DIGITAL FUTURE
OR4 – Soluzioni Verticali

Analisi Servizi di Piattaforma per la Sicurezza Ambientale e il Controllo del Territorio

TR 4.7

AUTORE: EXPRIVIA S.P.A

Indice dei contenuti

INDICE DEI CONTENUTI **3**
INDICE DELLE FIGURE **5**
INDICE DELLE TABELLE **6**
1. INTRODUZIONE **7**
2. MONITORAGGIO RIFIUTI INDUSTRIALI **9**
2.1. MONITORAGGIO ISOLE DI RACCOLTA 9
2.1.1. Isole di Raccolta con contenitori dotati di sensore *10*
2.1.2. Isole di Raccolta con contenitori privi di sensore *12*
2.2. TRASPORTO SU STRADA DI RIFIUTI PERICOLOSI 13
3. MONITORAGGIO INQUINAMENTO ATMOSFERICO **16**
3.1. CLUSTERING CENTRALINE ARPA E GENERAZIONE ALLARMI 17
3.2. MODELLO QUALITÀ DELL'ARIA E DISPERSIONE DELL'INQUINAMENTO 20
3.2.1. Campo Vettoriale di Ventosità *21*
3.2.2. Calcolo dell'IQA *22*
3.2.3. Generazione Mappa di Calore *23*
4. MONITORAGGIO ABBANDONO RIFIUTI **25**
4.1. COMPUTER VISION E MODELLI DI RICONOSCIMENTO OGGETTI 26
4.1.1. Messa a punto del Modello di Riconoscimento Rifiuti *28*
4.1.2. Conversione e Serving del Modello addestrato *31*
4.2. SERVIZIO DI REAL TIME VIDEO STREAM PROCESSING 33
4.2.1. Detection Streamer *34*
4.2.2. Alarm Streamer *36*
5. MONITORAGGIO FENOMENI AMBIENTALI TRAMITE TECNICHE OSINT **40**
5.1. SERVIZIO APPLICATIVO DI CALAMITY DETECTION 42
5.1.1. Data Acquisition *42*
5.1.2. Event Detection *44*
5.1.3. Early Warning *46*

6. CONCLUSIONE 48
7. BIBLIOGRAFIA E SITOGRAFIA 49

Indice delle figure

Figura 1: Codifica a blocchi dell'algoritmo previsionale del conferibile 12
Figura 2: Object Detection 26
Figura 3: Modelli di object detection a confronto. Accuratezza contro tempi di inferenza [3] 28
Figura 4: Addestramento Garbage Detection Yolov3 con AlexeyAB/Darknet 30
Figura 5: Conversione del Modello Addestrato per essere utilizzato a run time dal servizio applicativo di Riconoscimento Rifiuti 32
Figura 6: Pipeline Riconoscimento Rifiuti implementata sulla Piattaforma Digital Future 33
Figura 7: Schema del Job Flink che effettua il Detection Streamer 35
Figura 8: Tumbling Time Windowing 36
Figura 9: Schema del Job Flink che effettua l'Alarm Streamer 37
Figura 10: Sliding Time Windowing 39

Indice delle tabelle

Non è stata trovata alcuna voce dell'indice delle figure.

1. Introduzione

Scopo del presente documento è descrivere scenari reali di utilizzo dei servizi esposti dalla piattaforma Digital Future per il Monitoraggio Ambientale e il Controllo del Territorio. Dalla descrizione degli scenari, si potrà evincere come, in momenti diversi, la piattaforma Digital Future diventa uno strumento fondamentale per approcciare ile diverse problematiche che il controllo dell'ambiente deve affrontare e soprattutto la grande quantità di dati che nel mondo Ambiente / Territorio si raccolgono o vengono prodotti in real-time da dispositivi e attrezzature di ultima generazione.

Digital Future diventa, quindi, utile in più scenari, apparentemente distanti tra loro ma collegati da una analisi di fondo che a più riprese aiuta l'esperto del dominio in svariate attività: dalla raccolta dei dati, alla loro fruizione multimediale, all'analisi esplorativa, all'utilizzo di tecniche intelligenti per l'apprendimento da tali dati, all'analisi complessa di schemi "nascosti" tra i dati che vengono enfatizzati e portati alla luce.

Gli scenari che vengono, di seguito, riportati enfatizzano l'utilizzo pervasivo della piattaforma Digital Future utilizzando dati reali e ipotizzando come questi possano essere sfruttati per dar luce a differenti tipologie di analisi attraverso l'utilizzo sia dei servizi infrastrutturali esposti dalla piattaforma e sia applicativi che tramite i servizi infrastrutturali possono essere realizzati ed eseguiti per fornire informazioni utili alla soluzione verticale per il Monitoraggio e Controllo del Territorio.

La soluzione verticale sarà sperimentata in quattro scenari applicativi:

1. Monitoraggio Rifiuti Industriali nelle due varianti:
    - Monitoraggio Isole di raccolta
    - Monitoraggio Trasporto su strada di rifiuti pericolosi
2. Monitoraggio Inquinamento Atmosferico, previa acquisizione dati da centraline ARPA.

3. Monitoraggio Abbandono Rifiuti in aree urbane rilevato attraverso l'analisi di video da telecamere fisse.
4. Monitoraggio Fenomeni Ambientali catturati attraverso l'analisi di quanto riportato sui canali social (ad esempio Twitter) e siti specialistici del settore.

Di seguito vengono dettagliati i servizi che saranno realizzati attraverso la Piattaforma Digital Future per supportare tutte le fasi di analisi dei dati specifiche dei casi d'uso suddetti. Tali servizi possono, a ragione, considerarsi parte integrante della logica di business implementata dalla soluzione di Monitoraggio e Controllo nei quattro scenari applicativi.

2. Monitoraggio Rifiuti Industriali

2.1. Monitoraggio Isole di Raccolta

La gestione dei Rifiuti Urbani e Speciali è divenuta uno degli aspetti più importanti della tutela dell'ambiente e di governo del territorio, per le società industriali avanzate. L'attenzione degli addetti ai lavori si sta sempre più spostando verso i sistemi di raccolta, come strumento di gestione e controllo della produzione. Una tecnologia che si sta sperimentando in alcune grandi città è quella che prevede la modernizzazione dei contenitori dei rifiuti con sensori in grado di fornire la percentuale di riempimento del contenitore, la temperatura all'interno del contenitore (incendio dei rifiuti), la sua posizione, se è stato rovesciato, etc. L'introduzione di tale tecnologia dovrebbe consentire non solo l'ottimizzazione della raccolta ma anche la raccolta di dati in tempo reale sulla produzione dei rifiuti, alimentando algoritmi di apprendimento automatico con lo scopo di analizzare i modelli di generazione dei rifiuti e fare previsioni basate sui dati che possono aiutare la città a ottimizzare i servizi di raccolta.

Nel Pillar Monitoraggio e Controllo del Territorio si è pensato di mettere a punto due casi d'uso relativi al monitoraggio di isole di raccolta di oli industriali esausti, situate presso alcune infrastrutture portuali pugliesi e presso aziende private, in due situazioni differenti:

1. isole con contenitori monitorati da sensori di riempimento
2. isole con contenitori tradizionali privi di sensore di riempimento

Il due casi d'uso, generalizzabili per qualsiasi tipologia di rifiuti, hanno lo scopo di mostrare come la Piattaforma Digital Future, attraverso i servizi infrastrutturali messi a disposizione, possa contribuire a fornire soluzioni utili alla gestione ottimizzata del processo di raccolta rifiuti.

2.1.1. *Isole di Raccolta con contenitori dotati di sensore*

Tale scenario prevede di monitorare il conferimento di rifiuti di tipo olio industriale esausto in isole di raccolta in cui i contenitori sono dotati di sensori di riempimento.

Tale scenario prevede l'utilizzo di sensori Low Power connessi attraverso la rete SIGFOX che è una rete di telecomunicazione dedicata all'Internet delle cose. Sigfox utilizza un nuovo e innovativo protocollo di comunicazione wireless, che fornisce i seguenti vantaggi: eccellente raggio d'azione e sicurezza, consumo energetico molto basso, bassa complessità e tecnologia esclusiva. Tutto questo sarà ottenuto impiegando una tecnologia wireless a banda ultra stretta, operante sulla frequenza libera 868MHz, che garantisce una comunicazione ad ampio raggio con bassi consumi energetici, pur mantenendo una infrastruttura di rete semplice. La tecnologia LPWA (Low Power Wide Area) progettata da Sigfox è una soluzione ideale per qualsiasi applicazione connessa che richieda semplicità d'uso, costo contenuto e basso consumo energetico, con i benefici aggiuntivi di eccellente sicurezza, scalabilità e supporto alla mobilità. Nettrotter è l'unico operatore italiano ad implementare e gestiree la rete Sigfox sul territorio nazionale, avendo il ruolo di SNO (Sigfox Network Operator) in Italia, attraverso le esistenti torri TLC e televisive.

In tale scenario, i dati provenienti dai singoli sensori Sigfox presenti su ogni contenitore dislocato presso alcune isole di raccolta, saranno:

- convogliati sulla Piattaforma Digital Future e persistiti nel layer di storage della Piattaforma;
- processati man mano che arrivano (stream processing) per generare messaggi ad indicare lo stato dei contenitori presenti nell'isola di raccolta e/o la situazione dell'intera isola.

I dati che arriveranno sulla Piattaforma sono alquanto variegati e riguardano non solo la percentuale di riempimento del contenitore ma anche informazioni per la sua geo-localizzazione, la temperatura all'interno del contenitore, se il contenitore è capovolto, il livello di batteria del sensore, etc.

Il servizio applicativo di analisi dati sarà realizzato attraverso il componente di Middleware di Piattaforma che consente la "Configurazione ed Esecuzione di Algoritmi di Elaborazione in Modalità Adattiva e Riflessiva". Il servizio applicativo elaborerà i dati in streaming, man mano che le tuple di dati contenente informazioni relative ad un sensore, entreranno nella Piattaforma Digital Future.

Lo script eseguirà:

1. Controlli puntuali sui dati del sensore:
   - ✓ superamento soglia per la percentuale di riempimento del contenitore
   - ✓ superamento soglia per il valore di temperatura rilevato
   - ✓ stato del contenitore (rovesciato / non rovesciato)
   - ✓ livello della batteria

   ritornando segnalazioni opportune che verranno veicolate verso i destinatari nelle modalità più appropriate.
2. Controlli di correlazione con i dati forniti da altri sensori collocati su contenitori dello stesso tipo presenti nell'isola di raccolta al fine di generare segnalazioni sulla capacità corrente di conferimento dell'isola, fornendo le corrette informazioni per il processo di raccolta dei rifiuti.
3. Verifiche su eventuali sversamenti / perdite di contenuto da parte dei contenitori (percentuali di riempimento in difetto rispetto alle rilevazioni precedenti in assenza di un processo ufficiale di svuotamento del contenitore).

La situazione puntuale di ogni contenitore, per ogni isola di raccolta, sarà, grazie alle segnalazioni prodotte dallo script suddetto, visualizzata all'interno delle dashlet messe a disposizione dalla soluzione verticale per il Monitoraggio e Controllo del Territorio.

2.1.2. *Isole di Raccolta con contenitori privi di sensore*

Tale scenario prevede di monitorare il conferimento di rifiuti di tipo olio industriale esausto in isole di raccolta in cui i contenitori non sono dotati di sensori di riempimento. In tale caso, la previsione del conferibile presso l'isola sarà effettuato sulla base dei dati storici relativi al conferito negli anni precedenti. L'idea è di mettere a punto un algoritmo predittivo capace di predire il conferibile mensile, a partire da dati storici sul conferito: isola di raccolta, data di raccolta, quantità di olio prelevato alla data.

Per pervenire alla definizione dell'algoritmo migliore da utilizzare, è stato effettuato uno studio di dominio. Le conclusioni a cui si è pervenuto e la descrizione dell'algoritmo più idoneo alla predizione viene fornito nel documento dal titolo "TR4.7-Allegato - Specifica Modello Previsionale del Conferibile" allegato al presente Technical Report.

L'algoritmo di previsione del conferibile ipotizzato sarà poi codificato in Python utilizzando il componente di Piattaforma per la "Realizzazione ed Esecuzione di Algoritmi di Elaborazione dati in Modalità Interactive Computing", dopo aver prima creato sulla Piattaforma un Offline Dataset e successivamente caricato i dati storici relativi al conferito negli anni precedenti, per ogni isola di raccolta attraverso gli appositi servizi messi a disposizione dal Middleware della Piattafroma DF. Nella figura seguente viene mostrata la possibile codifica a blocchi dell'algoritmo previsionale.

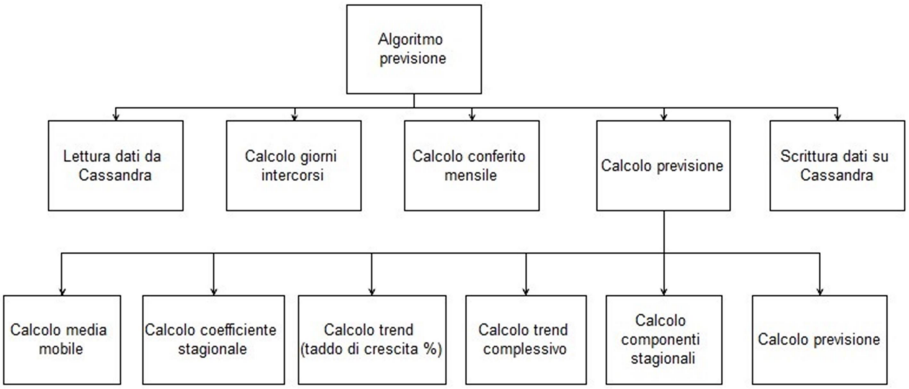

Figura 1: Codifica a blocchi dell'algoritmo previsionale del conferibile

L'idea di base è eseguire l'algoritmo all'inizio di ogni esercizio di gestione della raccolta rifiuti dalle isole di raccolta, ad esempio all'inizio dell'anno, utilizzando i dati storici relativi al conferito reale negli anni precedenti. L'esecuzione produrrà, per ogni isola di raccolta, il presunto conferibile mensile dell'isola.

Per utilizzare la previsione mensile, sulla Piattaforma sarà implementato un altro servizio applicativo che sarà eseguito automaticamente con cadenza giornaliera con il compito di calcolare il valore presunto del conferito nell'isola di raccolta alla data. Il valore presunto del conferito sarà confrontato con la capacità massima conferibile presso l'isola (calcolata tenendo conto del numero di contenitori presenti per la capacità del contenitore) e sarà inviata una eventuale segnalazione alla soluzione verticale per il Monitoraggio e Controllo del Territorio qualora il valore del presunto conferito sia molto vicino alla capacità massima conferibile dell'isola.

Ovviamente, il conferito realmente raccolto sarà poi utilizzato, come dato storico, per effettuare una nuova previsione del conferibile per il prossimo esercizio di gestione della raccolta dei rifiuti.

2.2. Trasporto su strada di Rifiuti Pericolosi

Gli incidenti stradali che coinvolgono veicoli adibiti al TMP possono causare significativi danni all'uomo e all'ambiente. Nonostante tali eventi incidentali siano caratterizzati da una bassa probabilità di accadimento, le gravi conseguenze di alcuni eventi verificatisi nella storia hanno sensibilizzato l'opinione pubblica e motivato le istituzioni ad interessarsi al fenomeno e disponendo specifiche norme che ne regolamentano tuttavia solo in parte lo svolgimento. I principali riferimenti normativi per la regolamentazione del trasporto terrestre di merci pericolose sono costituiti dall'ADR (Accord européen relatif au transport international des marchandises Dangereuses par Route), relativo al trasporto stradale, e dal RID (Règlement concernant le trasport International ferroviaire des merchandises Dangereuses), relativo al trasporto ferroviario. Tali accordi tuttavia si

limitano a disciplinare i trasporti di carichi pericolosi considerando esclusivamente le caratteristiche dei carichi stessi e dei contenitori, la tipologia e quantità di merci e i dispositivi e requisiti minimi di sicurezza a bordo dei veicoli. Al contrario nulla viene specificato in merito all'interazione tra il sistema veicolo – infrastruttura – ambiente.

Le conseguenze concrete di un tale approccio consistono nell'assenza di misure finalizzate alla mitigazione del rischio trasporti che possono giungere anche alla restrizione al passaggio di alcune sostanze pericolose in aree caratterizzate da elevata densità abitativa, in prossimità di luoghi sensibili e in zone con particolare vulnerabilità ambientale.

Il caso d'uso implementato prevede la realizzazione sulla Piattaforma Digital Future di un servizio per il Tracking del trasporto su gomma di merce pericolosa, ad esempio liquidi infiammabili ed inquinanti, attraverso il monitoraggio continuo dei parametri di viaggio: geo localizzazione puntuale del mezzo, velocità del mezzo e condizioni del carico trasportato.

Il caso d'uso prevede degli specifici dispositivi montati sui mezzi: in particolare, ogni veicolo dovrà essere munito di un ricevitore GPS per la rilevazione della posizione geografica e di un gateway con connettività 4G / 5G avente il compito sia di raccogliere dati dai sensori preposti al monitoraggio del carico trasportato e sia di trasmettere i dati raccolti verso la piattaforma Digital Future per essere ulteriormente elaborati. Tra i sensori per il monitoraggio del carico, si ipotizza l'uso di misuratori di temperatura e di pressione interna all'autobotte trasportata contenente liquidi inquinanti.

Il servizio applicativo che sarà realizzato sulla Piattaforma ha essenzialmente due finalità:

a. rapida ed efficiente raccolta e persistenza dei dati sui veicoli monitorati durante la esecuzione del trasporto;
b. rapida e puntuale comunicazione alla centrale operativa preposta al monitoraggio del trasporto, in questo caso la soluzione verticale per il

Monitoraggio e Controllo del Territorio, di situazioni anomale rilevate durante il trasporto:

- abbandono della rotta;
- attraversamento di aree urbane ad accesso vietato per la tipologia di carico trasportato;
- superamento della velocità massima consentita, grazie alla consultazione on line del servizio Nominatim ed Overpass di OpenStreet;
- coinvolgimento del veicolo in un incidente stradale o malfunzionamento dello stesso;
- allarmi generati a fronte della elaborazione dei dati provenienti dai sensori di monitoraggio del carico trasportato;

I dati raccolti, vedi punto a), potranno successivamente essere elaborati per fini statistici, ad esempio: Ricostruzione delle rotte e degli eventi, Analisi del conducente (guida), Analisi del carico trasportato, etc.

I dati prodotti dalle elaborazioni, allarmi e non, vedi punto b), potranno essere inviati alla centrale operativa di monitoraggio del trasporto, in modo tale da consentire ai suoi operatori di avere a disposizione il quadro complessivo della situazione durante il trasporto ed attuare le azioni del caso.

3. Monitoraggio Inquinamento Atmosferico

I problemi ambientali ed in particolar modo l'inquinamento sono argomenti di grande interesse ed attualità, di forte impatto nella vita sociale. Studi di monitoraggio e ricerche vengono condotti per quantificare l'ammontare di inquinanti immessi nell'ambiente, per individuare trend di lungo periodo, per valutare la loro conformità agli standard ambientali o a quelli relativi alle emissioni; altri studi si occupano invece di determinare come gli inquinanti si distribuiscono nell'aria, nell'acqua, sul suolo e nel sottosuolo, i loro tempi di persistenza e gli effetti sull'uomo e l'ambiente.

Lo stadio fondamentale per la conoscenza dei fenomeni d'inquinamento è costituito dalla rilevazione delle sostanze inquinanti. Le concentrazioni vengono misurate dalle reti di monitoraggio, ossia da un insieme di siti di misurazione coordinati e gestiti da un centro operativo in base a criteri omogenei, per i quali la messa in rete agevola la determinazione della variabilità spaziale delle concentrazioni ma anche, come nel caso dell'inquinamento atmosferico, di altri parametri metereologici e climatici quali direzione del vento, quantità di pioggia, umidità.

Secondo l'Organizzazione mondiale della sanità , oltre 5,5 milioni di persone in tutto il mondo muoiono ogni anno a causa dell'inquinamento atmosferico. Molte di queste morti si verificano nelle grandi città, dove i gas di scarico di automobili, fabbriche e centrali elettriche riempiono l'aria di particelle pericolose.

In risposta a una crescente preoccupazione per gli effetti dell'inquinamento atmosferico, molte città hanno migliorato i loro sforzi per misurare l'inquinamento utilizzando l'Internet of Things, reti di sensori collegate che raccolgono e inviano dati. Utilizzando questi dati, le città possono mappare le aree ad alto inquinamento, monitorare i cambiamenti nel tempo, identificare gli inquinanti e gli inquinatori infine analizzare i potenziali interventi.

Molte città hanno integrato sensori per mappare la qualità dell'aria nelle infrastrutture esistenti . In Puglia, ad esempio, l'ARPA ha implementato una rete di centraline per tracciare la presenza di un certo numero di inquinanti atmosferici, tra cui monossido di carbonio, biossido di azoto, ozono e particolato. I dati rilevati sono poi sia resi disponibili per consultazione sul portale ARPA e sia per essere letti da applicazioni attraverso delle specifiche API. Sfruttando queste informazioni messe a disposizione da ARPA Puglia, sulla piattaforma Digital Future saranno realizzati due servizi applicativi:

- Clustering Centraline ARPA e Generazione Allarmi
- Modello Qualità dell'aria e dispersione dell'Inquinamento a livello regionale

3.1. Clustering Centraline ARPA e Generazione Allarmi

Il servizio implementerà N cluster di dati geo-referenziati, relativi a qualità dell'aria e condizioni atmosferiche a partire dai dati provenienti dalle centraline gestite da ARPA Puglia. Il numero dei cluster che saranno prodotti a fronte della esecuzione dell'algoritmo sarà variabile in quanto la regola di produzione dei cluster dovrà tener conto del numero di centraline attive in quel momento e della distanza esistente tra di esse. L'obiettivo è fotografare, dal punto di vista degli inquinanti, porzioni abbastanza ampie del territorio, superando le informazioni specifiche provenienti dalle singole centraline, cercando di realizzare un clustering che sia abbastanza coesivo geometricamente, e che quindi dia una correlazione relativamente forte e significativa tra le centraline ARPA appartenenti ad ogni cluster.

Il servizio applicativo, quando è in esecuzione, eseguirà i seguenti passi:

1. Lettura dei dati di meteo e qualità dell'aria, relativi ad un periodo temporale antecedente di un'ora rispetto al tempo di esecuzione del servizio, dalla tabella del database di piattaforma DF ove essi sono persistiti a fronte della fase continua di ingestion.

2. Esecuzione di varie attività di data cleaning sui dati prelevati (verifica di integrità dei dati in base al significato fisico delle varie quantità, rimozione di outliers dovuti a sensori difettosi, etc).
3. Avendo derivato un dataset di punti rappresentanti le centraline e la loro distribuzione geografica, sarà effettuato il calcolo dinamico del numero di cluster in cui suddividere questo dataset, utilizzando il cosiddetto "*metodo del gomito*" (dall'inglese "*elbow method*"). Tale metodo consiste nel seguente procedimento:
    a. si itera sul numero di cluster k, incrementando questo valore di volta in volta a partire dal numero di cluster minimo (settato a due) e si effettua un nuovo clustering per ogni nuovo valore k;
    b. Il ciclo termina nel momento in cui la riduzione di inerzia (quantità legata alla varianza, il cui inverso dà una misura del grado di coesione di cui sopra) del clustering attuale rispetto a quello precedente risulta minore di un determinato *threshold*. In altre parole, in questo caso, l'aggiunta di un ulteriore cluster, rispetto al clustering precedente, non comporterebbe una riduzione di inerzia sufficientemente elevata: si prende quindi il numero di cluster precedente come quello ottimale.
4. Esecuzione del clustering finale delle centraline ARPA, utilizzando l'algoritmo K-MEANS. All'interno del ciclo del metodo del gomito del passo 3), si applica K-MEANS ad ogni iterazione (per k = 2, 3, …) fin quando non si trova quella ottimale quella che minimizza la varianza di ogni cluster. Essendo questa varianza funzione della distanza euclidea tra campioni e centroide del cluster, il risultato è una suddivisione che cerca di massimizzare il grado di coesione dei vari cluster.
5. Elaborazione delle informazioni relative ad ogni cluster, calcolando, per ognuno di essi, i valori medi delle variabili di interesse relative a qualità dell'aria e condizioni atmosferiche. Ad esempio:
    - IQA medio
    - Temperatura media

- Umidità relativa media
- Intensità Vento media
- Radiazione solare media
- Pressione media
- Precipitazioni medie

Questi valori potrebbero costituire uno stream di eventi da valutare attraverso due ulteriori servizi applicativi, al fine di produrre, per la zona a cui il cluster si riferisce:

a) allarmi di superamento soglie;
b) informazioni più dettagliate, ad esempio un modello puntuale di qualità dell'aria e dispersione di inquinamento, simile a quello prodotto dal servizio applicativo descritto nel paragrafo successivo, qualora i valori di IQA medio e di Ventosità media del cluster superassero determinate soglie.

La decisione su quale tipo di valutazione fare sui dati suddetti, ossia quale servizio applicativo realizzare ed eseguire tra i due elencati precedentemente nei punti a) e b), dipende dal contesto e dalla particolare situazione ambientale del momento. In certe situazioni potrebbe essere sufficiente sollevare semplici allarmi di superamento soglie, mentre in altre potrebbe essere necessario generare un modello puntuale di dispersione dell'inquinamento. Il servizio infrastrutturale messo a disposizione dalla piattaforma per la *Configurazione ed Esecuzione di Servizi di Analisi ed Elaborazione dati in Modalità Adattiva* consente all'analista del dominio di creare e mettere in esecuzione nel sistema, in maniera dinamica, algoritmi di analisi ed elaborazione a seconda della necessità e del contesto. Tali algoritmi, iniettati nel sistema senza dover interrompere il servizio di Monitoraggio, consentono di incrementare le funzionalità che la soluzione per il Monitoraggio e Controllo del Territorio può fornire.

6. I dati relativi ai cluster ed eventuali allarmi di superamento soglie potranno, pertanto, essere inviati:

- alla soluzione verticale per il Monitoraggio e Controllo del Territorio per essere geo localizzati su mappa con insight sui valori calcolati;
- al motore a regole della Reflective Architecture qualora si voglia eseguire, in maniera adattiva e a seconda del contesto, uno od entrambi i due servizi applicativi citati precedentemente ai punti a) e b).

3.2. Modello Qualità dell'Aria e Dispersione dell'Inquinamento

Il servizio effettuerà, utilizzando i dati caricati sulla piattaforma e provenienti da ogni singola centralina ARPA, una stima dell'indice di qualità dell'aria ("IQA", o "AQI" dal corrispettivo inglese "air quality index") su una data area geografica (nel nostro caso la regione Puglia qualora si considerassero tutte le centrale gestite dall'ARPA), in base a misurazioni sparse di concentrazioni di inquinanti e condizioni metereologiche. In particolare, le misurazioni di ventosità disponibili saranno interpolate su una griglia che si estende su tutta l'area di interesse, ottenendo un campo vettoriale bidimensionale definito sulla griglia stessa. Questo campo verrà poi utilizzato per stimare come le concentrazioni degli inquinanti suddetti vanno a distribuirsi nello spazio di interesse. Il risultato finale consisterà in una stima dell'IQA su tutta l'area geografica, rappresentata tramite una mappa di calore e visualizzata nel front-end della soluzione verticale per il Monitoraggio e Controllo del Territorio tramite uno shader grafico appositamente sviluppato.

Il servizio che sarà implementato sulla piattaforma, per ogni centralina ARPA per la quale si hanno dati sufficienti, provvederà a:

- generare il campo vettoriale del vento
- calcolare l'IQA

Lo shader grafico in openGL presente nella soluzione verticale si occuperà di incrociare opportunamente le due tipologie di informazioni e di generare la mappa di calore estesa a tutto il territorio di interesse.

3.2.1. *Campo Vettoriale di Ventosità*

Input: misurazioni sparse di ventosità (ogni campione è definito da intensità e direzione radiale del vento)

Output: stima del campo vettoriale di ventosità definito su una griglia regolare di punti

L'interpolazione, calcolata su questa griglia, sarà effettuata tramite una variante dell'algoritmo "K Nearest Neighbors" secondo cui, per ogni punto della griglia, si va a calcolare una media pesata delle K misurazioni di vento più vicine al punto stesso. I pesi di questa media sono dati dall'inverso della distanza geodetica tra il punto della griglia in questione e l'i-esimo *neighbor* nella media:

$$W(x,y) = \frac{\sum_i \left(\frac{W_{ni}}{dist(n_i)}\right)}{\sum_i \left(\frac{1}{dist(n_i)}\right)}$$

dove:

- *W(.)* è il vento stimato,
- *(x, y)* è un punto della griglia,
- *i=1…K*, essendo K il numero di neighbors,
- *dist(.)* è la distanza geodetica,
- n_i identifica l'i-esimo neighbor (tra tutti i campioni di vento disponibili) dal punto (x, y)
- w_{ni} è il valore del vento per l'i-esimo neighbor

Tale tecnica di interpolazione è una variante del classico algoritmo di interpolazione *Inverse Distance Weighting* [1] che limita l'influenza nel calcolo dei valori interpolati soltanto ai K campioni più vicini (piuttosto che utilizzare tutti i campioni disponibili). Questo porta ad un'interpolazione di carattere più locale, a costo di una complessità computazionale maggiore dovuta ad uno step di ordinamento in più, per ogni punto della griglia, necessario per la determinazione dei K *neighbors*.

3.2.2. *Calcolo dell'IQA*

Input: misurazioni di concentrazione di inquinanti (raggruppate per stazione)

Output: IQA per le stazioni nell'input (un valore di IQA per stazione)

Il calcolo dell'indice di qualità dell'aria verrà effettuato su base stazione.

Gli inquinanti presi in considerazione sono i seguenti:

- Particolato PM_{10}
- Particolato $PM_{2.5}$
- Diossido di Azoto (NO_2)
- Benzene (C_6H_6)
- Monossido di Carbonio (CO)
- Ozono (O_3)
- Diossido di Zolfo (SO_2)

Per ogni centralina ARPA, soltanto informazioni relative ad un sottoinsieme di questi inquinanti saranno disponibili in ogni determinato intervallo temporale.

L'IQA della stazione sarà, quindi, definito come il massimo (ovvero il peggiore) tra i valori di IQA relativi ai singoli inquinanti disponibili, dove l'IQA per singolo inquinante è dato dalla seguente formula:

(Sotto-)IQA = (Concentrazione Misurata / Limite di Legge) * 100

NB: ogni inquinante ha un suo valore di limite. [2]

Si noti inoltre che queste quantità non sono necessariamente concentrazioni istantanee, ma possono rappresentare medie in un certo intervallo di tempo, o valori massimi, etc. I dati ritornati alle API di interrogazione delle centraline ARPA sono già processati in modo tale da dare queste informazioni derivate, utilizzate poi per il calcolo diretto dell'IQA.

Il significato dell'indice di qualità dell'aria è riassunto dalla seguente tabella:

Valore dell'IQA (stazione, o singolo inquin.)	Classe di qualità dell'aria
0-33	OTTIMA
34-66	BUONA
67-99	DISCRETA
100-150	SCADENTE
>150	PESSIMA

3.2.3. *Generazione Mappa di Calore*

Input: Griglia del campo vettoriale di ventosità (vedi paragrafo 3.2.1), campioni sparsi di IQA su base stazione (vedi paragrafo 3.2.2)

Output: Mappa di calore IQA, definita come una superficie S(x, y) il cui valore in ogni dato punto fornisce una stima dell'IQA

I dati in input potranno essere incrociati tramite un modello Gaussiano ad N componenti, ognuna delle quali fa riferimento ad una stazione IQA. Ogni componente consiste in una Gaussiana la cui altezza massima è data dall'IQA della stazione in questione e il cui profilo è deformato punto per punto in funzione del campo vettoriale del vento - con l'obiettivo di simulare la dispersione degli inquinanti a causa di quest'ultimo. La superficie S(x, y) di stima sarà data, in ogni punto, dal massimo tra tutte le N componenti. Da un punto di vista matematico, ad alto livello, l'interazione IQA-Vento in ogni componente è definita dalla seguente formula:

$$G(x,y) = AQI_i \times f_s\big(G_u(x,y) + d_i(x,y)\big)$$

Dove il termine di distorsione è a sua volta dato da:

$$d_i(x,y) = M_c(x,y) \times |W(x,y)| \times \cos(\Delta\theta)$$

Infine, come già accennato, il valore della Mappa di Calore vale

$$S(x,y) = max\big(G_i(x,y), \dots, G_N(x,y)\big)$$

Al di la dei dettagli matematici, l'intuizione di base che questo modello vuole catturare è la dispersione degli inquinanti in funzione della geometria del vento e del posizionamento della centralina ARPA da cui dati l'IQA è stato calcolato, rispetto al campo vettoriale del vento. Si noti inoltre che, essendo le misurazioni di qualità dell'aria relativamente sparse, si è ritenuto opportuno associare una componente ad ogni centralina, piuttosto che utilizzare un algoritmo di tipo più granulare.

4. Monitoraggio Abbandono Rifiuti

Oggi sempre più spesso si sente parlare di *littering* ovvero dell'inquinamento di strade, piazze, parchi o mezzi di trasporto pubblici causato gettando intenzionalmente o lasciando cadere rifiuti e abbandonandoli. Questo fenomeno compromette la qualità di vita e il senso di sicurezza negli spazi pubblici, genera costi elevati per i servizi di pulizia e nuoce all'immagine delle località. Il *littering* dalle automobili che interessa alcuni tratti di strade urbane ed extra urbane è un fenomeno diffuso che comporta l'accumulo di rifiuti in aree difficilmente pulibili. A questi fenomeni si somma quello più circoscritto ma grave delle vere e proprie discariche abusive o incontrollate dove vengono abbandonati quantitativi ingenti di rifiuti soprattutto in aree periferiche e naturali.

I risultati dei processi d'innovazione tecnologica sviluppati negli ultimi anni consentono la realizzazione di soluzioni software che, utilizzando strumenti di computer vision e approcci di Machine Learning per l'image processing semantico, sono capaci di rilevare in automatico, senza il controllo di un operatore umano, il formarsi di una discarica a cielo aperto attraverso l'analisi dei video catturati da telecamere fisse e/o mobili poste nei luoghi a maggior rischio abbandono. Per mettere a punto il caso d'uso di monitoraggio rifiuti attraverso l'analisi in tempo reale dei video, sulla piattaforma Digital Future, utilizzando i servizi infrastrutturali disponibili, sarà realizzato un servizio applicativo in grado di:

- raccogliere i frame video entranti nella piattaforma;
- analizzare ogni frame, attraverso tecniche di deep learning, alla ricerca di presenza di rifiuti.

Ovviamente, propedeutico alla fase di analisi dei frame è il processo di addestramento e messa a punto del modello di riconoscimento rifiuti. Di seguito viene fornita una breve descrizione delle tecnologie e del processo da seguire per pervenire ad un modello ottimale da utilizzare nella realizzazione del servizio applicativo sulla piattaforma.

4.1. Computer Vision e modelli di riconoscimento oggetti

La Computer Vision è la branca dell'informatica che si occupa dell'analisi più o meno intelligente di immagini e video. Esempi applicativi della Computer Vision sono l'*Image Classification*, in cui si cerca di classificare immagini in base a un qualche criterio (ad esempio il tipo di oggetti contenuti nell'immagine stessa), il *Motion Tracking* (tracciamento di oggetti o landmark in video), l'*Optical Character Recognition* (lettura automatica di testi da immagini), o anche l'analisi automatica di scan a raggi-X per la diagnosi di specifiche malattie.

L'Object Detection, che è di interesse nella sua applicazione al riconoscimento di rifiuti, può considerarsi un'estensione dell'*Image Classification* in cui, oltre ad identificare la classe dell'oggetto saliente contenuto nell'immagine, si è interessati anche a localizzare quest'ultimo all'interno della stessa immagine tramite un *bounding box* – generalizzando inoltre all'identificazione di un numero arbitrario di oggetti, eventualmente di classi diverse. Si tratta di un problema relativamente complesso su cui il deep learning ha proliferato notevolmente negli ultimi anni.

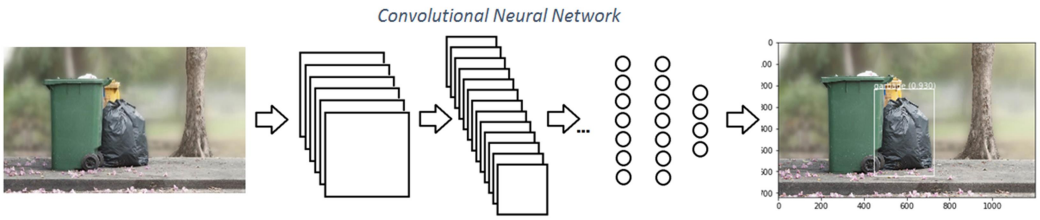

Figura 2: Object Detection

Il Deep Learning è la branca dell'intelligenza artificiale che si occupa dello studio di reti neurali profonde – ovvero reti che presentano livelli intermedi di neuroni tra quelli di input e quelli di output. Questi livelli aggiuntivi permettono alla rete neurale di apprendere rappresentazioni dell'input via via più astratte (da cui il termine *Representation Learning*), che permettono alla stessa di risolvere il proprio problema in

maniera più efficiente rispetto ad architetture *shallow* più tradizionali (EG: Logistic Regression, Support Vector Machines, etc). L'idea è quindi quella di apprendere una rappresentazione ad alto livello dello spazio di input che vada a semplificare il quanto più possibile il calcolo dell'output finale.

Come già accennato, le applicazioni del deep learning sono anche molto diverse tra di loro – dalla Computer Vision al Natural Language Processing, dalla regressione statistica alla sintesi di dati complessi. È naturale quindi che, insieme a questa varietà applicativa, i modelli che sono stati sviluppati per risolvere questi problemi sono equamente diversificati – da modelli ad unità logistiche, a modelli convoluzionali, a modelli ricorsivi e sequenziali, a modelli ibridi, alle GANs (*Generative Adversarial Networks*) – e così via.

Il caso dei modelli convoluzionali è particolarmente utile per quanto riguarda la Computer Vision, qui di interesse, in quanto tali modelli sono particolarmente efficienti nel processare input di tipo visivo, o comunque input che possiedono una forte caratterizzazione geometrica su cui poter applicare trasformazioni sparse e locali (quale è un filtro convoluzionale – elemento fondamentale delle *Convolutional Neural Networks*). Lo stato dell'arte attuale per il problema dell'Object Detection è costituito da vari modelli e architetture di deep learning, ognuno dei quali può presentare vari punti di forza, a seconda della metrica considerata. Nello scegliere un modello da utilizzare per un caso applicativo reale è dunque necessario prendere in considerazione tutti i fattori rilevanti del caso, in relazione ai vari vincoli pratici che si hanno.

Si è deciso, quindi, di utilizzare un modello YOLOv3, che ha come caratteristica principale il fatto di avere tempi di inferenza relativamente brevi (fattore importante per un caso applicativo real-time), mantenendo comunque livelli di accuratezza relativamente buoni.

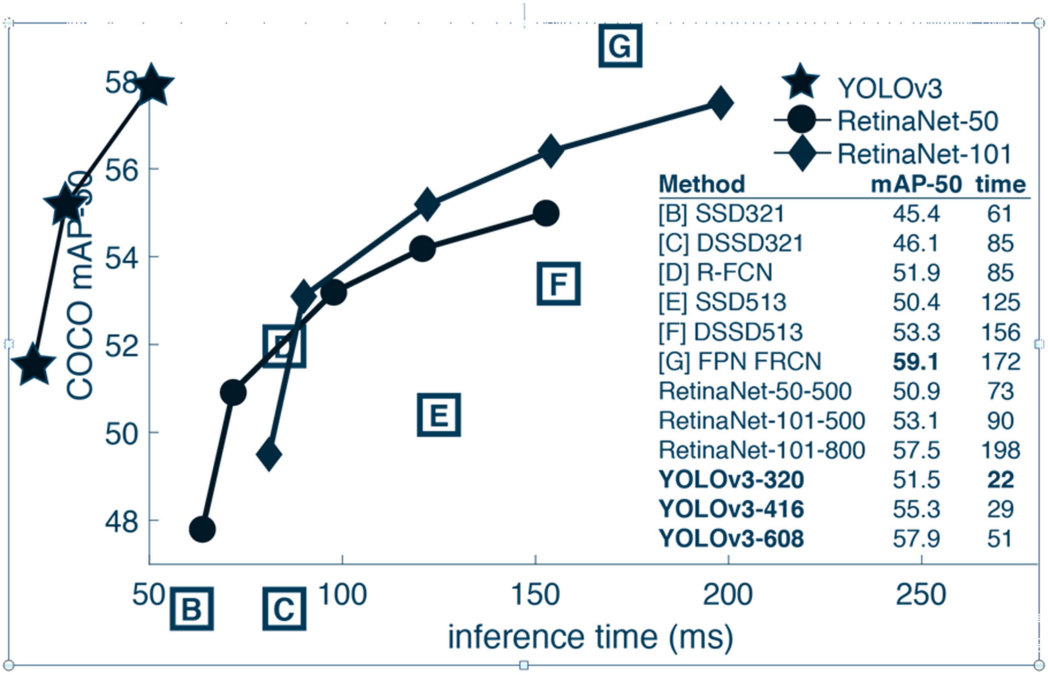

Figura 3: Modelli di object detection a confronto. Accuratezza contro tempi di inferenza [3]

4.1.1. *Messa a punto del Modello di Riconoscimento Rifiuti*

Nell'addestrare il modello di Garbage Detection si sfrutterà il principio del *Transfer Learning*, secondo il quale adattare un modello pre-addestrato su un problema A, ad un nuovo problema B, a patto che B sia abbastanza simile ad A, è un'operazione più semplice rispetto all'addestrare un modello per B partendo da zero (ovvero partendo da pesi pseudocasuali). Questo trade-off di complessità – ovvero lo spostare parte del computo dal problema B al problema A - si traduce poi in dataset di training di dimensioni minori per B, a parità di livello di accuratezza finale.

Riportando questo discorso al caso dell'Object Detection, dunque, se abbiamo a disposizione un modello addestrato su un qualche dataset di grosse dimensioni, è poi possibile adattare quest'ultimo a classi diverse di oggetti utilizzando un nuovo dataset di dimensioni relativamente ristrette (qualche migliaio di immagini per ogni classe, piuttosto che centinaia di migliaia di immagini). Questa differenza si rivela cruciale, in

pratica, per molti casi applicativi reali, per cui è spesso troppo oneroso accumulare dati in quantità che sarebbero necessarie se non si utilizzassero tecniche di transfer learning.

Il processo di addestramento del modello di Riconoscimento Rifiuti sarà, quindi, avviato a partire da una rete neurale pre-addestrata sul dataset COCO, contenente immagini e relative labels per la detection di 80 classi di oggetti, continuando poi il training su un dataset di Riconoscimento Rifiuti della dimensione di qualche migliaio di esempi.

Più esattamente, il dataset di Riconoscimento Rifiuti che è stato costruito contiene, nella sua versione finale:

- 3118 immagini, di cui:
    - 2155 (il 69%) esempi positivi, ovvero contenenti localizzazioni di rifiuti
    - 963 esempi negativi, ovvero non contenenti rifiuti

L'addestramento della rete neurale è stato effettuato utilizzando il software seguente:

https://github.com/AlexeyAB/darknet

compilato appositamente con CUDA 10.0 (https://developer.nvidia.com/cuda-zone) e CuDNN 7.6 (https://developer.nvidia.com/cudnn), per svolgere il training su GPU. Addestrare modelli di machine learning su GPU piuttosto che su CPU comporta in genere una notevole riduzione di tempi, a causa del fatto che calcoli su tensori (e questo genere di calcoli costituiscono i building block fondamentali del Deep Learning), sono tipicamente operazioni altamente parallelizzabili – quindi adatte ad una efficiente esecuzione su GPU.

Per il processo di training del modello di Garbage Detection è stata utilizzata una GPU Nvidia RTX2060, ottenendo tempi di addestramento di 8÷10 ore per sessione. Ecco riportate in breve le specifiche della scheda grafica:

1. Memory size: 6GB GDDR6
2. CUDA compute capability: 7.5
3. CUDA cores: 1920, Tensor cores: 240

Di seguito è riportato il grafico della *Loss Function* calcolata durante il processo di ottimizzazione, ovvero di apprendimento, per l'ultima sessione di addestramento:

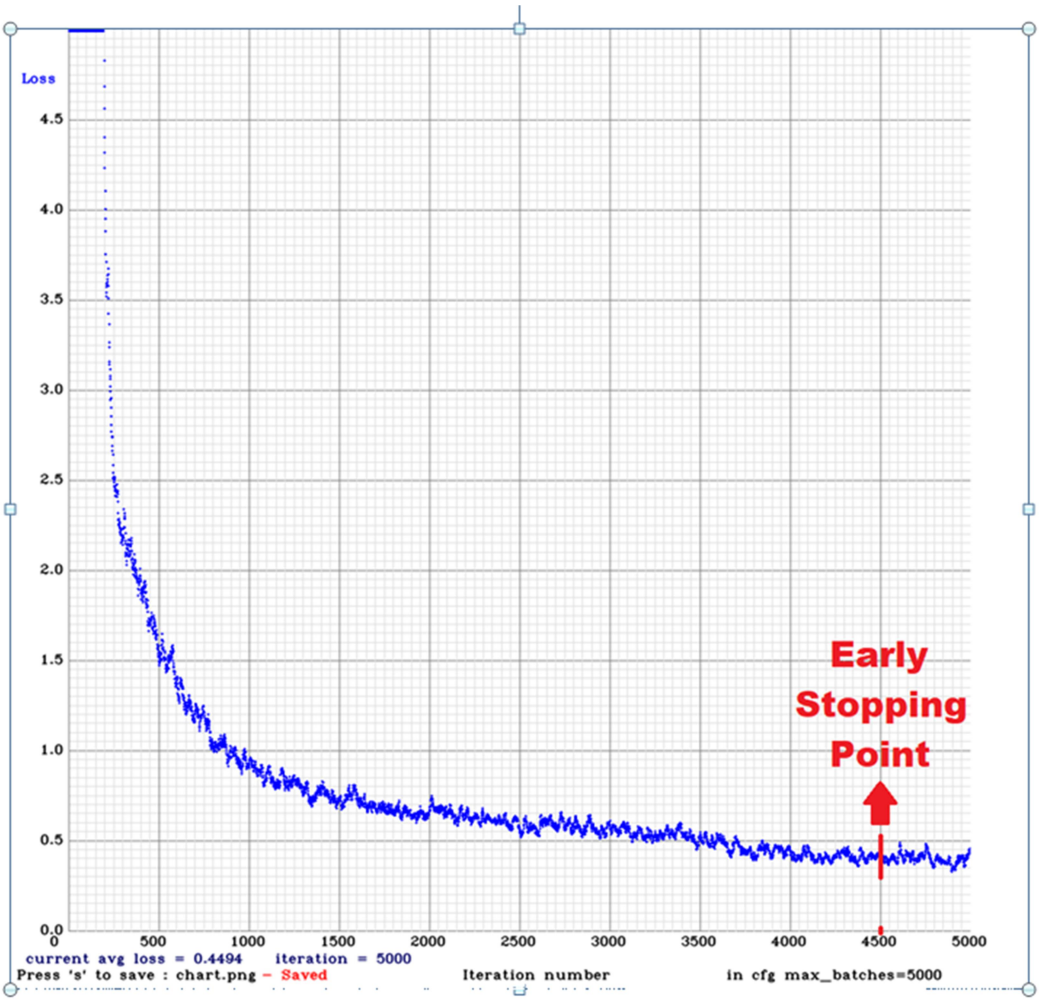

Figura 4: Addestramento Garbage Detection Yolov3 con AlexeyAB/Darknet

Si noti che la *Loss Function* (calcolata a livello di *mini-batches* di 64 immagini per iterazione), dà una misura della performance del modello rispetto al training set, che a sua volta è preso come misura della performance che lo stesso modello avrebbe su dati reali (ovvero dati osservati in fase di production), sotto le ipotesi seguenti:

1. Il training set è abbastanza rappresentativo della distribuzione di dati reali
2. Il modello non è in overfitting

Un modello si dice essere in overfitting se esso non è in grado di generalizzare ad esempi non facenti parte del training set, anche se la performance su quest'ultimo è buona.

Ogni modello sufficientemente complesso (rispetto ad un dato dataset) va in overfitting se si hanno tempi di training abbastanza prolungati.

L'underfitting, al contrario, identifica il caso in cui il modello sia sotto-addestrato rispetto ad un determinato dataset, ovvero il caso in cui esso non sia né in grado di modellare il dataset di training in misura abbastanza buona, né in grado di generalizzare a dati che non fanno parte del training set.

A seguito di uno studio su underfitting e overfitting del modello di Riconoscimento Rifiuti (eseguito utilizzando uno split training/dev di 91% contro 9% del dataset completo), si è scelto Il punto di ESP (Early Stopping Point) di 4500 iterazioni, con l'obbiettivo di limitare il fenomeno di overfitting.

4.1.2. *Conversione e Serving del Modello addestrato*

Una volta ottenuti i pesi addestrati del modello di Riconoscimento Rifiuti, sarà necessario convertire questi ultimi in un formato gestibile dal **framework Tensorflow Serving** installato in un apposito docker container della piattaforma Digital Future.

Questa conversione sarà effettuata istanziando l'architettura di YOLOv3 utilizzando costrutti di Tensorflow/Keras, e poi caricando i pesi addestrati all'interno di questa architettura, un livello alla volta. Oltre a ciò si è ritenuto opportuno aggiungere alcuni livelli di pre-processing e post-processing, in modo tale da snellire l'interfaccia di Input/Output del modello che sarà utilizzato (serving) in real time.

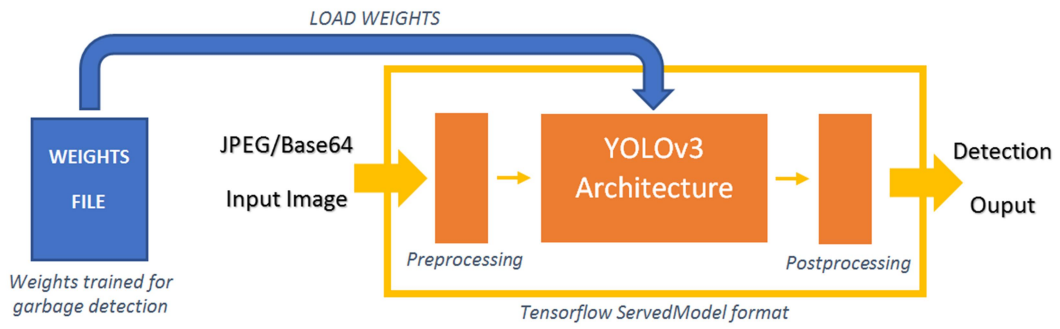

Figura 5: Conversione del Modello Addestrato per essere utilizzato a run time dal servizio applicativo di Riconoscimento Rifiuti

I compiti che saranno effettuati dai livelli aggiuntivi di pre e post processing sono i seguenti:

- Pre-Processing:
  1. Conversione JPEG/base64 -> tensore RGB
  2. Ridimensionamento del tensore alla risoluzione 416x416 (dimensione input YOLOv3)
  3. Normalizzazione dei valori RGB all'intervallo [0, 1]
- Post-Processing:
  1. Decodifica dei 3 tensori di output del modello YOLOv3 tramite NMP (Non Max Suppression)
  2. Riformattazione del tensore così ottenuto secondo il formato desiderato

L'introduzione di questi livelli porta non solo una riduzione notevole di lavoro da parte di chi utilizza il modello – in quanto esso non deve preoccuparsi di manipolare l'immagine di input o di decodificare i tensori di output del modello YOLO (operazione affatto triviale) – ma anche una riduzione del flusso di dati in input ed output della Piattaforma Digital Future, consentendo quindi **lag di trasmissione** dati molto minori, una volta che questo verrà utilizzato a run time. In particolare per l'output, si passa da dimensioni dell'ordine del megabyte a dimensioni dell'ordine del kilobyte, per ogni frame processato.

Il modello convertito sarà accessibile attraverso un endpoint REST su cui poter effettuare chiamate di inferenza e da cui ottenere risultati.

4.2. Servizio di Real Time Video Stream Processing

Di seguito è riportato un diagramma architetturale della pipeline di video streaming processing che sarà implementata sulla piattaforma Digital Future per riconoscere la presenza di rifiuti attraverso video catturati da telecamera.

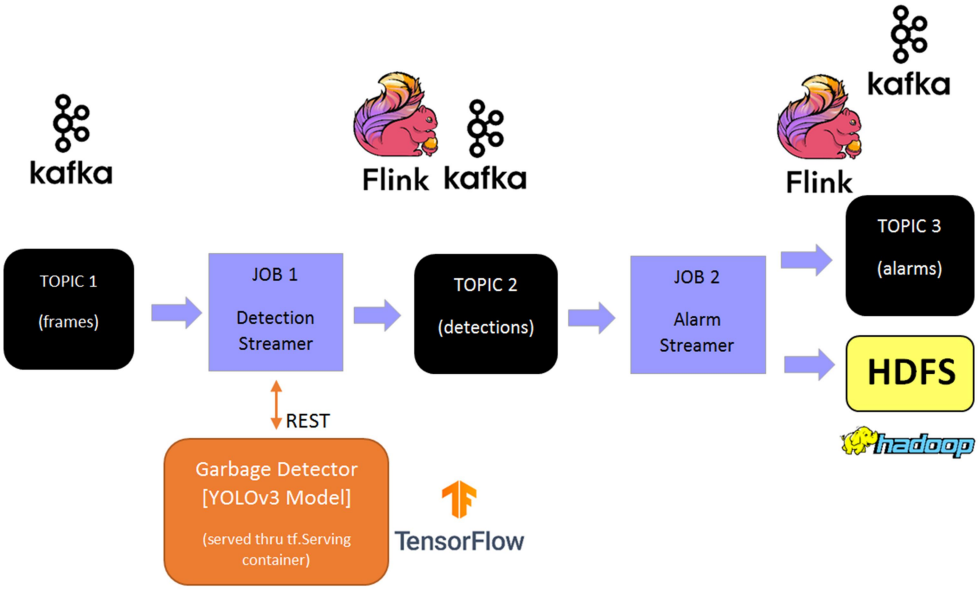

Figura 6: Pipeline Riconoscimento Rifiuti implementata sulla Piattaforma Digital Future

Come si può evincere dal diagramma, la pipeline utilizzerà alcuni servizi infrastrutturali della Piattaforma Digital Future che poggiano sui seguenti framework:

- KAFKA per il transito dei frame video, dei risultati della Detection e degli Allarmi a fronte della individuazione di rifiuti;
- TENSORFLOW per il serving di algoritmi di Machine Learning, in questo caso del modello addestrato per il Riconoscimento Rifiuti;
- FLINK per lo stream processing dei frame video attraverso l'interrogazione del modello suddetto;
- HDFS, file system distribuito, per la conservazione dei frame video interessati dalla presenza di rifiuti.

Per quanto riguarda lo Stream Processing, saranno realizzati due job separati poiché questi hanno ruoli logicamente diversi:

- il primo, il *detection streamer*, dovrà effettuare le chiamate di inferenza attivando (acting) il modello addestrato per ogni frame video proveniente dalle telecamere attive;
- il secondo, l'*alarm streamer*, dovrà effettuare un'analisi di più alto livello sulle detection rilevate, generando allarmi in funzione di riconoscimenti distribuiti su scale temporali relativamente estese.

4.2.1. *Detection Streamer*

Il compito principale di questo job sarà quello di allocare il modello addestrato alle telecamere attive in ogni dato intervallo temporale. Questa allocazione è quindi dinamica, nel senso che alcune telecamere possono essere più attive di altre in momenti diversi. Di conseguenza si vuole che il modello venga allocato alle varie telecamere in funzione di quali sono attive e, a queste ultime, in maniera bilanciata.

Per fare questo, il job manterrà in memoria una coda di CameraIDs (ognuno dei quali identifica una telecamera), il cui ordine è l'ordine di serving delle telecamere stesse. Si potrà, quindi, utilizzare questa struttura dati per identificare la telecamera con priorità massima fra tutte quelle attualmente attive: la priorità è massima per la telecamera servita il meno recentemente fra tutte quelle attualmente attive.

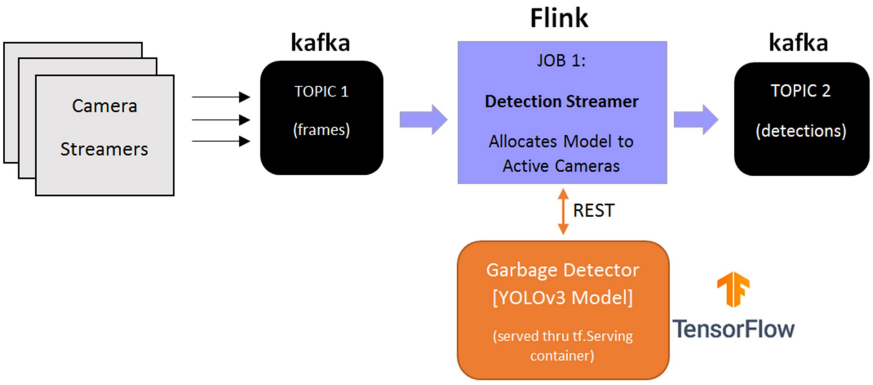

Figura 7: Schema del Job Flink che effettua il Detection Streamer

Di seguito viene fornito il pseudocodice dell'algoritmo che sarà implementato nel *Detection Streamer* (ogni freccetta identifica un Flink Streaming Operator):

- Keep track of a queue of camera IDs (in serving order): cameraQueue
- *SOURCE*: Kafka Consumer (topic: camera_v1_events)
  - ➔ frames [Flink DataStream]
  - ➔ filter(): filter out messages that don't conform to the required JSON schema
  - ➔ assign timestamps (for Event Time handling)
  - ➔ map(): map to <cameraID, message>
  - ➔ tumbling time window of DETECTION_INFERENCE_TIME (1.5 seconds)
  - ➔ apply():
    - Iterate throught the messages, find the one relative to the camera that was served the least recently (or, if you find a message from a camera that hasn't been served yet, take that one and break): cameraToServe
    - Remove cameraToServe's ID from cameraQueue, if present (NB: not necessarily at the head)
    - Enforce cameraQueue's max capacity by removing from the head as needed
    - Add cameraToServe's ID to cameraQueue's tail
    - Collect/propagate cameraToServe's message
  - ➔ flatMap(): perform inference call via REST to served model, format output message
  - ➔ *SINK*: Kafka Producer (topic: camera_v1_detections)

Questo job andrà, quindi, a suddividere i frame provenienti dal topic di input in base a intervalli temporali contigui di dimensione DETECTION_INFERENCE_TIME, ed attiverà il

modello, per ogni slot di tempo, alla telecamera di priorità massima tra quelle attive nello stesso slot. Ad ogni allocazione (acting) del modello verrà anche aggiornata la struttura dati che codifica la priorità delle telecamere, ovvero cameraQueue (la telecamera appena servita verrà posizionata in tail).

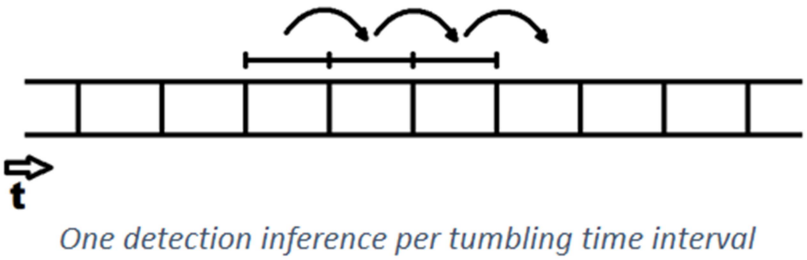

Figura 8: Tumbling Time Windowing

4.2.2. *Alarm Streamer*

Avendo a disposizione una sorgente di frame e relativi risultati (metadati) di *Riconoscimento Rifiuti*, l'*Alarm Streamer* avrà, quindi, il compito di generare allarmi di rilevazione di rifiuti, nel caso in cui le detection relative ad una data videocamera sono in numero ed estensione temporale sufficiente. In particolare, l'algoritmo sarà costituito da due step consecutivi:

A. Rilevamento di picchi di detection, tramite media mobile esponenziale e thresholding
B. Rilevamento di persistenza, tramite analisi temporale

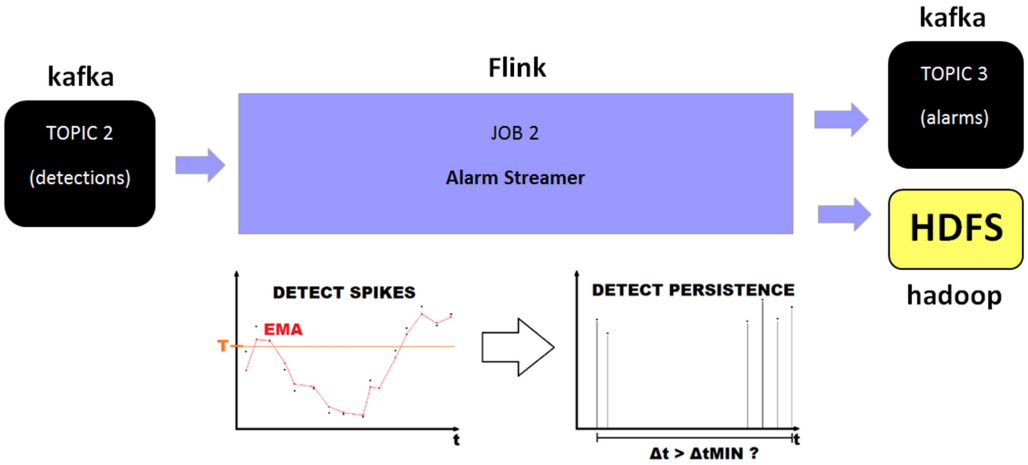

$$EMA_i = \alpha(EMA_{i-1}) + (1-\alpha)d_i$$

$$\alpha \in [0,1]$$

Figura 9: Schema del Job Flink che effettua l'Alarm Streamer

La media esponenziale fungerà da filtro passa-basso, rimuovendo parte del rumore insito negli output di detection. Si otterrà, inoltre una sorta di effetto di accumulazione, per cui la rilevazione di un picco avverrà soltanto nel caso in cui le ultime detection passate siano in numero e di *confidence* abbastanza elevati.

Si noti inoltre che nel calcolo dell'EMA (media mobile esponenziale), nel caso in cui un dato frame contenga più di un oggetto rilevato, si considererà l'oggetto cui è associato il massimo valore di *detection confidence*.

Nel momento in cui sarà stata rilevata una condizione di allarme da parte dello stadio di *persistence detection,* verranno selezionati i frame da associare al suddetto allarme tramite gli indici:

$$i \in \{floor(j * \Delta) \mid j = 0, \dots, n-1\}, \text{ dove}$$

$$\Delta = \frac{N-1}{n-1}$$

Essendo N il numero di frame totali di spike, e n il numero di frame massimi desiderati. Nel caso in cui $N \leq n$ la suddetta riduzione non sarà necessaria e verranno propagati tutti i frame disponibili per l'allarme.

Di seguito viene fornito il pseudocodice dell'algoritmo che sarà implementato nel *Alarm Streamer*:

- *SOURCE*: Kafka Consumer (topic: camera_v1_detections)
  - ➔ Detections [Flink DataStream]
  - ➔ filter(): filter out messages that don't conform to the required JSON schema
  - ➔ assign timestamps (for Event Time handling)
  - ➔ map(): map to <cameraID, message>
  - ➔ keyBy(): key by cameraID
  - ➔ sliding time window, defined by LENGHT (eg: 10 minutes) and SLIDING_TIME (eg: 5 minutes)
  - ➔ apply(): iterate over messages
    - detect spikes from exponential moving average
    - detect long-term persistence from these spikes
  - ➔ semiOut [DataStream]

- semiOut
  - ➔ map(): format output message
  - ➔ *SINK*: Kafka Producer (topic: mcs_tenant_rifiuti_results)
- semiOut
  - ➔ flatMap(): save selected frames to HDFS

Questo job andrà, quindi, a suddividere lo stream delle detection di input per chiave, ovvero per cameraID, e poi sul KeyedStream ottenuto andrà ad applicare un operatore di Sliding Time Window, in base al quale effettuare l'analisi temporale. Per ogni intervallo temporale si eseguiranno gli stadi di spike detection, persistence detection e, nel caso in cui sia necessario, di riduzione di frame, generando elementi di allarme nel DataStream intermedio semiOut. A partire da quest'ultimo, gli allarmi verranno formattati in messaggi JSON opportuni, per essere inviati al topic kafka di uscita; i frame dell'allarme verranno salvati su HDFS.

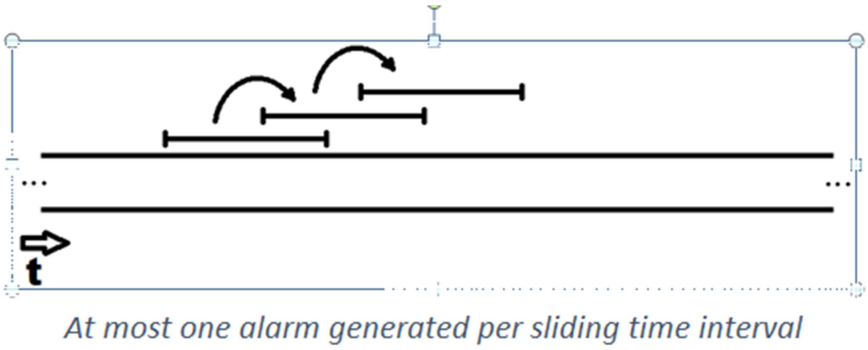

Figura 10: Sliding Time Windowing

5. Monitoraggio Fenomeni Ambientali tramite tecniche OSINT

La condivisione di informazioni in rete è ormai una realtà quotidiana e consolidata. Nel corso degli ultimi anni i Social Media (SM), ovvero quelle piattaforme web che consentono la creazione e lo scambio di contenuti generati dagli utenti (User Generated Content), hanno rappresentato un fondamentale cambiamento nel modo di comunicare delle persone e delle aziende, diventando a tutti gli effetti nuovi vettori per la diffusione dell'informazione e ampliando le possibilità di interazione tra soggetti.

In questo senso nei SM ha avuto luogo una vera e propria democratizzazione dell'informazione e le persone si sono trasformate da fruitori di contenuti ad editori.

Le piattaforme di Social Media costituiscono la base ideale per tutte le analisi incentrate sull'utilizzo dell'individuo come generatore di informazioni.

Questa branca di studi prende il nome di Social Sensing e si basa sul concetto che comunità o gruppi di persone possano fornire ognuna un insieme di informazioni, simili a quelle ricavabili da un singolo sensore, tali da generare nel complesso un'adeguata conoscenza su uno o più temi specifici. Gli utenti dei SM possono quindi essere visti come veri e propri sensori in grado di fornire tempestive informazioni riguardo a particolari tematiche.

Tra i vari ambiti di studio relativi al Social Sensing vi è quello relativo all'Emergency Management. Questo tema è di chiaro interesse per una molteplicità di soggetti che hanno la possibilità di raccogliere informazioni aggiornate su emergenti situazioni di pericolo, con lo scopo di acquisire una maggiore consapevolezza dello scenario creatosi, la possibilità di allertare gli interessati tempestivamente o verificare informazioni ottenute attraverso altri canali. Le informazioni su un evento in corso sono tanto più importanti quanto più tempestivamente vengono raccolte. Acquisire informazioni rapidamente lascia più tempo per prendere decisioni corrette riguardo la situazione da

affrontare e consente di allertare in anticipo la popolazione interessata contribuendo ad una migliore gestione dell'emergenza stessa.

Uno degli obiettivi del Pillar Monitoraggio e Controllo del Territorio è raccogliere ed analizzare segnalazioni riguardanti fenomeni che destano allarme o pericolo sociale, come ad esempio: incidenti, disastri o calamità naturali, sia di piccola che di larga scala. L'attività di raccolta di informazioni presenti su diverse fonti di pubblico accesso viene detta **OSINT**. Utilizza diverse fonti di informazione, tra cui:

- Siti web di notizie o blog
- Feed RSS
- Motori di ricerca, dai più comuni ai meno famosi
- Social network

È bene ricordare che è un'attività ben diversa dalla semplice ricerca, poiché ha lo scopo finale di creare una specifica conoscenza di un target ben preciso.

EUROPEAN COMMISSION
Joint Research Centre

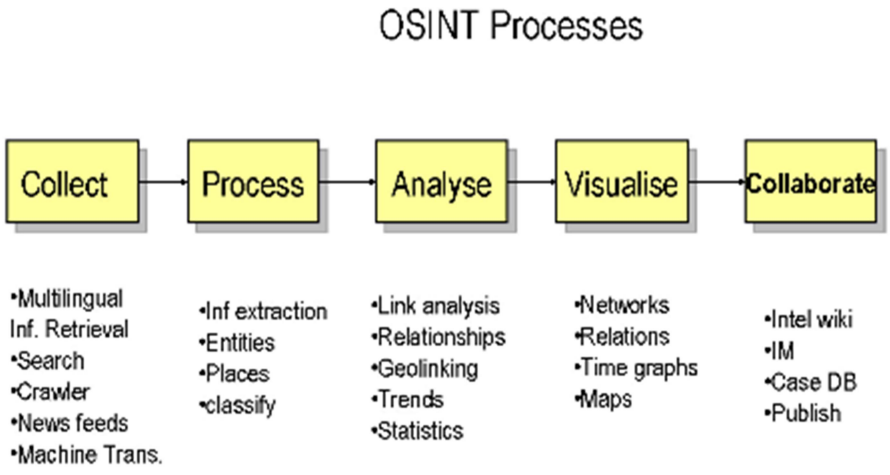

5.1. Servizio Applicativo di Calamity Detection

Sulla piattaforma Digital Future, sfruttando i servizi infrastrutturali messi a disposizione, come il Semantic Layer e lo Stream Processing Layer, sarà implementato un servizio applicativo di **Calamity Detection**, ovvero un servizio in grado di catturare eventi che destano preoccupazione sociale da più fonti pubbliche. Un servizio di Calamity Detection è generalmente costituito da sensori, componenti per l'individuazione di eventi, decisori e componenti per l'invio di notifiche, ed è in grado di garantire al sistema di risposta, la soluzione verticale per il monitoraggio e controllo, il tempo necessario a preparare risorse ed azioni per minimizzare l'impatto dell'evento.

Il servizio che sarà allestito sulla piattaforma si compone dei seguenti moduli:

- **Data Acquisition**: si occupa della raccolta e del salvataggio dei dati.
- **Event Detection**: a partire dai dati raccolti è in grado di individuare l'insorgere di un nuovo evento.
- **Early Warning**: si occupa di pubblicare la notizia della rilevazione di un evento e le informazioni ad esso associate.

5.1.1. *Data Acquisition*

E' uno dei componenti più importanti dell'intero servizio perché gli altri moduli utilizzano i dati raccolti in questa fase. Le conseguenze del processo di raccolta dei dati si ripercuotono su tutte le altre fasi dell'elaborazione, per questo è importante cercare di limitare al minimo gli errori in questa fase; inoltre, data la natura real-time dello studio da effettuare, i dati persi non possono essere recuperati.

Il modulo di Data Acquisition non è dipendente da una piattaforma o canale specifico; vengono utilizzati differenti *connettori* di raccolta dati in parallelo, ognuno relativo ad un diverso canale. Ad ogni modo è indispensabile che i dati raccolti siano memorizzati tutti con lo stesso formato: l'origine dei dati deve quindi essere trasparente per il modulo di Event Detection che deve poter eseguire le sue elaborazioni indipendentemente dal canale da cui provengono i dati. La tipologia di connettori che potranno essere gestiti è

alquanto variegata. In prima battuta, si è ipotizzato che il servizio di Calamity Detection possa ascoltare i seguenti canali informativi:

- http://www.meteoam.it/avvisi.xml
- http://www.meteoam.it/notizie.xml
- http://www.regione.lazio.it/rl_protezione_civile/rss/generatoreRssBollettiniCriticitaProtezioneCivile.xml
- http://www.regione.lazio.it/rl_protezione_civile/rss/generatoreRssBollettiniVigilanzaProtezioneCivile.xml
- http://www.regione.lazio.it/rl_protezione_civile/rss/generatoreRssAvvisiCriticitaProtezioneCivile.xml
- http://www.regione.lazio.it/rl_protezione_civile/rss/generatoreRssAllertamentoProtezioneCivile.xml
- https://www.protezionecivile.puglia.it/feed/?cat=42
- https://www.protezionecivile.puglia.it/feed/?cat=14
- https://www.protezionecivile.puglia.it/feed/?cat=15
- https://www.protezionecivile.puglia.it/feed/?cat=17
- https://www.protezionecivile.puglia.it/feed/?cat=6
- https://www.protezionecivile.puglia.it/feed/?cat=5
- google dork
- Canale Twitter: Dipartimento Protezione Civile
- Canale Twitter: Istituto Nazionale di Geofisica e Vulcanologia: Ambiente
- Canale Twitter: Istituto Nazionale di Geofisica e Vulcanologia: Terremoti

Dal punto di vista operativo il problema della raccolta dati da un canale si articola su due punti principali:

- la scelta delle keywords da cercare
- l'utilizzo dell'interfaccia messa a disposizione dal canale per la raccolta vera e propria dei dati

Idealmente l'obiettivo della fase di raccolta dati dovrebbe essere quello di raccogliere ed immagazzinare nel minor tempo possibile solo ed esclusivamente quei messaggi che si riferiscono ad eventi in corso (del tipo cercato), scartando tutti gli altri. In questo modo si limiterebbe al minimo l'utilizzo delle risorse e si fornirebbero dati completi ed attendibili al modulo di Event Detection. Migliore è la fase di raccolta dati e più facile risulta l'individuazione di un evento da parte del modulo di Event Detection.

Allo scopo di filtrare la moltitudine di messaggi prodotti sui canali sui quali si è in ascolto e raccogliere solo quelli di effettivo interesse, è necessario individuare delle keywords, vale a dire dei termini 'chiave' per gli eventi cercati. Una buona keyword dovrebbe essere un termine non ambiguo, utilizzato molto spesso dagli utenti per parlare dell'evento cercato. Il nome dell'evento ed i suoi sinonimi (ad esempio: terremoto, sisma) rappresentano in generale un buon punto di partenza per la ricerca delle keywords migliori. Ad un evento possono essere associate una o più keywords: questo dipende fondamentalmente dal modo in cui le persone parlano dell'evento e le keywords migliori per un evento non dipendono solo dall'evento cercato, ma sono anche influenzate da fenomeni linguistici e culturali.

5.1.2. *Event Detection*

Il componente di Event Detection rappresenta il cuore del servizio dal momento che lo scopo del lavoro è proprio quello di identificare emergenti situazioni di pericolo. Il componente che realizza l'Event Detection deve quindi essere in grado di rilevare il verificarsi di un evento a partire dai messaggi che gli arrivano dal componente di raccolta dati. Poiché il funzionamento dell'intero servizio è valutato principalmente in base agli eventi correttamente individuati, si comprende quale importanza rivesta questo modulo per l'architettura di un servizio di Calamity Detection.

L'identificazione degli eventi avviene sulla base dei dati che viaggiano sul canale o sui canali monitorati. I messaggi/testi che viaggiano sui canali vengono raccolti perché contenenti particolari keywords e quindi perché ritenuti potenzialmente pertinenti per

gli eventi da individuare. Il modulo di Information Extraction, con un approccio misto basato su tecniche di Machine Learning e Regular Expression, riconosce keyword come:

- Luoghi geografici (comuni, città, regioni, nazioni, etc.)
- Date
- Indirizzi
- terremoto
- terremoti
- sisma
- movimento tellurico
- movimenti tellurici
- scossa tellurica
- scosse telluriche
- moto tellurico
- moti tellurici
- sismicità
- maremoto
- maremoti
- moto ondoso
- moti ondosi
- nevicata
- nevicate
- neve
- bufera di neve
- bufere di neve
- esondazione
- inondazione
- saette
- fulmini
- tempesta di fulmini
- tempeste di fulmini
- grandinata
- grandinate
- grandine
- nubifragio
- nubifragi
- lava
- vulcano
- eruzione
- eruzioni
- tempesta geomagnetica
- tempeste geomagnetiche

- tempesta solare
- tempeste solari
- esplosione
- esplosioni

I canali, tuttavia, sono affetti da una forma di rumore: non tutti i messaggi con una determinata keyword parlano effettivamente di un evento in corso. Generalmente ci sono due differenti fonti di rumore nei messaggi raccolti: messaggi in cui la keyword viene utilizzata con significato diverso da quello che assume per l'evento cercato e messaggi in cui la keyword si riferisce effettivamente al tipo di evento cercato, ma non ad un evento in corso. Questi messaggi vanno scartati perché non forniscono informazioni utili all'individuazione di un evento. Per questo motivo è indispensabile prevedere dei meccanismi di filtraggio dei dati volti all'abbattimento del rumore in ingresso al componente che individua gli eventi. Minore sarà il rumore residuo, più semplice sarà il compito di individuazione degli eventi e, di conseguenza, migliori saranno le performance del servizio.

Il modulo di Event Detection si baserà sul Semantic Layer messo a disposizione dalla piattaforma Digital Future. L'approccio più semplice per estrarre informazioni dai testi dei canali ed eseguire quindi un'analisi semantica è basato sul conteggio dei termini. E' possibile eliminare le *stopwords,* termini che compaiono molto frequentemente in un linguaggio e che non aggiungono contenuto informativo come ad esempio gli articoli e le congiunzioni, e contare le occorrenze dei termini che compaiono nel corpus dei messaggi associati ad un evento. Contando le occorrenze dei termini emergeranno quelli più utilizzati e quindi maggiormente legati all'evento.

5.1.3. *Early Warning*

Una volta individuati gli eventi ed estratte più informazioni possibili su di essi, queste informazioni vengono comunicate ai soggetti interessati. Nello specifico, le informazioni saranno ritornate alla soluzione verticale per il Monitoraggio e Controllo incapsulati in appositi messaggi che viaggeranno come stream di eventi negli appositi canali messi a disposizione dalla piattaforma Digital Future. Le informazioni, opportunamente geo

localizzate saranno visualizzate su mappe geografiche consentendo all'utente finale di poterne analizzare il contenuto.

6. Conclusione

I servizi implementati sulla piattaforma Digital Future dimostrano che la stessa è uno strumento essenziale nelle attività di analisi dei dati nell'ambito del Monitoraggio e Controllo del Territorio.

La capacità della Piattaforma di fare *ingestion* e *processing* di dati in modalità real time (dati provenienti da sensori) e attraverso file .csv (caricati direttamente dall'utente), indipendentemente dalla loro natura (dati strutturati, testi e video), rappresenta un valore aggiunto per il processo di monitoraggio ambientale poiché consente di catturare e portare all'attenzione dell'utente finale informazioni utili per il decoro e salvaguardia dell'ambiente e del territorio.

7. Bibliografia e Sitografia

[1] "A two-dimensional interpolation function for irregularly-spaced data", Donald Shepard, 1968

[2] IQA e limiti di soglia da ARPA Puglia

https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=4&cad=rja&uact=8&ved=2ahUKEwjdi5TJ4rXnAhXLsKQKHVjzAdcQFjADegQICRAB&url=http%3A%2F%2Fwww.arpa.puglia.it%2Fc%2Fdocument_library%2Fget_file%3Fuuid%3D91777cce-f032-42f2-8d8e-4fce68409383%26groupId%3D13879&usg=AOvVaw3Ra1_1R1DDpnhk-hHrID86

[3] YOLOv3: An Incremental Improvement, Redmond Joseph and Farhadi Ali, arXiv, 2018