

# IDENTIFICAZIONE MORFOLOGICA E CLASSIFICAZIONE DI INSETTI ADULTI PER SORVEGLIANZA ENTOMOLOGICA: IL CONTRIBUTO DEL *DEEP-LEARNING*

Noemi Sarleti (a), Francesco Silvestrini (a), Guido Gigante (b), Andrea Ciardiello (c), Pietro Alano (a)

(a) Dipartimento di Malattie Infettive, Istituto Superiore di Sanità, Roma

(b) Centro Nazionale Protezione dalle Radiazioni e Fisica Computazionale, Istituto Superiore di Sanità, Roma

(c) Istituto Nazionale di Fisica Nucleare, Sezione di Roma

## Approcci computazionali alla analisi di immagini e al riconoscimento di insetti

L'identificazione e classificazione di un insetto a livello di genere e specie avviene, a livello morfologico, con il riconoscimento di caratteri macroscopici e microscopici accompagnato dall'uso di chiavi dicotomiche. La manipolazione del campione e l'interrogazione delle chiavi dicotomiche richiedono un personale esperto, capace di operare le scelte binarie su cui si basano le chiavi al fine di categorizzare ogni individuo nel modo più corretto. La struttura dicotomica delle chiavi consente di classificare un individuo sulla presenza/assenza o su variazioni di forma, dimensione e colore di determinati caratteri (*feature*). L'estrazione dei caratteri ad ogni passaggio è possibile grazie al nostro sistema visivo ed è proprio sull'organizzazione della corteccia visiva che si ispirano strumenti come gli algoritmi di *deep-learning* basati su reti neurali convoluzionali (*Convolutional Neural Network*, CNN), afferenti agli approcci di *machine-learning* nell'ambito del *Artificial Intelligence technology* (Figura 1).





Figura 1. Estrazione di caratteri morfologici rilevanti per l'identificazione/classificazione di insetti adulti da parte del meccanismo visivo ed elaborazione a livello della corteccia nell'uomo e da parte di un algoritmo di *deep-learning* basato su una rete neurale convoluzionale

Similarmente alla corteccia visiva, le CNN sono costituite da più livelli operativi specializzati (o livelli di convoluzione), la cui funzione è estrarre le *feature* da un'immagine per analizzarne il contenuto e assegnare ogni oggetto presente ad una data categoria (nel caso di insetti, un genere o una specie). Quindi, con il termine *deep-learning* si definiscono, più generalmente, tutti quei software in grado di emulare parzialmente il funzionamento del sistema nervoso mediante le CNN.

Quest'ultimo aspetto determina le principali differenze tra la maggioranza degli algoritmi di *deep-learning* e i classici algoritmi di *machine-learning*; mentre un algoritmo di *machine-learning* necessita di un *input* informativo (ovvero le *feature* da osservare) da parte dell'operatore per realizzare un'identificazione, un algoritmo di *deep-learning* è in grado di estrapolare in maniera autonoma le *feature* più significative per classificare uno o più oggetti (Figura 2).




**Figura 2. Schemi operativi di algoritmi di *machine-learning* e di *deep-learning* nella classificazione morfologica di insetti adulti**

Tale differenza è evidente nel lavoro di Okaiasu *et al.* (1), dove sono stati messi a confronto le performance ottenute con un approccio di *machine-learning* (basato su 12 *feature* morfologiche selezionate da un operatore) ed uno di *deep-learning* (dipendente solamente dalla capacità della CNN di estrarre autonomamente le *feature*), nel riconoscimento e classificazione dei generi *Anopheles*, *Aedes* e *Culex*. L'accuratezza massima raggiunta dalla CNN è stata del 95.5% contro l'82.4% ottenuto dal *machine-learning*.

Oltre a raggiungere *performance* spesso superiori, gli algoritmi di *deep-learning* tendono a trarre beneficio in misura maggiore rispetto ad approcci più classici da un grande numero di immagini nella fase di *training*. Di fondamentale importanza è dunque la realizzazione di un ampio numero di immagini in cui l'operatore posiziona gli oggetti che vuole che l'algoritmo impari ad identificare e classificare nelle *N* categorie scelte; questa collezione di immagini viene definita *training set*. La disponibilità di un alto numero di immagini permette a una CNN di estrarre *feature* che risultano meno sensibili a differenze di luminosità, posizione, orientamento e integrità/stato di conservazione degli esemplari fotografati e quindi più robustamente associate alle specifiche categorie, nonché più affidabili nella classificazione di nuove immagini.

Data la difficoltà pratica di ottenere gallerie di immagini sufficientemente grandi da poter essere utilizzate sia nella fase di *training* che nei successivi passaggi di validazione dell'algoritmo, vengono utilizzate tecniche di *augmentation*, ovvero ogni fotografia può essere modificata in luminosità, contrasto, saturazione, tinta ma anche meccanicamente con rotazioni a diverse angolature, aumentando significativamente il numero di immagini a disposizione (Figura 3). Applicare in modo rigoroso questa tecnica risulta un passaggio decisivo nell'incrementare l'accuratezza nella classificazione di una CNN (1, 2, 3).



**Figura 3. Esempi di tecniche di *augmentation* a partire dalla fotografia di un esemplare**

Le immagini originali che possono essere fornite all'algoritmo ed utilizzate nel passaggio di *augmentation* possono provenire da fonti diverse e non necessariamente “omogenee” tra loro, ad esempio da laboratori (1, 3), trappole entomologiche (4), ambiente naturale (5, 6) oppure da gallerie di immagini online (7).

## Contributo del *deep-learning* per la sorveglianza entomologica

Approcci di riconoscimento e classificazione basati sul *deep-learning* di insetti adulti sono stati applicati con successo soprattutto nel settore dell'agricoltura intensiva (8). La ragione dell'ampio utilizzo di questi metodi risiede nel fatto che i tradizionali sistemi di sorveglianza entomologica risultano spesso complessi e non completamente efficaci nello stimare la presenza e l'abbondanza delle specie dannose. Un minor numero di lavori riguarda invece insetti di interesse sanitario; in particolare, le CNN vengono utilizzate con l'obiettivo di distinguere diverse specie appartenenti ai tre principali generi di zanzare vettori di patogeni, vale a dire *Anopheles*, *Aedes* e *Culex* (6, 9). In questo ambito, da citare è il lavoro di Couret *et al.* (10) in cui una CNN è stata in grado di distinguere quattro specie del complesso *Anopheles gambiae sensu lato* (s.l.), estraendo *feature* specifiche per ciascuna di esse con accuratezze superiori al 90%. Il complesso di specie *Anopheles gambiae* s.l. comprende entità tassonomiche pressoché indistinguibili morfologicamente, ma che possono essere identificate sulla base di differenze genetiche. Data la

grande difficoltà di distinguere le minime e impercettibili differenze morfologiche tra le quattro specie del complesso, quest'ultimo studio sottolinea la capacità delle CNN di estrarre autonomamente le *feature* per ogni classe da riconoscere senza avere esplicite istruzioni su quali strutture siano diagnostiche per l'identificazione. Lo studio condotto da Park et al. (3) su 8 specie appartenenti ai generi *Anopheles*, *Aedes* e *Culex* ha rivelato come le diverse *feature* estratte dalla rete neurale avessero un "peso" diverso nella classificazione; ad esempio, la forma della zampa o la forma dei palpi, suscettibili a rotture o alterazioni, contribuivano in misura minore nella catalogazione.

Lavori di questo tipo hanno aperto nuovi scenari per la sorveglianza entomologica; requisito fondamentale per la raccolta di dati entomologici affidabili è la disponibilità di strumenti di cattura efficaci e capaci di rappresentare il più oggettivamente possibile la situazione sul campo. L'attività di sorveglianza entomologica è tuttora basata prevalentemente su una prima identificazione morfologica da parte di operatori esperti a seguito di una cattura mediante trappola, con un eventuale successivo passaggio di analisi molecolare di sequenze geniche specie-specifiche dell'insetto e/o di quelle diagnostiche della presenza nell'insetto di specifici patogeni. Queste attività risultano un processo laborioso che limita la quantità e la qualità dei dati nel tempo e nello spazio, con la possibilità di produrre parametri entomologici inadeguati e, conseguentemente, attività di prevenzione e risposta non corrette. Lo sviluppo e l'utilizzo di un algoritmo di *deep-learning* per l'identificazione/conteggio automatico e remoto può consentire l'ampliamento e l'ottimizzazione delle campagne di sorveglianza, generando inoltre omogeneità nelle procedure.

Approcci basati su strumenti di apprendimento artificiale vengono sviluppati con crescente attenzione in campo entomologico anche per la loro capacità di stimare correttamente abbondanza, biomassa, diversità e localizzazione di popolazioni di insetti (11), in particolare nella prospettiva di controllare questi parametri in aree urbane (12). L'analisi di immagine di insetti adulti, oggetto di questo articolo, è solo uno degli aspetti su cui tali approcci si stanno sviluppando; altre aree di interesse sono la rilevazione e l'analisi di parametri geografici, ecologici e ambientali per la geolocalizzazione di insetti di interesse agronomico o sanitario o, ancora, la rilevazione e identificazione basata sul ronzio provocato dal battito alare mediante opportuni sensori acustici e pseudo-acustici (12). In questo scenario, stanno affacciandosi con crescente rilevanza anche le attività di monitoraggio individuale e volontario collettivamente raccolte sotto l'etichetta di *citizen science*. La integrazione di approcci di *deep-learning* con entrambe queste attività rappresenterebbe un decisivo salto di qualità nell'ambito della sorveglianza entomologica. Tuttavia, raggiungere questo obiettivo richiederà di delineare specifici modelli operativi e soluzioni tecnologiche a seconda delle diverse tipologie di attività e di scenari.

## Applicazioni del *deep-learning*

### Scenario 1: monitoraggio in aree a rischio di malattie a trasmissione vettoriale

Uno degli scenari in cui il *deep-learning* può trovare applicazione è il rapido intervento per l'identificazione e localizzazione di insetti vettori di patogeni in un determinato territorio; ad esempio, quando si tratta di circoscrivere un possibile focolaio epidemico in seguito ad uno o più casi clinici provocati da un dato patogeno a trasmissione vettoriale oppure nell'ispezionare un territorio per la potenziale presenza di patogeni a trasmissione vettoriale prima di collocare insediamenti e attività.

In questi casi, la classificazione a livello di genere è spesso sufficiente per selezionare gli esemplari su cui condurre saggi di amplificazione genica patogeno-specifici. L'analisi morfologica degli insetti condotta sui singoli esemplari da personale specializzato, seppur con

chiavi dicotomiche e criteri semplificati, limita necessariamente ampiezza e velocità dell'indagine. In alternativa, lo sviluppo di un protocollo che preveda una semplice fotografia, che contenga tutti gli esemplari ottenuti in una cattura, e il suo immediato processamento mediante una CNN istruita a restituire la classificazione a livello di genere, consentirebbe di selezionare un elevato numero di esemplari per l'analisi molecolare in tempi brevissimi e con precisione. Un simile protocollo si inserirebbe in una filiera "cattura-classificazione del vettore-identificazione molecolare del patogeno" affidabile anche ad operatori non esperti, suscettibile di significativo *scaling up*.

## Scenario 2: prevenzione dell'introduzione e diffusione di nuovi vettori e patogeni

Globalizzazione e cambiamenti climatici motivano l'importante obiettivo della sorveglianza entomologica di rilevare tempestivamente l'introduzione nel territorio nazionale di specie esotiche di vettori. In questo campo le attività di cattura prevedono il monitoraggio dei potenziali mezzi di trasporto e punti d'ingresso (porti, aeroporti, ecc.). L'incertezza a priori di quali specie invasive possano presentarsi e la prevista sporadicità degli esemplari nelle catture sono i principali punti critici. A complicare ciò, si aggiunge la difficoltà di individuare le stesse specie invasive, in quanto possono presentare differenze morfologiche minime rispetto alle specie congeneriche autoctone (13).

La prospettiva di sviluppare una filiera di saggi analoga a quella descritta sopra impone di affrontare due ostacoli proprio a partire dallo sviluppo dell'algoritmo. Il primo ostacolo riguarda l'allestimento di una galleria di immagini per il *training set* che permetta l'individuazione di oggetti rari. Il secondo ostacolo è l'identificazione a livello di specie che l'algoritmo dovrà raggiungere per discriminare e classificare gli oggetti analizzati. Nel primo caso, il passaggio di *augmentation* può essere sfruttato per bilanciare la galleria di immagini del training set aumentando il numero di immagini delle specie invasive bersaglio rispetto a quello delle immagini delle specie autoctone, anche con la creazione di immagini artificiali (14). Nel secondo caso è possibile l'integrazione di due diversi algoritmi di cui uno riconosce il genere e l'altro la specie, limitatamente a quelle presenti sul territorio; in questo modo una prima classificazione a livello di genere sarà attesa per tutti gli esemplari, mentre gli esemplari che il secondo algoritmo non sarà in grado di classificare oltre il livello di genere potranno essere oggetto di allerta e soggetti ad analisi, sia morfologica esperta che molecolare.

## Scenario 3: supporto alla *citizen science*

Il potenziale contributo della *citizen science* alla sorveglianza entomologica è documentato dai primi successi quale l'individuazione della comparsa di *Aedes japonicus* nel Nord-Ovest della Spagna nell'ambito del progetto *Mosquito Alert* (15). In questo progetto, fotografie di insetti, insieme alle coordinate geografiche, vengono inviate via smartphone ad entomologi che le analizzano per una identificazione dell'esemplare (vedi il contributo di Caputo *et al.* in questo volume). Alcune applicazioni permettono l'identificazione attraverso una sequenza di passaggi interattivi tra l'utente e gallerie di immagini, ad esempio di zanzare anofeline (16).

Anche in questo settore, algoritmi di *deep-learning* per classificare le immagini cominciano ad essere oggetto di ricerca e sviluppo. L'applicazione scaricabile su smartphone *Seek* di *iNaturalist* permette di associare ad una immagine raccolta in modalità video una possibile assegnazione a livello di specie in tempo reale, sfruttando una CNN ([www.seek.org](http://www.seek.org)).

Il fatto che la raccolta delle immagini di insetti nei progetti di *citizen science* sia affidata a iniziative volontarie e individuali da un lato ha il potenziale di raccogliere informazioni originali da ambienti e localizzazioni geografiche normalmente ignorate da attività di sorveglianza entomologica istituzionali.

D'altra parte, per gli stessi motivi, questo contributo manca della sistematicità spazio temporale che assicurerebbe la robustezza attesa per un'attività sentinella.

#### **Scenario 4: sviluppo di un sistema “cattura-identificazione” automatizzato**

Lo sviluppo delle applicazioni di *deep-learning* capaci di classificare immagini in tempo reale permette di ipotizzare che un analogo salto di qualità possa essere applicato alla sorveglianza entomologica di vettori di interesse sanitario. Questo implica integrare in un unico sistema la cattura di insetti, l'acquisizione di immagine (verosimilmente da video) e l'analisi tramite una CNN, con trasmissione di dati da remoto.

Alcuni prototipi di questo tipo di trappole complesse sono già stati sviluppati, come quelli capaci di attirare falene in trappole dove sono immobilizzate e fotografate, oppure filmate in volo, per essere identificate tramite reti neurali che inviano i risultati a server dedicati (17-19). Questi risultati sono incoraggianti nel tentativo di estendere questi protocolli e sistemi integrati al monitoraggio di insetti di rilevanza sanitaria.

Il vantaggio di sviluppare sistemi di riconoscimento e monitoraggio in tempo reale di insetti, a livello di genere se non di specie, rappresenterebbe un salto di qualità sia nel sistema di sorveglianza territoriale che nella sorveglianza di specie invasive in punti d'ingresso.

Nel primo caso, permetterebbe il monitoraggio costante in sistemi di sorveglianza in cui oggi la predisposizione e successiva ispezione delle trappole avviene con cadenza variabile nelle diverse stagioni, ad esempio quindicinale (*vedi* il contributo di Calzolari *et al.* in questo volume), con un importante dispendio di risorse economiche ed umane.

Nel secondo caso, il riconoscimento in tempo reale di vettori sospetti nella ispezione di aeromobili in transito o di convogli marittimi o terrestri permetterebbe di intervenire immediatamente con misure di controllo specifiche e mirate.


## **Approcci di *deep-learning* per applicazioni in entomologia medica all'Istituto Superiore di Sanità**

Un gruppo di lavoro trasversale dell'Istituto Superiore di Sanità (ISS), che unisce ricercatori del Dipartimento di Malattie Infettive (reparto di Malattie Trasmesse da Vettori) e del Centro Nazionale Protezione dalle Radiazioni e Fisica computazionale, ha iniziato ad applicare approcci di *deep-learning* allo studio della motilità cellulare del parassita malarico *Plasmodium falciparum* e sta ora affrontando le tematiche qui descritte, applicando tali approcci al riconoscimento di artropodi di interesse sanitario.

Nell'ambito del progetto del Piano Nazionale di Ricerca Militare del Ministero della Difesa “Cattura Caratterizzazione Controllo di artropodi vettore e relativi patogeni-C3LAB”, una collaborazione tra Policlinico Militare di Roma, ISS e Sapienza Università di Roma, è iniziata in ISS un'attività che punta a realizzare un algoritmo di *deep-learning* in grado di identificare, a livello di genere, zanzare e flebotomi raccolti e fotografati in trappole entomologiche.

L'algoritmo è concepito per essere integrato in un protocollo di “cattura-classificazione del vettore-identificazione molecolare del patogeno” affidabile anche ad operatori non esperti, ad uso civile in emergenze epidemiologiche o militare in missioni in paesi endemici.

Il *workflow* generale per la costruzione di un suddetto algoritmo prevede una serie di passaggi riportati in Figura 4.



**Figura 4. Workflow utilizzato per lo sviluppo di un algoritmo di *deep-learning* per l'identificazione e classificazione di zanzare e flebotomi da trappole entomologiche**

Vediamo nel dettaglio le varie fasi:

1. Creazione di un data set di immagini a partire da esemplari disponibili negli insettari dell'ISS e dell'Università di Roma La Sapienza, grazie a collaborazioni con i gruppi di ricerca del Dott. Marco Di Luca (Dipartimento di Malattie Infettive, ISS) e del Prof. Marco Pombi (Istituto di Sanità Pubblica e Malattie Infettive, Sapienza Università di Roma). Le fotografie ritrarranno esemplari dei generi di interesse, insieme ad altri insetti che non rivestono importanza sanitaria e che possono essere rinvenuti nelle trappole sul campo, in configurazioni che imitano le condizioni di una reale cattura.
2. Organizzazione del data set e applicazione di un passaggio di *augmentation* mediante il software dedicato *Roboflow* (20), al fine di ottenere una collezione di immagini sufficientemente grande e bilanciata per ogni categoria (genere) da riconoscere.
3. Annotazione da parte di entomologi esperti delle immagini del data set per introdurre i "tag" genere-specifici in corrispondenza degli esemplari, sempre mediante *Roboflow* (20), ed esportazione del data set in formato leggibile dall'algoritmo.
4. Suddivisione casuale delle immagini in un *training set* (70% del data set), in cui le immagini saranno utilizzate dall'algoritmo per estrarre le feature, un *validation set* (20%), in cui saranno utilizzate per valutare l'apprendimento, e un *test set* (10%), in cui saranno utilizzate per misurare l'efficienza dell'algoritmo nel riconoscimento delle categorie.
5. Utilizzo dell'algoritmo di *deep-learning Yolo-v5PyTorch* (21) sui data set precedentemente creati per la configurazione di una CCN. La *performance* della CNN verrà valutata attraverso i parametri di *precision* (precisione), *recall* (sensibilità) e *F1 score*. La *precision* e il *recall* sono due indicatori, inversamente correlati, utili a valutare la qualità di un modello decisionale o di un modello predittivo. Per *precision* si intende il rapporto tra il numero delle previsioni corrette di un evento (categoria) sul totale delle volte che il modello lo prevede, mentre la *recall* è il rapporto tra le previsioni corrette per una classe sul totale dei casi in cui si verifica effettivamente. La metrica denominata *F1 score* bilancia i due

precedenti parametri e restituisce un valore di riferimento per i successivi passaggi di ottimizzazione della CNN. Tanto più è elevato questo parametro, tanto più alti sono i valori associati a *precision* e *recall*, indicando una buona *performance* dell'algoritmo.

## Bibliografia

1. Okayasu K, Yoshida K, Fuchida M, Nakamura A. Vision-based classification of mosquito species: comparison of conventional and deep learning methods. *Applied Sciences*. 2019;9(18):3935.
2. He HZ, Fan Y, Ji S, Wu J. Application of deep learning in integrated pest management: a real-time system for detection and diagnosis of oilseed rape pests. *Mobile Information Systems* 2019;4570808.
3. Park J, Kim DI, Choi B, Kang W, Kwon HW. Classification and morphological analysis of vector mosquitoes using deep convolutional neural networks. *Sci Rep* 2020;10(1):1012.
4. Kim K, Hyun J, Kim H, Lim H, Myung H. A deep learning-based automatic mosquito sensing and control system for urban mosquito habitats. *Sensors* 2019;19(12):2785.
5. Minakshi PB, Chellappan S. Leveraging smart-phone cameras and image processing techniques to classify mosquito species. *Proceedings of the 15th EAI International Conference on Mobile and Ubiquitous Systems: Computing, Networking and Services (MobiQuitous '18)*. 2018. Association for Computing Machinery, New York, NY, USA. p. 77-86.
6. Motta D, Santos AÁB, Winkler I, Machado BAS, Pereira DADI, Cavalcanti AM, Fonseca EOL, Kirchner F, Badaró R. Application of convolutional neural networks for classification of adult mosquitoes in the field. *PLoS One* 2019 14(1):e0210829.
7. Fuchida M, Pathmakumar T, Mohan RE, Tan N, Nakamura A. Vision-based perception and classification of mosquitoes using support vector machine. *Applied Sciences* 2017;7(1):51-62.
8. Li W, Zheng T, Yang Z, Li M, Sun C, Yang X. Classification and detection of insects from field images using deep learning for smart pest management: A systematic review. *Ecological Informatics* 2021;66:101460.
9. Lorenz C, Ferraudo AS, Suesdek L. Artificial Neural Network applied as a methodology of mosquito species identification. *Acta Trop* 2015 152:165-9.
10. Couret J, Moreira DC, Bernier D, Loberti AM, Dotson EM, Alvarez M. Delimiting cryptic morphological variation among human malaria vector species using convolutional neural networks. *PLoS Negl Trop Dis* 2020;14(12):e0008904.
11. Høye TT, Årje J, Bjerger K, Hansen OLP, Iosifidis A, Leese F, Mann HMR, Meissner K, Melvad C, Raitoharju J. Deep learning and computer vision will transform entomology. *Proc Natl Acad Sci USA* 2021;118(2):e2002545117.
12. Joshi A, Miller C, Review of machine learning techniques for mosquito control in urban environments, *Ecological Informatics* 2021;61:101241.
13. Ballardini M, Ferretti S, Chiaranz G, Pautasso A, Riina MV, Triglia G, Verna F, Bellavia V, Radaelli MC, Berio E, Accorsi A, De Camilli M, Cardellino U, Fiorino N, Acutis PL, Casalone C, Mignone W. First report of the invasive mosquito *Aedes koreicus* (Diptera: Culicidae) and of its establishment in Liguria, Northwest Italy. *Parasit Vectors* 2019;12(1):334. doi: 10.1186/s13071-019-3589-2.
14. Lu CY, Rustia DJ, Lin TT. Generative adversarial network based image augmentation for insect pest classification enhancement. *IFAC-PapersOnLine* 2019;52(30):1-5.
15. Eritja R, Ruiz-Arrondo I, Delacour-Estrella S, Schaffner F, Álvarez-Chachero J, Bengoa M, Puig MÁ, Melero-Alcíbar R, Oltra A, Bartumeus F. First detection of *Aedes japonicus* in Spain: an unexpected finding triggered by citizen science. *Parasit Vectors* 2019;12(1):53-62. doi: 10.1186/s13071-019-3317-y.



16. Gupta SK, Nagpal BN, Singh H, Vikram K, Nayak A, Chalga MS, Srivastava A, Joshi MC, Saxena R. Mobile App based pictorial identification key for Indian anophelines. *J Vector Borne Dis.* 2021;58(4):306-10.
17. Ding W, Taylor G. Automatic moth detection from trap images for pest management. *Computers and Electronics in Agriculture* 2016;123:17-28.
18. Bjerger K, Nielsen JB, Sepstrup MV, Helsing-Nielsen F, Høye TT. An automated light trap to monitor moths (lepidoptera) using computer vision-based tracking and deep learning. *Sensors (Basel)* 2021;21(2):343-60.
19. Brydegaard M, Jansson S, Malmqvist E, Mlacha YP, Gebru A, Okumu F, Killeen GF, Kirkeby C. Lidar reveals activity anomaly of malaria vectors during pan-African eclipse. *Sci Adv* 2020;6(20):eaay5487.
20. Alexandrova S, Tatlock Z, Cakmak M. RoboFlow: a flow-based visual programming language for mobile manipulation tasks. *IEEE International Conference on Robotics and Automation* 2015:5537-44.
21. Redmon J, Divvala S, Girshick R, Farhadi A. You only look once: unified, real-time object detection. *IEEE Conference on Computer Vision and Pattern Recognition* 2016; 779-88.