronti della giunta comunale. Il modello ICM (Jun et al. 2012) considera l'emanazione di una nuova legge o decreto come un evento ad alto coinvolgimento istituzionale e ad alto livello di conative coping. In tal senso, viene ipotizzato che le emozioni condivise dal pubblico siano principalmente rabbia e tristezza (Jun et al. 2012). I risultati di questo studio supportano parzialmente l'ipotesi di questo modello.

Considerando i dati ricavati giorno per giorno, la sentiment analysis e l'analisi delle parole più frequentemente utilizzate permettono di fare diverse considerazioni sui flussi di informazione che riguardano le proteste di Trieste:

- 29 Ottobre: Nei tweet raccolti in questa data la distribuzione delle emozioni nei due dataset presenta valori molto simili. Anche in termini di condivisione tutte le categorie considerate ottengono punteggi simili. Le parole più frequenti contengono termini legati alle manifestazioni e ai contagi da covid-19 indicando un sentimento molto attivo e aggressivo nei confronti di queste tematiche.
- 30 Ottobre: Il numero di tweet è molto vicino a quello del giorno precedente,

anche se è presente una maggiore attività di condivisione. La tristezza raggiunge in questa giornata il maggior numero di ripubblicazioni ed è anche l'unica giornata in cui la frequenza nel dataset con retweet aumenta rispetto al dataset senza retweet. Le parole più frequenti sono maggiormente incentrate sui contagi in aumento e sugli effetti avversi del vaccino. Ciò potrebbe spiegare l'aumento della propagazione di paura e tristezza in quanto le persone sembrano essere preoccupate e spaventate rispetto all'aumento dei casi di covid e ai possibili effetti negativi del vaccino. E' possibile che il pubblico, di fronte a questo scenario, provi un forte sentimento di impotenza e incapacità di reagire.

- 31 Ottobre: Anche in questa giornata i dati dei tweet e dei retweet sono simili rispetto a quelli dei giorni precedenti. Un dato interessante si può riscontrare nel numero di condivisione di paura e gioia. Considerando il dataset senza retweet si può osservare come, rispetto alle altre date, la gioia abbia la maggior frequenza mentre la paura quella minore. Invece, considerando il dataset con retweet, il 31/10 è il giorno in cui la paura ha il maggior numero di condivisioni (circa 11 volte), arrivando ad essere presente in un tweet su quattro, mentre la gioia è presente solo nel 10% dei tweet. Come nelle precedenti giornate, i termini più frequenti sono centrati sul covid e sul numero di contagi.
- 1 Novembre: In questa giornata arriva la comunicazione del sindaco di bloccare le proteste in Piazza Unità. La notizia non lascia il pubblico indifferente e l'attività su Twitter incrementa sia in termini di pubblicazioni sia in termini di condivisione. La rabbia è l'emozione che domina questa giornata, presente in più del 70% dei tweet in entrambi i dataset. Anche la paura ottiene un alto numero di condivisioni, di poco superiore a quello della rabbia. Le parole più frequenti riguardano tematiche legate alla decisione del sindaco di fermare le manifestazioni. Tale presa di posizione può aver aumentato la rabbia e il malcontento nei confronti delle autorità locali, alimentando il risentimento dei manifestanti e incrementando la tensione che si era creata con l'introduzione del green pass.
- 2 Novembre: La data con più pubblicazioni e più condivisioni. Inoltre, è il

giorno in cui la gioia possiede il maggior numero di ripubblicazioni, circa 10 volte rispetto al dataset senza retweet. Una possibile spiegazione a questo dato può essere data dall'apparizione di Stefano Puzzer in Piazza del Popolo. Il portavoce dei portuali si era guadagnato le simpatie dei lavoratori di tutta Italia durante il periodo delle manifestazioni. La sua comparsa a Roma può aver provocato un'ondata di pubblicazioni con termini molto positivi volti a supportare e a sostenere l'iniziativa di Puzzer. Questo dato trova conferma nei termini più frequenti usati in quella giornata in cui il cognome "Puzzer" appare circa in un tweet su dieci. L'elevato numero di pubblicazioni può anche essere spiegato dal blocco delle manifestazioni comunicato il giorno precedente.

- 3 Novembre: Rispetto alle precedenti giornate si può osservare un calo nel numero di tweet pubblicati. È interessante notare come, il 3 novembre, sia stato pubblicato un numero di tweet relativamente basso, simile al periodo iniziale, ma in termini di ripubblicazioni è il secondo giorno per numero di condivisioni. Questo può indicare che gli eventi dei giorni precedenti sono ancora fonte di turbamento e, anche se le persone hanno pubblicato meno tweet di loro pugno, il pubblico online è ancora interessato a ciò che è accaduto. In particolare, molti termini sono ancora legati all'apparizione di Stefano Puzzer a Roma.
- 4 Novembre: In questa data è possibile notare una diminuzione nell'attività sul social network, dato che, in entrambi i dataset, questa è la giornata con il minor numero di tweet raccolti. Per quanto riguarda i termini più utilizzati, è ancora presente il cognome "puzzer" anche se aumentano le parole relative al covid, come per esempio "contagi", "terapie" e "intensive". È possibile osservare come, nel dataset senza retweet, la frequenza della gioia in questa giornata ha il secondo punteggio più alto, dato che potrebbe indicare ancora un forte sostegno nei confronti di Stefano Puzzer. In termini di propagazione, invece, sono le emozioni negative ad avere i punteggi più elevati. Ciò potrebbe essere causato dalla maggiore attenzione dedicata all'aumento dei contagi e al riempimento delle terapie intensive.

In generale, la rabbia e la paura sono le emozioni che vengono ripubblicate

maggiormente dagli utenti. Inoltre, la rabbia è l'emozione che in generale mostra il maggior numero di pubblicazioni in entrambi i dataset. Al contrario, la tristezza, non solo è l'emozione meno presente ma anche quella meno condivisa. Questi dati supportano la teoria dell'attivazione (Barrett e Russell 1998), secondo la quale rabbia e paura sono emozioni attivanti che spingono le persone all'azione, mentre la tristezza è considerata come deattivante. Sempre secondo questa teoria anche la gioia è un'emozione attivante (Barrett e Russell 1998) ma, nel caso preso in esame, essa presenta un numero basso di condivisioni, superando nei retweet solo la tristezza. Prendendo in considerazione la condizione senza retweet, invece, la gioia è la seconda emozione più pubblicata.

## Conclusioni

In questo studio sono state indagate le emozioni presenti nei post che sono stati pubblicati su Twitter dal 29/10 al 04/11 riguardanti le proteste di Trieste. Utilizzando l'API di Twitter sono stati considerati creati due dataset, uno con retweet e uno senza retweet, entrambi classificati con FEEL-IT-emotion, un modello deep learning che si basa su quattro emozioni: rabbia, tristezza, paura e gioia. I risultati indicano che i fattori emotivi contenuti in un tweet, come rabbia e tristezza, mostrano effetti diversi sull'attività di condivisione dei contenuti. I dati ricavati supportano parzialmente la teoria del bias di negatività, la teoria dell'attivazione e il modello ICM nel caso considerato in questo studio, indicando così la necessità di approfondire queste teorie, applicandole ad altri contesti.

Il principale limite incontrato in questo è legato all'account creato per interfacciarsi all'API di Twitter. Nel caso in cui il richiedente non sia un ricercatore abilitato oppure un'azienda, la piattaforma fornisce un account standard, che consente l'accesso ai tweet pubblicati entro i sette giorni precedenti alla data in cui si effettua la richiesta di download.

In futuro sarà necessario studiare come il dibattito riguardo un determinato evento si sviluppa considerando i contenuti pubblicati su diversi social network, come Facebook e Instagram. Ciò permetterà ai ricercatori di indagare le differenze nel comportamento di condivisione degli utenti che pubblicano messaggi su diverse piattaforme social e, nel complesso, una visione d'insieme più accurata sull'opinione del pubblico online. Inoltre, si potrebbe integrare la sentiment analysis i dati delle posizioni da cui gli utenti hanno pubblicato un determinato contenuto, creando in questo modo una mappa del sentimento. In questo modo si potrebbe studiare la distribuzione delle emozioni in base alla distanza dal luogo in cui si è verificato un determinato evento, verificando come questa possa influire nelle emozioni contenute nei messaggi pubblicati sui social network.



Le tecniche di sentiment analysis sono un ottimo strumento di analisi per estrarre informazioni da grandi quantità di dati, come per esempio i contenuti pubblicati nei social network, e con l'aiuto di tali tecniche i professionisti potranno studiare diverse strategie di analisi dell'opinione pubblica, aiutandoli a inquadrare quali siano le tematiche che preoccupano le persone e quale sia il tono emotivo che circonda le discussioni online.

## Bibliografia

- Alpaydin, E. (2010). Introduction to Machine Learning. MIT Press. 1, 9.
- Berger, J., e Milkman, K. L. (2012). What makes online content go viral?. Journal of Marketing Research, 49, 192-205.
- Bianchi, F., e Nozza, D., e Hovy, D. (2021). FEEL-IT: Emotion and Sentiment Classification for the Italian Language. Proceedings of the 11th Workshop on Computational Approaches to Subjectivity, Sentiment and Social Media Analysis. Association for Computational Linguistics.
- Burnap, P., e Williams, M. L., e Sloan, L., e Rana, O., e Housley, W., e Edwards, A., e Knight, V., e Procter, R., e Voss., A. (2014) Tweeting the terror: Modelling the social media reaction to the Woolwich terrorist attack. Social Network Analysis and Mining, 4, 1-14.
- Chen, R., e Sakamoto, Y. (2014). Feelings and perspective matter: Sharing of crisis information in social media. Proceedings of the Annual Hawaii International Conference on System Sciences, 1958-1967.
- Chowdhury, G. (2003). Natural Language Processing. Annual Review of Information Science and Technology, 37, 51-89.
- Chung, W., e Zeng, D. (2018). Dissecting emotion and user influence in social media communities: An interaction modeling approach. Information and Management, 57.
- Devlin, J., e Chang, M., e Lee, K., e Toutanova, K. (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. arXiv:1810.04805.
- Fan, R., e Zhao, J., e Chen, Y., Xu, K. (2014). Anger is more influential than joy: Sentiment correlation in Weibo. PloS one, 9.

Gaspar, R., e Pedro, C., e Panagiotopoulos, P., e Seibt, B. (2016). Beyond positive or negative: Qualitative sentiment analysis of social media reactions to unexpected stressful events. *Computers in Human Behavior*, 56, 179-191.

Hornik, J., e Satchi, R. S., e Cesareo, L., Pastore, A. (2015). Information dissemination via electronic word-of-mouth: Good news travels fast, bad news travels faster!. *Computers in Human Behavior*, 45, 273-280.

Hu, X., e Zhang, X., e Wei, J. (2019). Public attention to natural hazard warnings on social media in China. *Weather, Climate, and Society*, 11, 83-197.

Jianqiang, Z., e Xiaolin G., e Feng, T. (2017). A new method of identifying influential users in the micro-blog networks. *IEEE Access: Practical Innovations, Open Solutions*, 5, 3008-3015.

Jin, Y., e Pang, A. e Cameron, G.T. (2007). “Integrated crisis mapping: towards a publics-based, emotion-driven conceptualization in crisis communication”, *Sphera Publica*, 81-95.

Jin, Y., e Pang, A., e Cameron, G. T. (2012). Toward a publics-driven, emotion-based conceptualization in crisis communication: Unearthing dominant emotions in multi-staged testing of the integrated crisis mapping (ICM) model. *Journal of Public Relations Research*, 24, 266-298.

Kanavos, A., e Perikos, I., e Hatzilygeroudis, I., e Tsakalidis, A. (2018). Emotional community detection in social networks. *Computers and Electrical Engineering*, 65, 449-460.

LeCun, Y., e Bengio, Y. e Hinton, G. (2015). Deep learning. *Nature*, 436-444.

Lee, J., e Hong, I. B. (2016). Predicting positive user responses to social media advertising: The roles of emotional appeal, informativeness, and creativity. *International Journal of Information Management*, 36, 360-373.

Liu, Y., e Ott, M., e Goyal, N., e Du, J., e Joshi, M., e Chen, D., e Levy, O.,

Lewis, M., e Zettlemoyer, L., e Stoyanov, V. (2019). RoBERTa: A Robustly Optimized BERT Pretraining Approach. arXiv:1907.11692.

Liu, B. (2012). Sentiment Analysis and Opinion Mining. Morgan & Claypool Publishers.

Li, X., e Wang, Z., e Gao, C., e Shi, L. (2017). Reasoning human emotional responses from large-scale social and public media. Applied Mathematics and Computation, 310, 182-193.

Loureiro, M. L., e Alló M. (2020). Sensing climate change and energy issues: Sentiment and emotion analysis with social media in the U.K. and Spain. Energy Policy, 143.

Lwowski, B., e Rad, P., e Choo. K. R. (2020). Geospatial Event Detection by Grouping Emotion Contagion in Social Media, IEEE Transactions on Big Data, 6, 159-170.

Nabi, R. L. (2003). Exploring the framing effects of emotion: Do discrete emotions differentially influence information accessibility, information seeking, and policy preference?. Communication Research, 30, 224-247.

Messaoudi, C., e Guessoum, Z., e Romdhane1, L. B. (2022). Opinion mining in online social media: a survey. Social Network Analysis and Mining, 12-25.

Oh, O., e Kwon, K., Rao, H. R. (2010). An exploration of social media in extreme events: Rumor theory and twitter during the HAITI earthquake. 31st International Conference on Information Systems, ICIS 2010, 231, 7332-7336.

Öztürk, N., e Ayvaz, S. (2018). Sentiment analysis on Twitter: A text mining approach to the Syrian refugee crisis. Telematics and Informatics, 35, 136-147.

Pang, B., e Lee, L., e Vaithyanathan, S. (2002). Thumbs up?: sentiment classification using machine learning techniques. Proceedings of Conference on Empirical Methods in Natural Language Processing.

Pang, B., e Lee, L. (2008). Opinion mining and sentiment analysis. *Found Trends and Information Retrieval*, 2, 1-135.

Patel, P., e Thakkar, A. (2020). The upsurge of deep learning for computer vision applications, *International Journal of Electrical and Computer Engineering*, 10, 538-548.

Remy, C., e Pervin, N., e Toriumi, F., Takeda, H. (2013). Information diffusion on twitter: Everyone has its chance, but all chances are not equal. *Proceedings - 2013 International Conference on Signal-Image Technology and Internet-Based Systems*, 483-490.

Rogers, A., e Kovaleva, O., e Rumshisky, A., (2020). A Primer in BERTology: What We Know About How BERT Works. *Transactions of the Association for Computational Linguistics*, 8, 842–866.

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks*, 61, 85-117.

Su, Y., e Wu, P., e Li, S., Xue, J., e Zhu, Z. (2020). Public emotion responses during COVID-19 in China on social media: An observational study. *China Social Science Fund*.

Uban, A., e Chulvi, B., e Rosso, P. (2021). An emotion and cognitive based analysis of mental health disorders from social media data. *Future Generation Computer Systems*, 124, 480-494.

Vaish, A., e Grossmann, T., e Woodward, A. (2008). Not all emotions are created equal: The negativity bias in social-emotional development. *Psychological Bulletin*, 134, 383-403.

Vaswani, A., e Shazeer, N., e Parmar, N., e Uszkoreit, J., e Jones, L., e Gomez, N. A., e Kaiser, L., Polosukhin, I. (2017). Attention Is All You Need. *arXiv:1706.03762*.

Wiebe, J., e Bruce, R. F., e O'Hara, T. P. (1999). Development and use of a

gold-standard data set for subjectivity classifications. Proceedings of the Association for Computational Linguistics.

Wu, B., e, Shen H. (2015). Analyzing and predicting news popularity on Twitter. *International Journal of Information Management*, 35, 702-711.

Xu, J., e Du, Z., e Guo, J., e Fu, X., e Zhang, Y., e Wu, Y., (2018). Empirical and modeling studies of WeChat information dissemination. *Physica A: Statistical Mechanics and Its Applications*, 512, 1113-1120.

