

INTEGRAZIONE DI CITIZEN SCIENCE E MONITORAGGIO STRUMENTALE PER IL RICONOSCIMENTO DELLE CLASSI ODORIGENE NELLE VICINANZE DI UN IMPIANTO DI DEPURAZIONE

Federico Cangialosi^{1,*}, Edoardo Bruno¹, Antonio Fornaro²

¹Tecnologia e Ambiente (T&A), Putignano (BA), Italia

²Labservice Analytica. Anzola Dell'Emilia (BO), Italia

Sommario

Le emissioni odorigene sono fonti di disturbo alla popolazione residente molto complessi da caratterizzare efficacemente con i protocolli di monitoraggio che sono oggi applicati per i comuni parametri ambientali. L'estrema complessità risiede nell'elevata dinamicità del fenomeno, legata agli agenti di dispersione atmosferica e all'orografia del territorio, la presenza di composti caratterizzati da una bassissima soglia di percezione che richiedono strumenti analitici molto sensibili per l'identificazione in real-time. Per tale ragione, si sta sempre più diffondendo l'utilizzo di *instrumental odor monitoring systems (IOMS)* come sistemi che integrano una sezione di monitoraggio strumentale con diversi sensori ed una sezione di calcolo che, partendo dai segnali ricevuti dai sensori, applica degli algoritmi per la determinazione della tipologia o concentrazione dell'odore. Nel contesto delle molestie olfattive si inserisce anche il contributo dei cittadini stessi, i quali, come già diversi studi hanno dimostrato, possono costituire uno dei fattori determinanti per il controllo dell'ambiente: la *citizen science* è oggi considerata un'arma in più per la gestione intelligente del monitoraggio ambientale, in grado di effettuare un'analisi approfondita del problema inquinamento. In questo articolo viene presentato uno studio di monitoraggio in continuo degli odori al confine di un impianto di depurazione di acque reflue urbane, integrando il monitoraggio strumentale con IOMS e le segnalazioni dei cittadini. È stata inizialmente svolta un'attività di addestramento in campo dello IOMS, utilizzando algoritmi di classificazione e di quantificazione degli odori ottenuti tramite moderne tecniche di *machine learning*, quali le reti neurali e la

random forest al fine di ottenere un sistema in grado di riconoscere in automatico sia la tipologia dell'odore che la sua intensità. Successivamente, si è fatto ricorso alla *citizen science* raccogliendo ed analizzando le segnalazioni di cattivi odori effettuate dai cittadini, che avevano a disposizione una App per il monitoraggio delle molestie olfattive: l'App era strutturata in modo tale che i cittadini potessero inserire tipologia ed intensità dell'odore che rilevavano, associando ad ogni segnalazione la posizione, il tempo ed i dati meteo. È stato condotto tale monitoraggio in un lasso di tempo della durata di 5 mesi, per poi incrociare i dati ottenuti dagli algoritmi con le segnalazioni dei cittadini. In un primo momento si è provveduto ad un'analisi dei risultati degli algoritmi dello IOMS addestrato, al fine di individuare le classi di odori più frequenti. Successivamente, sono stati incrociati i risultati dello IOMS con le segnalazioni e con i dati del meteo, al fine di verificare se le segnalazioni fossero collegate o meno all'impianto. La descrizione degli odori percepiti dalla popolazione, presente su ogni segnalazione, unitamente all'individuazione del giusto cono di vento di influenza dell'impianto sulla città, ha permesso di isolare gli avvenimenti che evidenziavano un'effettiva correlazione con i trend emissivi dell'impianto. I risultati ottenuti da entrambe le elaborazioni di dati sono quindi risultati utili per stabilire il contributo reale dell'impianto monitorato rispetto alla totalità degli eventi registrati di disturbo olfattivo percepiti dai cittadini.

Parole chiave: *IOMS, machine learning, classificazione odori, quantificazione odori, citizen science.*

INTEGRATING CITIZEN SCIENCE AND INSTRUMENTAL MONITORING FOR THE RECOGNITION OF ODOR CLASSES NEARBY A WASTEWATER TREATMENT PLANT

Abstract

Odor emissions are very complex sources of annoyance to the resident population to be effectively characterized with the monitoring protocols currently applied for common environmental parameters. The extreme complexity lies both in the high temporal variability of the odour perception, related to atmospheric dispersion and the orography of the territory and the presence of compounds characterized by a very low odor threshold that require very sensitive analytical tools for real-time identification. For such reason, the use of instrumental odor monitoring systems (IOMS) is becoming more and more widespread as systems that integrate an instrumental monitoring section with different sensors and a software section that applies algorithms to determine the type or concentration of the odor starting from the signals received from the sensors. In the context of odor nuisances there is also the contribution of citizens, who can be a determining factor for the control of the environment: citizen science is today considered an additional tool for the intelligent management of environmental monitoring, able to carry out an in-depth analysis of the pollution problem. This paper presents a continuous monitoring study of odours at the fence line of an urban wastewater treatment plant, integrating instrumental monitoring with IOMS and citizens' reports. The training of the IOMS was carried out in the field,

using odor classification and quantification algorithms obtained through modern machine learning techniques, such as neural networks and random forest, in order to obtain a system capable of automatically recognizing either the class of odour or its concentration. Afterward, citizen science was used to collect and analyze reports made by citizens, who had an App for monitoring odour annoyance: the App was designed to make the citizens enter type and odor intensity they detected, associating each signal with position, time and weather data. The monitoring campaign was carried out over 5 months, and then the data obtained from the IOMS were analyzed along with citizens' reports. At first, an analysis was carried out taking into account the results of the algorithms deriving from the trained IOMS, in order to identify the most frequent odor classes. Subsequently, the results of IOMS were correlated with the reports and with the weather data, in order to verify whether the reports were connected to the plant. The description of the odours perceived by the population, together with the identification of the appropriate wind direction, allowed to isolate the events that showed a correlation with the emission trends of the plant. The results of the study were therefore useful for establishing the real contribution of the monitored plant with respect to all the olfactory nuisance events perceived by citizens.

Keyword: *IOMS, machine learning, odor classification, odor quantification, citizen science.*

1. Introduzione

Nel contesto dell'inquinamento atmosferico gli odori si classificano come una componente rilevante ed un indicatore importante della salute delle aree urbane vicine agli impianti di trattamento delle acque reflue urbane (WWTP) [1]

Varie regioni all'interno di alcuni stati hanno implementato o stanno implementando proprie normative per definire i limiti di emissione di composti odoriferi dalle sorgenti e le modalità di gestione dell'inquinamento da odori per i WWTP, in quanto in Europa, America e Australia attualmente non è in vigore nessuna legislazione che regoli gli odori [2-4].

In un contesto così complesso e socialmente sensibile per le varie segnalazioni di cattivi odori in prossimità degli WWTP urbani, il contributo della citizen science per l'identificazione delle emissioni di odori [5-11], e il naso elettronico o sistema di monitoraggio degli odori strumentale (IOMS) [12] sono strumenti potenti per aiutare le Autorità competenti e/o le agenzie di protezione ambientale a definire strategie appropriate al fine di identificare, misurare e

ridurre l'impatto degli odori sui recettori. Per quanto riguarda gli IOMS, gli sviluppi degli ultimi anni sono stati molto rilevanti sia in termini hardware che software, anche grazie al crescente impiego di algoritmi che prevedono un idoneo trattamento dei segnali mediante l'estrazione delle caratteristiche più significative [13,14] e tecniche di machine learning [15, 16, 17].

L'approccio basato sul coinvolgimento attivo dei cittadini nella definizione delle molestie olfattive è basato sulla evidenza che il sistema olfattivo umano può distinguere più di un trilione di odori [18] e superare le apparecchiature di misurazione sensibili nelle attività di rilevamento degli odori [19], sebbene vi siano diverse discussioni sui limiti di questo approccio [20, 21, 22]. Tuttavia, negli ultimi anni diverse esperienze sono state effettuate anche con coinvolgimento delle Agenzie Regionali per la Protezione Ambientale [5, 23-26]

Sebbene vi siano diverse evidenze che indicano le potenzialità di integrare diversi approcci, pochi sono gli studi in cui sono stati utilizzati approcci integra-

ti utilizzando diverse metodologie di indagine e riferiti recentemente all'integrazione della field-inspection con la modellistica previsionale [27]; in questo contesto, si ritiene significativo presentare i risultati di uno studio condotto su un impianto di depurazione reflui civili, con l'obiettivo di integrare l'approccio sensoristico e la citizen science.

In particolare, obiettivo del presente studio è valutare le potenzialità di un sistema di monitoraggio che abbina alle più recenti tecniche di tipo strumentale le potenzialità della citizen-science per valutare l'impatto odorigeno connesso ad un impianto depurazione acque reflue caratterizzato da sorgenti emissive multiple, limitrofe spazialmente.

Il set-up sperimentale ed il coinvolgimento della popolazione nelle segnalazioni, in particolare, sono stati progettati per quantificare il disagio olfattivo, sia in termini di concentrazioni che di classi odorogene misurabili al confine dell'impianto ed identificare il contributo delle diverse sorgenti rispetto agli eventi di disturbo direttamente rilevati dalla popolazione.

2. Materiali e metodi

2.1. Descrizione dell'impianto

L'impianto di depurazione urbano qui considerato è situato nell'area industriale di Monopoli (Bari-Italia), a servizio di 64.695 abitanti equivalenti (PE) e funzionante con una portata media giornaliera di 12.939 m³/d (Figura 1). L'impianto si trova ad una distanza di 420 m dagli edifici residenziali più vicini.

Sulla base dei dati di vari studi effettuati per la caratterizzazione olfattiva degli impianti di trattamento reflui urbani [28] è stato stabilito che le sezioni

più critiche dal punto di vista delle emissioni odorigene sono i pretrattamenti, la sedimentazione primaria e il trattamento dei fanghi. Sulla base di tali studi e delle evidenze raccolte sul campo, è stata effettuata la mappatura degli odori dell'impianto: la prima fase ha previsto una caratterizzazione completa delle sorgenti di emissione, e successivamente è stato definito un programma di campionamento delle sorgenti più critiche. Il programma di campionamento per la raccolta dei campioni per l'addestramento e il test è stato progettato per tenere conto anche delle variazioni ambientali (temperatura, umidità relativa) ed è durato sette mesi. A seguito dell'applicazione di linee guida regionali relative alla gestione dei depuratori [29], le sezioni di pretrattamento e ispessimento fanghi sono state coperte, depressurizzate e l'aria è trattata in due biofiltri; inoltre, nell'impianto è attivo un digestore anaerobico per fanghi, a cui era associato il recupero energetico per combustione, per cui anche il biogas è stato considerato in quanto potenziale fonte di emissioni fuggitive.

2.2. Strumentazioni e procedura di addestramento IOMS

L'IOMS (MSEM32[®] by Sensigent, Baldwin Park, CA, USA) è stato posizionato in posizione SM (Figura 2), vicino alla linea di recinzione dell'impianto lungo la direzione dei venti prevalenti provenienti dall'impianto, verso i più vicini recettori urbani. Dopo la raccolta in duplicato, ogni campione è stato somministrato allo IOMS lo stesso giorno e il campione in replicato è stato analizzato utilizzando l'olfattometria dinamica (DO) presso il Laboratorio T&A entro 24 ore, utilizzando l'olfattometro dinamico LEO (ARCO Solutions srl, Trieste, Italia) per la misurazione delle Concentrazioni di Odore (Cod), che sono espresse come unità olfattiva europea (ouE/m³).

Sono stati raccolti un totale di 51 campioni, con concentrazioni di odore comprese tra 20 e 2435 ouE/m³.

Dopo una caratterizzazione preliminare delle emissioni della sorgente, è stato stabilito che le fonti di emissione più critiche erano i pretrattamenti, il condizionamento dei fanghi e il biogas dal digestore anaerobico. Le classi di odore selezionate erano Classe 1 (pretrattamenti), Classe 2 (condizionamento fanghi), Classe 3 (biogas) e Classe 0 (classe sconosciuta).

Il dataset usato per l'addestramento degli algoritmi di machine learning (ML) è stato ottenuto dai segnali acquisiti dallo IOMS che ha un array di 32 sensori (3 sensori ambientali, ovvero pressione, umidità e temperatura, 4 sensori elettrochimici, 14 sensori MOS (Metal Oxide Sensor), 1 sensore PID e 10 sensori *nano-composite-based*). La fase di addestramento è stata svolta in campo, in quanto ai fini della rappresenta-

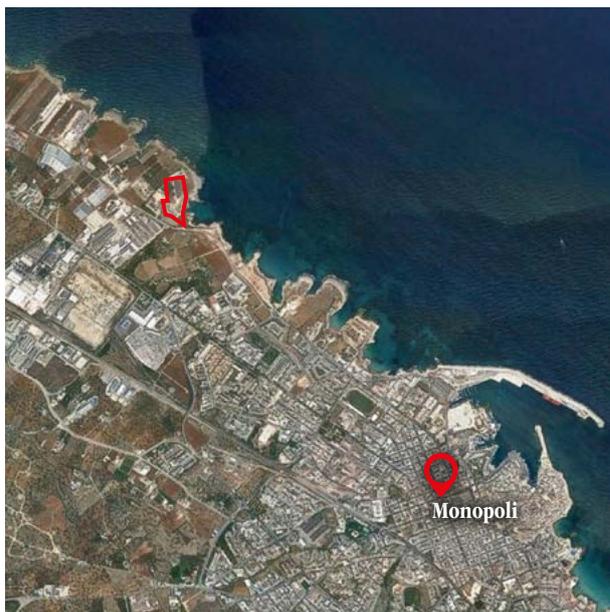


Figura 1. Ubicazione dell'impianto.



Figura 2. Mappa dell'impianto

tività del fattore di risposta di ogni singolo sensore è importante che i campioni siano acquisiti in diverse condizioni ambientali (in particolare per umidità e temperatura) [30]. Infatti, è noto in letteratura che variazioni di temperatura e umidità possono influenzare significativamente le condizioni di fondo dei sensori e la loro selettività [31,32] e, di conseguenza, influenzano le elaborazioni delle risposte acquisite.

Per queste ragioni lo strumento impiegato era dotato sistema di generazione interna di aria neutra inodore (zero air-ZA) generata localmente alle medesime condizioni di fondo di temperatura e umidità dell'ambiente esterno.

La durata di ciascuna fase è stata determinata sulla base della letteratura [14] e valutando puntualmente i tempi di t_{rise} e t_{fall} per la risposta specifica di ogni sensore, in relazione alla sua specifica costruttiva. È stato considerato un tempo medio di 90 s, in linea con i tempi di risposta di tutto l'array sensore utilizzato.

Per ottenere i migliori profili di acquisizione, il ciclo di misurazione è stato impostato in 1 min di purging con ciclo ZA, 3 min di somministrazione del campione da imputare (fase di acquisizione) e 3 min per il recupero delle condizioni di fondo; per ogni campione il ciclo di misura è stato ripetuto quattro volte. La frequenza di campionamento dello strumento è stata impostata su 0,1 Hz, in modo che fossero disponibili 12 punti dati per ogni replica di campione.

2.3. Pretrattamento dati

Le curve di risposta (Fig. 3), che rappresentano la variazione del segnale dei sensori, sono state analizzate per estrarre le caratteristiche del segnale. Sebbene dalle curve di risposta siano estraibili diverse caratteristiche (risposta R , risposta alla massima concentrazione rilevata dai sensori, t_{rise} , tempo necessario al raggiungimento della risposta R , t_{fall} , tempo necessario a ritornare ai valori di riposo R_0), studi recenti suggeriscono che i valori di picco dei segnali, che rappresentano il massimo grado di variazione nei sensori, siano più efficaci per la classificazione degli odori.

2.4. Algoritmi per la classificazione e la quantificazione degli odori

La classificazione degli odori e la previsione dell'unità odorimetrica è stata effettuata mediante l'utilizzo

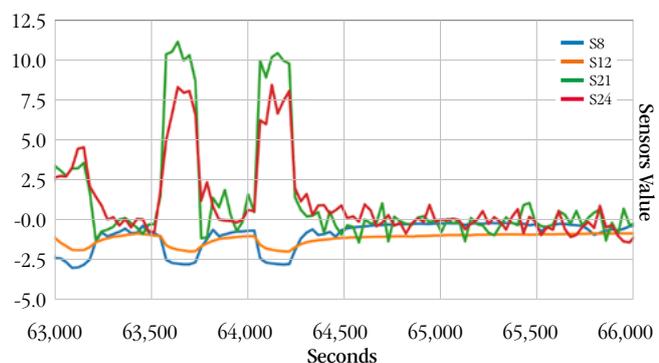


Figura 3. Esempio di andamento dei sensori durante una somministrazione.

Tabella 1. Struttura del dataset, diviso per classi di odore e i relativi intervalli di concentrazione.

Classe	Numero di Campioni	Numero di dati	Intervalli di concentrazione [ouE/m ³]
Classe 0	28	216	20-200
Classe 1	24	160	25-2435
Classe 2	28	215	40-510
Classe 3	28	160	64-1866

due algoritmi di machine learning opportunamente costruiti. Il primo è la Random Forest, ed il secondo è una rete neurale multistrato (Multi-Layer Perceptron – MLP). Tutti i dati raccolti dall'IOMS, che rappresentano le risposte dei sensori, sono stati registrati in un archivio cloud sicuro e quindi estratti per l'addestramento.

2.4.1. Estrazione delle feature e flusso di lavoro

Nella Figura 4 viene fornito il flusso di lavoro complessivo per lo sviluppo del modello. Dopo il pretrattamento dei dati, sono stati eseguiti diversi test per scegliere un sottoinsieme appropriato delle variabili di input, utilizzando l'algoritmo Recursive Feature Elimination con Cross Validation (RFECV) [33], al fine di ottenere l'insieme dei sensori più significativi che sono successivamente stati utilizzati per la costruzione di entrambi gli algoritmi.

Il dataset complessivo con le feature selezionate è stato quindi diviso in un *training set* ed in *test set* con rapporto 80:20, utilizzando così 600 dati per l'addestramento e 150 per la valutazione delle performances.

La procedura di Cross Validation consente di verificare se sia presente o meno un fenomeno di overfitting. Per i modelli selezionati si è deciso di utilizzare una 5-fold Cross Validation (ripetuta 5 volte): in dettaglio, il tasso di accuratezza complessivo di MLP e RF è stato calcolato cinque volte suddividendo il set di dati di addestramento (600 dati) in dati di addestramento interni (480 punti dati) e dati di convali-

da (120 punti dati) con suddivisioni diverse ogni volta. I modelli sono stati adattati ai dati di addestramento interni e i punteggi sono stati calcolati con riferimento ai dati di convalida. Dopo la Cross Validation e la selezione dei modelli, l'ultimo passaggio è stato quello di utilizzare il test set (20% del data set complessivo) per analizzare le performance dei modelli selezionati sia per la classificazione che per la regressione. Per il processo di classificazione è stata calcolata una matrice di confusione sia per la rete neurale che per la Random Forest e sono stati utilizzati come parametri di punteggio la *accuratezza*, calcolata sia per ciascuna classe sia in maniera complessiva, e il coefficiente *kappa da Cohen*, utile soprattutto in situazione di sbilanciamento di dati.

L'introduzione di questo parametro è correlata alle applicazioni di campo previste dell'IOMS. Se, ad esempio, dopo una campagna di monitoraggio della durata di un tempo T, risulta che la classificazione restituisce per il 90% del tempo la Classe 0 e per il 10% la Classe 1, e ci interessa confrontare le classi previste con quelle effettive, l'utilizzo del tasso di accuratezza complessivo distorcerebbe il risultato, poiché non tiene conto del fatto che le classi non sono equamente distribuite durante il rilevamento. Pertanto, il kappa di Cohen può essere utilizzato per affrontare situazioni che molto si potrebbero verificare durante il monitoraggio sul campo.

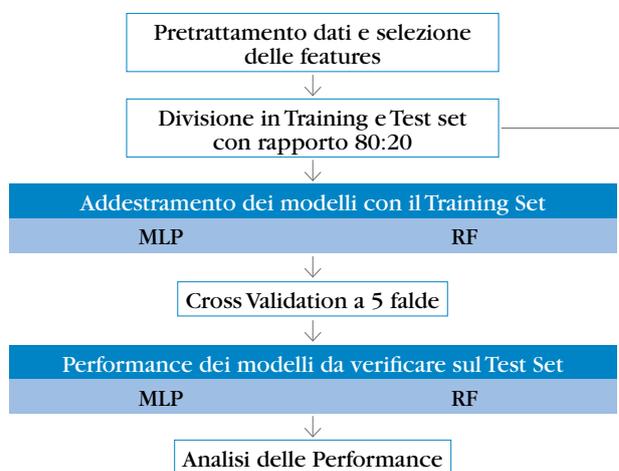
Per la regressione sono state calcolate le differenze in assoluto fra concentrazioni odorimetriche misurate e quelle predette, sia dall'algoritmo MLP che dalla RF.

2.5. Descrizione della APP

L'app utilizzata per la raccolta si chiama *Segnal App-Odori* ed è stata sviluppata dal Comune di Monopoli per i sistemi operativi Android (<https://play.google.com/store/apps/details?id=it.segnalapp.odori>) e iOS (<https://apps.apple.com/it/app/segnal-app-odori/id1446855011>).

Una volta che l'utente ha effettuato il login, è possibile effettuare una segnalazione quando si percepisce un disturbo olfattivo.

L'utente può selezionare il livello di intensità del fastidio olfattivo (debole, facilmente rilevabile o molto forte) e il tipo di odore avvertito (plastico, organico, bruciato o altro) e può anche inserire una breve descrizione dell'odore percepito (es. o fogna), per facilitare

**Figura 4.** Schema del flusso di lavoro.

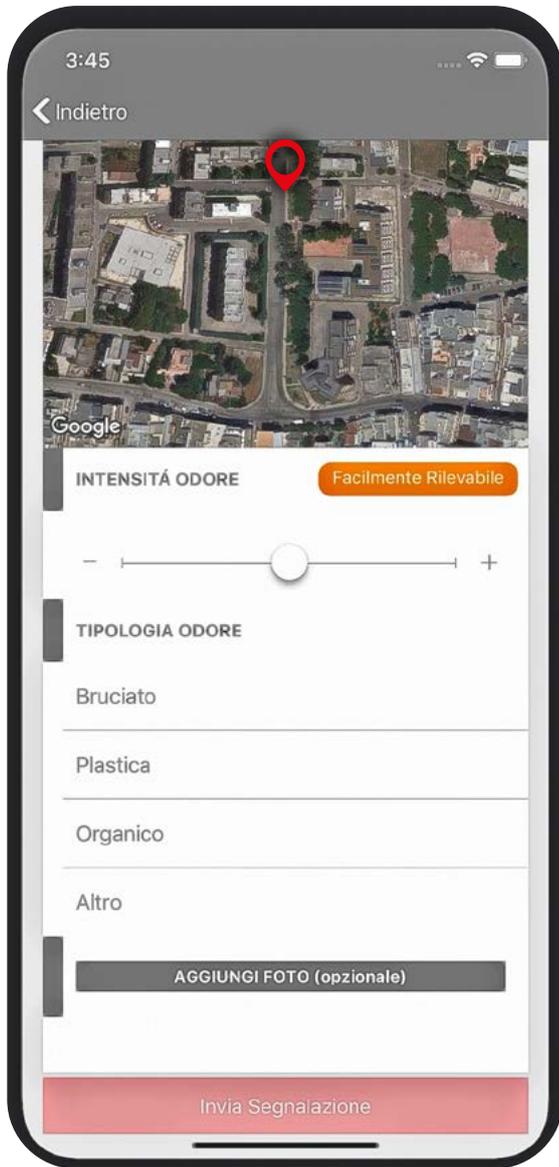


Figura 4. Schermata della applicazione Segnal APP-Odori.

tare la classificazione dell'odore, e anche dei possibili effetti sulla sua persona (ad esempio mal di testa o mal di gola o nausea).

Affinché la segnalazione sia utilizzabile per successive elaborazioni, ogni report inviato è associato alle coordinate geografiche rilevate in quel momento e ai dati di velocità e direzione del vento. Quest'ultima potenzialità, non presente in molte App per la segnalazione odori, è stata molto utile nelle elaborazioni successive per stabilire se il segnalatore fosse sottovento o sopravvento alla sorgente indagata.

3. Risultati e Discussioni

3.1. Fase di addestramento in campo per la classificazione e regressione

I segnali strumentali sono stati processati mediante una procedura di Feature selection che individua la variabile più idonea da utilizzare nei successivi model-

li di classificazione e regressione. Gli iperparametri dei modelli machine learning sono stati selezionati per la fase di classificazione e sono rappresentati dal numero di strati nascosti e dal numero di nodi per MLP e dal numero di alberi decisionali o stimatori per Random Forest. Per MLP la massima accuratezza è stata ottenuta con 5 strati nascosti e 100 neuroni, mentre per RF sono stati utilizzati 20 stimatori [16].

3.1.1. Classificazione

Una volta selezionati i modelli (MLP e RF), sono stati calcolati i tassi di accuratezza della classificazione per ciascuna classe e il tasso di accuratezza complessivo per i migliori modelli. I risultati per il training set hanno mostrato una accuratezza per ciascuna classe non inferiore a 0.99 per MLP e pari a 1 per RF. La Cross Validation a 5 classi ha consentito di escludere problemi di overfitting, in quanto le prestazioni di classificazione (superiori a 0.97 sia per MLP che per RF) hanno dimostrato che la scelta dei dati di allenamento non ha influenzato l'accuratezza della classificazione complessiva. Analizzando i risultati della classificazione con i dati del test-set, costituito da 150 campioni, solo tre elementi sono stati non correttamente classificati.

Il tasso di accuratezza complessivo ed il kappa di Cohen sono riportati nella seguente Tabella 2 per entrambi gli algoritmi e si ritengono soddisfacenti.

3.1.2. Regressione

Per la determinazione della concentrazione degli odori, è stata scelta la stessa struttura della MLP della classificazione: non sono stati variati gli iperparametri della rete neurale in quanto la riduzione del numero di strati e neuroni nascosti ha comportato solo una diminuzione delle prestazioni, senza una diminuzione significativa di tempo computazionale.

Nella seguente figura (Fig. 6) sono riportati gli scarti tra i valori predetti dal modello per il test-set rispetto ai valori reali, per entrambi gli algoritmi.

Lo scarto quadratico medio RMSE per MLP è pari a 130 uo/m^3 , mentre per RF il valore è pari a 97 uo/m^3 . Entrambi i valori corrispondono a degli scarti quadratici medi sull'intervallo di misura dei campioni analizzati in olfattometria dinamica [$20 - 2455 \text{ uo/m}^3$] inferiori al 10% e si ritengono accettabili per la successiva fase di monitoraggio in campo.

Tabella 2. Punteggio della accuratezza per la classificazione di ogni classe, punteggio accuracy globale e coefficiente Kappa di Cohen per MLP e RF sul test set.

Classe	MLP	RF
Punteggio accuratezza globale	0.98	0.98
Coefficiente Kappa di Cohen	0.97	0.97

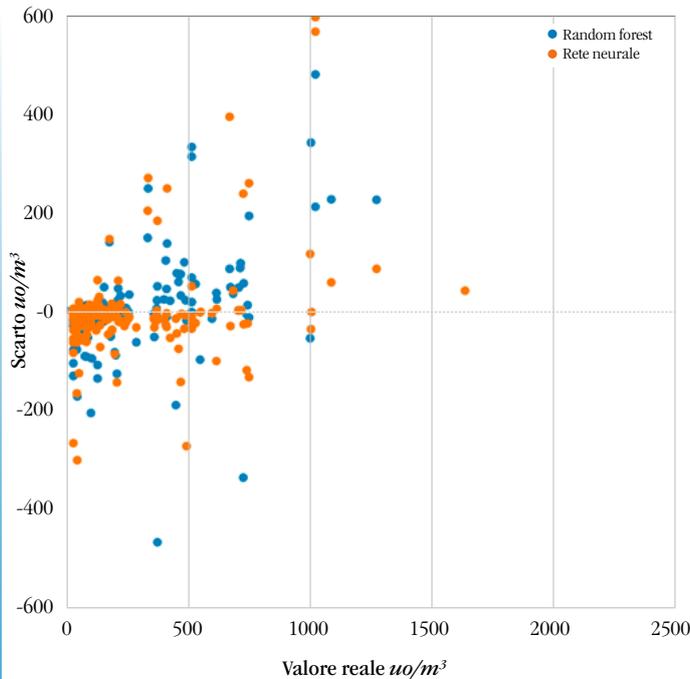


Figura 6. Grafico dello scarto fra i valori reali ed i valori predetti da entrambi gli algoritmi.

3.2. Analisi congiunta dei dati classe-concentrazione

Una volta completato l'addestramento dello IOMS e verificata l'idoneità dei parametri prestazionali per il monitoraggio in campo, sono stati raccolti i dati fra il 10 Febbraio 2021 e il 5 Maggio 2021. Il database ricavato ammonta ad un totale di 258.600 dati, raccolti con frequenza ogni 30 secondi.

Dall'analisi univariata della distribuzione della concentrazione in tutto il periodo sono stati ottenuti i più rappresentativi indici statistici, quali la media

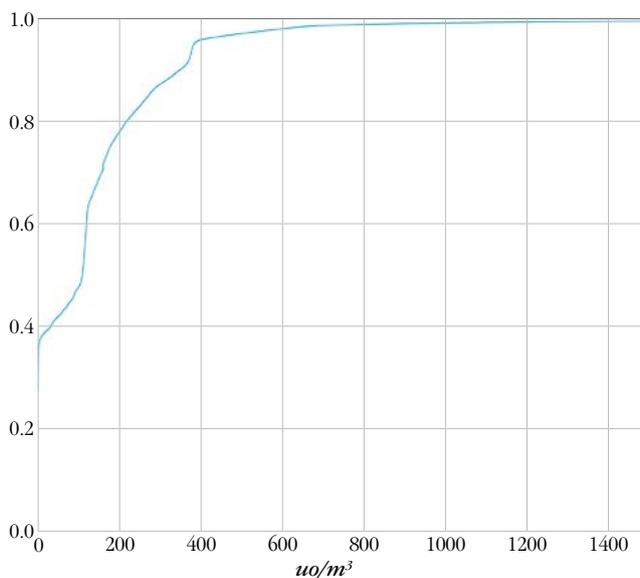


Figura 7. Distribuzione cumulata della concentrazione di odori.

Percentuali di Classi rilevate per fasce di uo/m^3

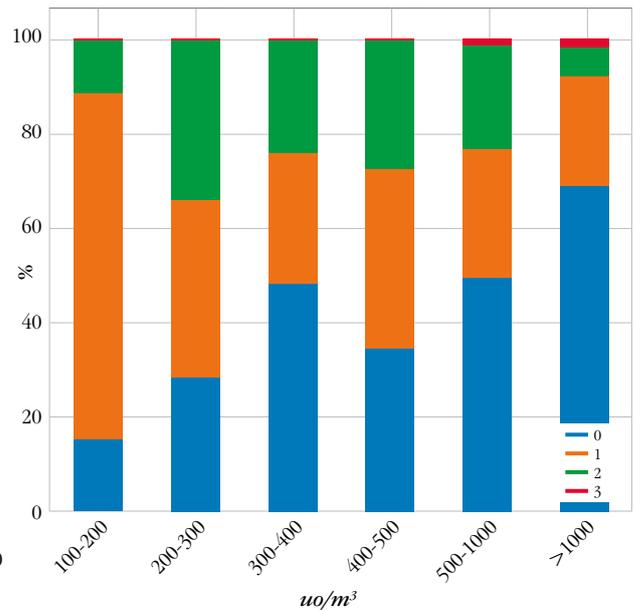


Figura 8. Percentuali delle classi di odori rivelate fra le diverse fasce di intensità odorigena.

(130 uo/m^3), la mediana (108 uo/m^3) ed il 95% percentile (382 uo/m^3). La Figura 7 riporta il grafico della distribuzione cumulata dell'intensità odorigena.

La simultanea disponibilità dei dati di concentrazione e classe odorigena ha consentito di esaminare congiuntamente i dati: si è deciso, in particolare, di suddividere tutti i dati proveniente dall'IOMS in fasce rispetto all'intensità rilevata. Le fasce sono state prese a partire dalle 100 uo/m^3 in quanto, sotto le 100 uo/m^3 i risultati della classificazione potrebbero non essere rilevanti.

Si sono considerati intervalli di ampiezza 100 uo/m^3 : 100-200, 200-300, 300-400 e 400-500 uo/m^3 . Da 500 uo/m^3 in poi, vista la minore numerosità di dati, si è ritenuto di considerare unicamente due fasce: 500-1000 uo/m^3 e > 1000 uo/m^3 .

Come si può vedere dalla Figura 8, più è alto il valore di concentrazione, più si riscontra la presenza di classe 0 (altro o sconosciuto): la percentuale più bassa si attesta al 15% nella fascia 100-200 uo/m^3 e si arriva fino ad oltre il 69% nella fascia con valori superiori a 1000 uo/m^3 . Considerando i dati aggregati in due range di concentrazioni, ovvero 100-500 uo/m^3 e maggiori di 500 uo/m^3 , la questione analizzata è ancora più evidente: per i valori di concentrazione più bassi, la percentuale di classi odorogene non riferibili all'impianto è del 24%, mentre per concentrazioni più alte, le sorgenti esterne all'impianto sono state rilevate per circa il 54% del tempo.

Poiché le concentrazioni più alte sono verosimilmente maggiormente responsabili dell'impatto si recet-

tori, è importante analizzare gli eventi segnalati dai cittadini e verificare, mediante i dati dello IOMS, quanti di essi si riferissero ad una sorgente interna all'impianto o esterna, come discusso nel seguente paragrafo.

3.3. Selezione delle segnalazioni ed analisi congiunta ai dati dello IOMS

Nel periodo di interesse (febbraio-maggio) sono state raccolte 268 segnalazioni complessive mediante SegnalApp (Fig. 9a). Per valutare l'integrazione informativa tra segnalazioni ed i dati strumentali registrati in continuo dallo IOMS dopo la procedura di addestramento, è stata effettuata una selezione dei dati registrati dalla App in due step.

Prima di tutto sono state ritenute pertinenti solo le segnalazioni per cui il vento spirasse lungo la direzione impianto-recettore: sono stati, quindi, selezionati due coni di afferenza dei venti, centrati sull'impianto e con ampiezza di 60°. Il primo cono è il cono Nord-Ovest compreso fra 60 e 120 gradi rispetto alla direzione nord, mentre il secondo cono considerato è il cono Sud-Est compreso fra 300 e 360 gradi rispetto alla direzione nord.

Successivamente, sono state considerate quelle segnalazioni rientranti nei coni di afferenza, per cui erano disponibili anche le descrizioni della tipologia di odore, risultate estremamente utili nella selezione delle informazioni. Sono state elaborate unicamente le segnalazioni che facevano riferimento alla tipologia di odore che potesse provenire dall'impianto considerato o da impianti limitrofi di trattamento acque e sono state scartate quelle che facevano riferimento ad altre tipologie di odori. Le segnalazioni considerate, registrate all'interno dei coni di vento e riferite ad una tipologia di odore che potesse provenire dall'impianto, sono riportate nella Fig. 9b.

Avendo selezionato le segnalazioni potenzialmente pertinenti, si è passati ad incrociare queste ultime

con i dati dell'IOMS e con le elaborazioni degli algoritmi in materia di classificazione.

Poiché le segnalazioni sono riferite ad un momento preciso, si è deciso di considerare, per ogni segnalazione, tutti i dati dell'IOMS e tutti i risultati degli algoritmi contenuti in una finestra temporale di un'ora centrata nel momento della segnalazione, in modo da poter avere un range più ampio da analizzare, tenendo conto anche di eventuali ritardi della segnalazione rispetto al momento della percezione o a segnalazioni effettuate nel momento di iniziale percezione dell'odore che plausibilmente avrebbe poi avuto un successivo aumento di intensità nel periodo successivo.

In Fig. 10 si presenta la distribuzione temporale giornaliera delle segnalazioni, confrontata con la distribuzione temporale giornaliera degli eventi registrati dall'IOMS con concentrazione maggiore di 500 uo/m³, entrambe normalizzate rispetto al numero massimo di eventi.

È interessante notare che le segnalazioni correlate alle emissioni di un impianto di depurazione si collocano nei periodi di fine febbraio di inizio aprile ovvero nei periodi in cui si trova maggiore correlazione fra tutte le segnalazioni con gli eventi odorigeni più elevati registrati dallo IOMS.

Il dataset dello IOMS direttamente correlato alle segnalazioni della popolazione è stato quindi analizzato con riferimento alle classi odorigene oggetto di addestramento (Fig. 11).

La percentuale di attribuzione alla classe 0, ovvero di classe non riconosciuta e quindi non proveniente dall'impianto, è risultata essere pari allo 40%, mentre il 60% degli intervalli temporali in cui si sono avute segnalazioni da parte dei cittadini è attribuibile alle sorgenti dell'impianto, ovvero 27.24% pretrattamenti (classe 1), 32.51% sorgente fanghi (classe 2), mentre la classe 3 (biogas) è trascurabile (0.15%). Pertan-

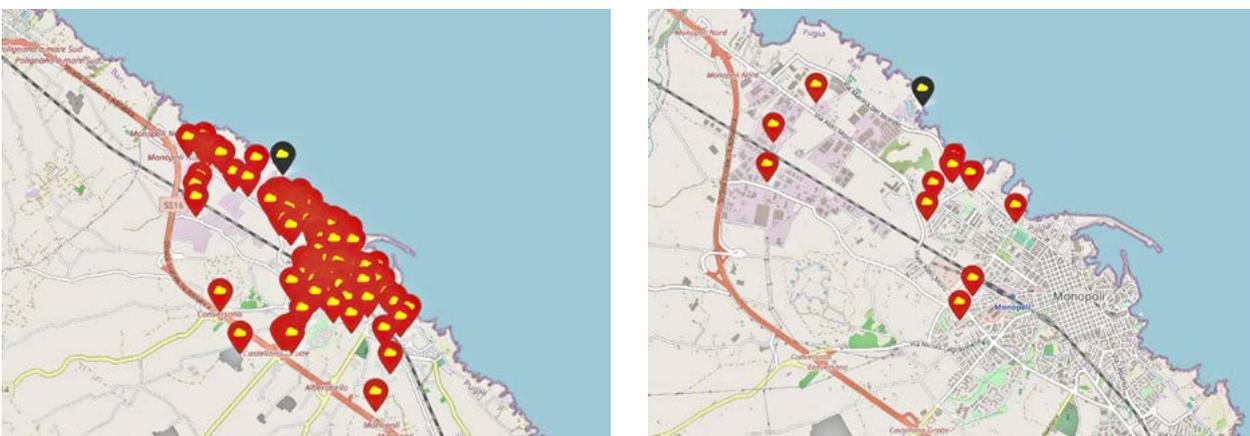


Figura 9. Analisi delle segnalazioni nel periodo di interesse (a), con evidenza di quelle selezionate per direzione di provenienza dall'impianto e tipologia di odore (b).

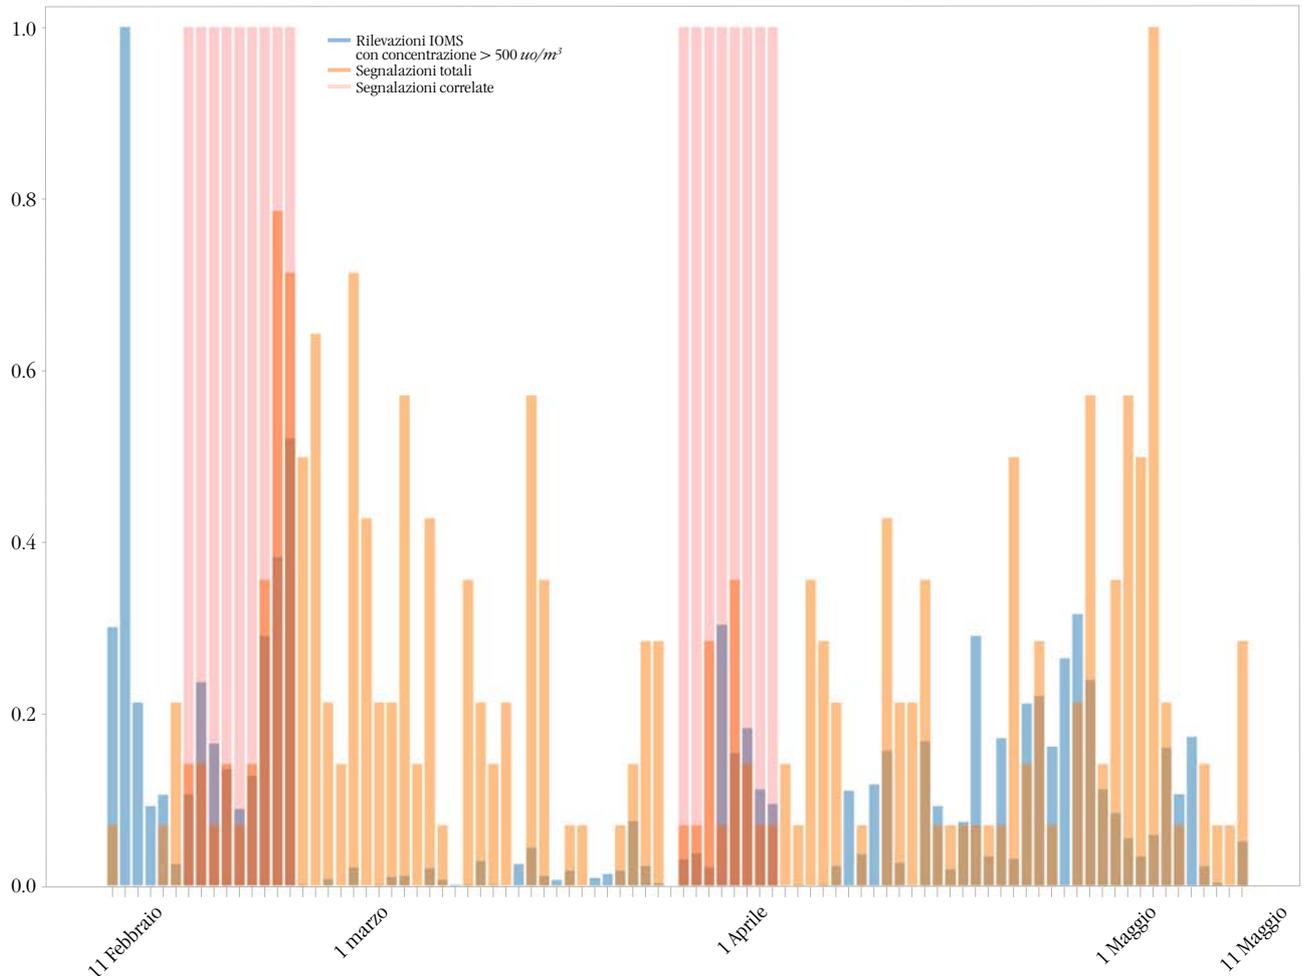


Figura 10. Confronto fra la distribuzione temporale delle segnalazioni e quella degli eventi registrati con concentrazioni > 500 uo/m³ e marcatura dei periodi di maggiore correlazione.

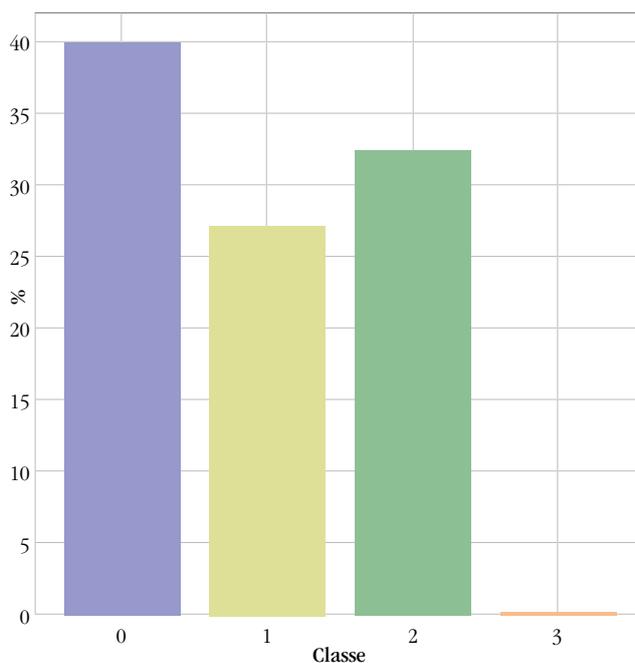


Figura 11. Percentuali delle classi di odore rilevate durante le segnalazioni significative.

to, i dati acquisiti dal sistema IOMS, unitamente ai criteri di post-analisi delle segnalazioni inviate dai cittadini, hanno evidenziato chiaramente come una parte di queste, quantificabile in una quota pari al 40%, derivi da aree emittive non attribuibili a specifiche sorgenti presenti nell'impianto monitorato e che hanno costituito il data set di addestramento.

Tale dato è coerente con quanto analizzato nel paragrafo precedente in cui è emerso che i valori di concentrazione più alti sono causati, per circa la metà, da sorgenti esterne all'impianto.

Poiché il caso studio rientra in un'area in cui insistono altre sorgenti di tipo industriale, alcune delle quali anche connesse al trattamento di reflui, le risultanze dello studio hanno indicato la possibile presenza di altre sorgenti esterne, non identificabili con le sorgenti campionate, che costituiscono una rilevante concausa rispetto alle molestie segnalate dai cittadini e corroborate dall'analisi di concentrazioni e classi odorigene dallo IOMS.

4. Conclusioni

Nel presente lavoro è stata descritta l'integrazione tra strumenti di Citizen Science e l'utilizzo di IOMS dotati di algoritmi di intelligenza artificiale per il monitoraggio degli impatti odorigeni da un impianto di depurazione di acque reflue civili.

Gli algoritmi sono stati costruiti a partire dai dati di addestramento in campo dello IOMS, posto al confine dell'impianto considerato. Per quanto riguarda l'implementazione degli algoritmi, sono stati ottenuti ottimi risultati sia nella classificazione (coefficiente Kappa di Cohen al 97%), sia nella regressione con uno scarto quadratico medio di 130 uo/m³ per la MLP e di 97 uo/m³ per la RF.

L'analisi dei dati di campo, post-addestramento, ha permesso di individuare le classi di odori che sono responsabili dei più alti valori di concentrazione durante i diversi mesi di monitoraggio, rilevando che circa la metà dei dati caratterizzati da valori elevati di concentrazione non fossero riferibili a classi odorigene interne all'impianto, ma ad altre sorgenti limitrofe.

I dati delle segnalazioni effettuate dai cittadini, oltre 60 al mese per i quattro mesi di monitoraggio, sono stati analizzati per tener conto della direzione del vento al momento della segnalazione e della descrizione della tipologia di odore, per evidenziare quelle più strettamente legate al trattamento di acque reflue. L'analisi dei dati dello IOMS durante le ore in cui sono state effettuate tali segnalazioni ha consentito di quantificare il contributo delle sorgenti emissive dell'impianto, individuando la sorgente fanghi come la maggior responsabile tra le sorgenti analizzate nel depuratore. Si è altresì dimostrato che il 40% delle molestie percepite dalla popolazione come legate al trattamento acque reflue, non è riferibile ad alcuna sorgente interna allo stesso e dovrebbe essere ricercata in altre sorgenti analoghe e limitrofe allo stesso.

L'utilizzo combinato dell'approccio strumentale e dei dati relativi alle segnalazioni dei cittadini mediante App si è dimostrato utile ed efficace, in particolare modo in presenza di sorgenti emissive di odori multiple e ravvicinate. ■

Riferimenti bibliografici

- Oliva G., Zarra T., Massimo R., Senatore V., Buonerba A., Belgiorno V., Naddeo V. Optimization of Classification Prediction Performances of an Instrumental Odour Monitoring System by Using Temperature Correction Approach. *Chemosensors* 2021, 9, 147, doi:10.3390/chemosensors9060147.
- Linee guida per la caratterizzazione emission gassose da attività a forte impatto odorigeno, D.g.r. 15 February 2012 – n. IX/3018. Available online: <http://www.olfattometria.com/download/dgr-lomb.pdf> (accessed on 02 July 2021).
- Legge sulle Emissioni Odorigene. L.R. 16 July 2018– n. 32. Available online: http://www.ager.puglia.it/documents/10192/29519220/LR_32_2018.pdf (accessed on 02 July 2021).
- Bokowa A., Diaz C., Koziel J.A., McGinley M., Barclay J., Schauburger G., Guillot J.-M., Sneath R., Capelli L., Zorich V., et al. Summary and overview of the odour regulations worldwide. *Atmosphere* 2021, 12, 206, doi:10.3390/atmos12020206.
- Brattoli M., Mazzone A., Giua R., Assennato G; de Gennaro G. Automated Collection of Real-Time Alerts of Citizens as a Useful Tool to Continuously Monitor Malodorous Emissions. *Int. J. Env. Res. Pub. Health* 2016, 13, 263, doi:10.3390/ijerph13030263.
- Real time, automatic and remote-activated sampling system for industrial odour emissions compliant with the European Standard EN 13725, CORDIS EU Research results. Available online: cordis.europa.eu/project/id/756865 (accessed on 02 July 2021).
- Lotesoriere B., Giacomello A., Bax C., Capelli L. The Italian Pilot Study of the D-NOSES Project: An Integrated Approach Involving Citizen Science and Olfactometry to Identify Odour Sources in the Area of Castellanza (VA). *Chem. Eng. Trans.* 2021, 85, 145-150.
- Yen-Chia Hsu, Paul Dille, Jennifer Cross, Beatrice Dias, Randy Sargent, and Illah Nourbakhsh. 2017. Community-Empowered Air Quality Monitoring System. *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems*. Association for Computing Machinery, New York, NY, USA, 1607-1619. DOI:<https://doi.org/10.1145/3025453.3025853>
- Zheng H., Hong Y., Long D., and Jing H.: Monitoring surface water quality using social media in the context of citizen science, *Hydrol. Earth Syst. Sci.*, 21, 949-961, <https://doi.org/10.5194/hess-21-949-2017>, 2017.
- W. Reimringer, T. Conrad and A. Schütze, "Citizens network as reference for odor impact sensors – A case study," 2017 ISOCS/IEEE International Symposium on Olfaction and Electronic Nose (ISOEN), 2017, pp. 1-3, DOI:10.1109/ISOEN.2017.7968903.
- Yen-Chia Hsu, Jennifer Cross, Paul Dille, Michael Tasota, Beatrice Dias, Randy Sargent, Ting-Hao (Kenneth) Huang, and Illah Nourbakhsh. 2020. Smell Pittsburgh: Engaging Community Citizen Science for Air Quality. *ACM Trans. Interact. Intell. Syst.* 10, 4, Article 32 (December 2020), 49 pages. DOI:<https://doi.org/10.1145/3369397>

- Karakaya D., Ulucan O., Turkan M. Electronic Nose and Its Applications: A Survey. *Int. J. Aut. Comp.* 2020, 17, 179-209, doi:10.1007/s11633-019-1212-9.
- Yan J., Guo X., Duan S., Jia P., Wang L., Peng C., Zhang S. Electronic Nose Feature Extraction Methods: A Review. *Sensors* 2015, 15, 27804-27831, doi:10.3390/s151127804.
- Zarra T., Galang M.G.K., Ballesteros, F.C. Jr., Belgiorio V., Naddeo V. Instrumental Odour Monitoring System Classification Performance Optimization by Analysis of Different Pattern-Recognition and Feature Extraction Techniques. *Sensors* 2021, 21, 114, dx.doi:10.3390/s21010114.
- Men H., Fu S., Yang J., Cheng M., Shi Y., Liu J. Comparison of SVM, RF and ELM on an Electronic Nose for the Intelligent Evaluation of Paraffin Samples. *Sensors* 2018, 18, 285, doi:10.3390/s18010285.
- Cangialosi E., Bruno E., De Santis G. Application of Machine Learning for Fenceline Monitoring of Odor Classes and Concentrations at a Wastewater Treatment Plant. *Sensors* 2021, 21, 4716. <https://doi.org/10.3390/s21144716>
- Yelim Choi, Kyunghoon Kim, Seonghwan Kim, Daekeun Kim, Identification of odor emission sources in urban areas using machine learning-based classification models, *Atmospheric Environment: X*, Volume 13, 2022, 100156, ISSN 2590-1621. <https://doi.org/10.1016/j.aeoa.2022.100156>.
- Bushdid C., Magnasco M.O., Vosshall L.B., and Keller A. 2014. Humans can discriminate more than 1 trillion olfactory stimuli. *Science* 343, 6177 (2014), 1370-1372.
- Shepherd G.M. 2004. The human sense of smell: Are we better than we think? *PLoS Biol.* 2, 5 (2004), e146.
- Obrist M., Tuch A.N., and Hornbaek K. 2014. Opportunities for odor: Experiences with smell and implications for technology. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. ACM, 2843-2852.
- Ottinger G. 2010. Buckets of resistance: Standards and the effectiveness of citizen science. *Sci. Technol. Hum. Val.* 35, 2 (2010), 244-270.
- Stuetz R.M., Fenner R.A., Engin G. Assessment of odours from sewage treatment works by an electronic nose, H2S analyzer and olfactometry. *Water Res.* 1999, 33, 453-461.
- Progetto NOSE Arpa Sicilia/CNR <https://www.isac.cnr.it/content/nose-ITA>
- Prog. OdorNet Arpa Marche <https://odornet.arpa.marche.it>
- Progetto Molf Arpa Lombardia <https://www.arpalombardia.it/Pages/Asfalti-Brianza%2C-monitoraggi-e-attivita-svolte-da-Arpa-Lombardia.aspx>
- Progetto Arpa FVG <https://www.snpambiente.it/2021/03/26/odori-nuovo-applicativo-web-di-arpa-fvg/>
- Zarra T., Belgiorio V., Naddeo V. Environmental Odour Nuisance Assessment in Urbanized Area: Analysis and Comparison of Different and Integrated Approaches. *Atmosphere* 2021, 12, 690. <https://doi.org/10.3390/atmos12060690>
- Naddeo V., Zarra T., Oliva G., Kubo A., Ukida N., Higuchi T. Odour measurement in wastewater treatment plant by a new prototype of e.Nose: Correlation and comparison study with reference to both European and Japanese approaches. *Chem. Eng. Trans.* 2016, 54, 85-90.
- Linee guida per il rilascio di pareri riguardanti le emissioni in atmosfera prodotte dagli impianti di depurazione ARPA Puglia (rev. 2014). Available online: https://old.arpa.puglia.it/c/document_library/get_file?uuid=6e747fc8-859a-4cd6-9302-bb73913f7410&groupId=13879
- UNI 11761:2019; Emissioni e qualità dell'aria- Determinazione degli odori tramite IOMS (Instrumental Odour Monitoring Systems). Available online: <http://store.uni.com/catalogo/uni-11761-2019>
- Eusebio L., Capelli L., Sironi S. Electronic Nose Testing Procedure for the Definition of Minimum Performance Requirements for Environmental Odor Monitoring. *Sensors* 2016, 16, 1548, doi:10.3390/s16091548.
- Wu Z., Zhang H., Sun W., Lu N., Yan M., Wu Y., Hua Z., Fan S. Development of a Low-Cost Portable Electronic Nose for Cigarette Brands Identification. *Sensors* 2020, 20, 4239, doi:10.3390/s20154239.
- Demarchi L., Kania A., Ciężkowski W., Piórkowski H., Oświecimska-Piasko Z., Chormański J. Recursive Feature Elimination and Random Forest Classification of Natura 2000 Grasslands in Lowland River Valleys of Poland Based on Airborne Hyperspectral and LiDAR Data Fusion. *Remote. Sens.* 2020, 12, 1842, doi:10.3390/rs12111842.

Ringraziamenti

Si ringrazia il Comune Monopoli per aver messo a disposizione i dati della APP, Acquedotto Pugliese SpA per il supporto logistico e la Regione Puglia per il finanziamento del Progetto ASPIDI.



INGEGNERIA DELL'AMBIENTE

per il 2022 è sostenuta da:

