



UNIVERSITÀ DEGLI STUDI DI PADOVA

Dipartimento di Agronomia, Animali, Alimenti, Risorse naturali e
Ambiente

Dipartimento di Biomedicina comparata ed Alimentazione

CORSO DI LAUREA MAGISTRALE
IN SCIENZE E TECNOLOGIE AGRARIE

Approcci di machine learning per la valutazione del
comportamento di galline ovaiole in sistemi cage free

Relatore: Prof. Angela Trocino
Correlatori: Prof. Francesco Marinello
Dott. Marco Sozzi

Laureando
Alessandro Bordignon
Matricola n. 1240704

ANNO ACCADEMICO 2021/2022

INDICE

INDICE	1
RIASSUNTO	2
ABSTRACT	4
INTRODUZIONE	6
1. PRODUZIONE DI UOVA DA CONSUMO E SISTEMI DI PRODUZIONE.....	6
2. BENESSERE DELLE GALLINE OVAIOLE NEI SISTEMI CAGE FREE	11
3. SISTEMI INNOVATIVI PER LA VALUTAZIONE DEL BENESSERE IN ALLEVAMENTO	20
LIVESTOCK PRECISION FARMING (PLF)	21
MACHINE LEARNING (ML).....	25
MACHINE LEARNING PER LA VALUTAZIONE DELLA DISTRIBUZIONE IN ALLEVAMENTO E DEL COMPORTAMENTO DEGLI ANIMALI	26
OBIETTIVI	31
CASO STUDIO	32
DESCRIZIONE DELL'ALLEVAMENTO	32
SISTEMA DI REGISTRAZIONE E TEMPI DI REGISTRAZIONE	35
DATASET	35
ALGORITMO DI RILEVAMENTO DEGLI OGGETTI.....	37
RETE CONVOLUZIONALE YOLO.....	39
VERSIONI DI YOLO UTILIZZATE IN QUESTO LAVORO.....	41
ACQUISIZIONE DATI.....	42
ETICHETTATURA	43
DATA AUGMENTATION	45
SETTAGGIO DI GOOGLE COLAB	46
TRAINING DEL MODELLO	47
VALIDAZIONE.....	50
FASE DI TEST	52
CONCLUSIONI	58
BIBLIOGRAFIA	60

RIASSUNTO

I numerosi limiti dell'allevamento in gabbia compromettono la qualità della vita degli animali, la quale risulta sempre più importante agli occhi del consumatore. Sono diverse, infatti, le istanze che opinione pubblica e ONG hanno presentato al legislatore dagli anni 60 fino ad oggi. Sebbene i sistemi di allevamento in gabbia siano tuttora largamente utilizzati in UE per l'allevamento di galline ovaiole, dati i vantaggi in termini di sanità, controllo ed efficienza economica, i sistemi cage free rappresentano un'alternativa valida e sono ritenuti migliori da parte dei consumatori. I sistemi cage free, nei quali sono accasate circa il 50% delle ovaiole allevate in Europa, forniscono fondamentalmente una maggiore libertà di movimento e di espressione del repertorio comportamentale specie-specifico. Il passaggio dai sistemi in gabbia a quelli senza gabbia presenta però diversi punti critici. Un ambiente più libero in cui i gruppi di animali sono molto numerosi promuove comportamenti negativi quali cannibalismo e soffocamento. Queste problematiche hanno un impatto sul benessere animale che deve essere limitato. Le prime permettono di raccogliere tramite sensori grosse quantità di dati digitali, le seconde consentono l'elaborazione degli stessi. Il ML, o apprendimento automatico, utilizza sofisticati metodi statistici in grado di estrapolare e mettere in relazione enormi moli di dati. Ciò permette di ricavare informazioni, anche in tempo reale, relative alla condizione degli animali, incluso lo stato di benessere animale. L'utilizzo di algoritmi di *deep learning*, o reti neurali, che si occupano di *Object recognition* è uno dei modi attraverso il quale è possibile sfruttare il ML. Questi algoritmi analizzano le immagini al fine di ottenere informazioni come la collocazione degli animali, la densità o l'esecuzione di un certo comportamento.

Fatte queste premesse, la presente tesi di laurea ha inteso creare un sistema autonomo per il rilievo della densità delle galline ovaiole allevate in aviari, utilizzando l'algoritmo YOLO (You Only Look Once). L'obiettivo è quello di monitorare, e in futuro prevenire, le condizioni che possono portare all'affollamento e al soffocamento degli animali. Inoltre, il sistema ha valutato la possibilità di monitorare il benessere degli animali in termini di comportamenti di comfort e, nello specifico, in termini di animali impegnati nel bagno di sabbia. Allo scopo, sono state utilizzate le video registrazioni del comportamento degli animali a terra all'interno

di un sistema ad aviario diviso in 8 moduli, a partire dalla trentacinquesima settimana di vita delle galline. I video sono stati successivamente divisi in singole immagini e sono state etichettate manualmente 1150 immagini entro le quali sono state individuati i singoli capi distinguendo due categorie, i.e. animali a terra (*ground*) e animali a terra impegnati nel bagno di sabbia (*dust*), comportamento funzionale e specie specifico. Le immagini etichettate sono state poi divise in 2 data set, il primo, il *training set*, utilizzato per l'addestramento dell'algoritmo, l'altro, il *test set*, utilizzato alla fine in fase di valutazione. Sono state valutate con le stesse immagini due diverse versioni di YOLO, YOLO v4 e YOLO v4-tiny al fine di individuare il più veloce e preciso algoritmo rispetto al conteggio delle galline presenti sulla lettiera e rispetto alla capacità di individuare quelle impegnate nel bagno di sabbia. I risultati mostrano che entrambi gli algoritmi presentano un'elevata accuratezza, circa 95%, riuscendo ad individuare e classificare correttamente le galline sulla lettiera. Il modello che presenta maggior velocità, circa 208,45 FPS, con precisione elevata, 95%, è risultato il modello v4-tiny. In conclusione, la presente tesi ha dimostrato la possibilità di utilizzare un sistema di ML per il conteggio degli animali a terra e quelli impegnati nel bagno di sabbia. In prospettiva, un sistema in grado di contare automaticamente gli animali e inviare un segnale di allarme nel caso di eccessivo affollamento degli animali a terra (o in altre parti dell'aviario) consentirebbe di monitorare le situazioni di pericolo associate ad affollamento e mortalità per soffocamento degli animali. Inoltre, vi è la possibilità di monitorare la condizione generale di benessere degli animali verificando che questi possano svolgere regolarmente il bagno di sabbia all'interno della struttura di allevamento.

ABSTRACT

The many limitations of cage farming compromise the quality of life of animals, which is increasingly important for the consumers. Indeed, there are several instances that public opinion and NGOs have presented to the legislature from the 1960s until today. Although cage systems are still widely used in the EU for rearing laying hens, given the advantages in terms of health, control, and economic efficiency, cage-free systems are a viable alternative and are considered better by consumers. Cage-free systems, in which around 50% of the laying hens bred in Europe are housed, basically provide greater freedom of movement and expression of the species-specific behavioural repertoire.

However, the transition from caged to cage-free systems has several critical points. A free environment, in which groups of animals are very large, promotes negative behaviors such as cannibalism and suffocation. These issues have an impact on animal welfare that must be limited. In today's complex rearing environment of laying hens, monitoring and studying the dynamics that lead to problems in large groups of hens is possible using new technologies of precision livestock farming (PLF) and machine learning (ML). The former allows large amounts of digital data to be collected via sensors, and the latter allows the processing of the same data. ML uses sophisticated statistical methods that can extrapolate and relate huge masses of data. This makes it possible to obtain information, even in real time, on the condition of animals, including the state of animal welfare. The use of deep learning algorithms, or neural networks, dealing with Object recognition is one of the ways through which ML can be exploited. These algorithms analyze images to obtain information such as animal location, density, or execution of certain behavior.

Having said that, this thesis aimed at creating an autonomous system for surveying the density of laying hens kept in aviaries, using the YOLO (You Only Look Once) algorithm. The goal was to monitor, and in the future prevent, conditions that can lead to crowding and suffocation of animals. In addition, the system evaluated the possibility of monitoring animal welfare in terms of comfort behaviours and, specifically, in terms of animals engaged in sand bathing.

For this purpose, video recordings of the behaviour of the animals on the ground

were used within an avian system divided into 8 modules, starting from the thirty-fifth week of life of the hens. The videos were then divided into individual images and 1150 images were manually labelled within which individual animals were identified by distinguishing two categories, i.e. animals on the ground (ground) and animals on the ground engaged in sand bathing (dust), functional and species-specific behaviour.

The labelled images were then divided into 2 data set, the first, the training set, used for training the algorithm, and the other, the test set, used at the end of the evaluation. Two different versions of YOLO, YOLO v4 and YOLO v4-tiny, were evaluated with the same images to identify the fastest and most accurate algorithm with regard to counting the hens on the litter and with regard to the ability to detect those engaged in sand bathing. The results show that both algorithms exhibit high accuracy, about 95%, being able to correctly identify and classify the hens on the litter. The model that has the highest speed, about 31.35 FPS, with high accuracy, 95%, was the v4-tiny model.

In conclusion, this thesis has demonstrated the possibility of using an ML system to count animals on land and those engaged in sand bathing. In perspective, a system capable of automatically counting the animals and sending an alarm signal in the event of excessive crowding of animals on the ground (or in other parts of the avarium) would make it possible to monitor dangerous situations associated with crowding and mortality due to suffocation of the animals. Moreover, there is the possibility of monitoring the general welfare condition of the animals by verifying that they can regularly perform the sand bath within the farm facility.

INTRODUZIONE

1. PRODUZIONE DI UOVA DA CONSUMO E SISTEMI DI PRODUZIONE

La domanda di alimenti di origine animale è in costante crescita a causa dell'aumento demografico, dell'aumento del reddito medio e dallo sviluppo dei centri urbani (FAO, 2018). Alexandratos e Bruinsma (2012) hanno previsto un incremento della quantità degli alimenti di origine animale pari al 70% tra il 2005 e il 2050. In particolare, per la produzione di uova, è atteso un incremento del 65%. Le uova sono un alimento che presenta caratteristiche peculiari che lo diversificano da altri prodotti di origine animale. Sono una fonte di proteine a basso costo e ad elevato valore biologico, sono disponibili in tutto il mondo e rivestono un ruolo importante soprattutto per la dieta di una parte della popolazione a basso reddito (Sumner *et al.*, 2011). È possibile controllarne la freschezza mantenendo una shelf life elevata, dalle 3 fino alle 5 settimane dalla deposizione (USDA, 2019).

Questo alimento è anche alla base di numerose preparazioni culinarie date le molteplici proprietà tecnologiche (emulsionante, schiumogeno, colorante) (Stadelman, 1999). Per il consumo dell'uovo, non ci sono inoltre pregiudizi religiosi o etnici. Si tratta quindi di un alimento che, tal quale o trasformato, presenta caratteristiche uniche che lo portano da essere potenzialmente presente in qualsiasi dieta umana.

I dati pubblicati dalla FAO mostrano come la produzione mondiale di uova sia aumentata del 25% circa nell'ultimo decennio, passando da 63 milioni di tonnellate nel 2009 a 83 milioni di tonnellate nel 2019 (Figura 1). La Cina è il più grande produttore di uova seguito dagli Stati Uniti e UE (Figura 2) (FAOSTAT, 2021).




Figura 1. Produzione mondiale di uova di gallina (X 1000 tonnellate) (FAOSTAT, 2021)




Figura 2. Quota di produzione di uova per regione (FAOSTAT, 2021)

In Italia la produzione di uova si attesta su oltre 12,3 miliardi di uova (2019), ciò la colloca al quarto posto tra i produttori comunitari dopo Francia, Germania e Spagna (ISMEA, 2020). In Italia il consumo si attesta sulle 214 uova all'anno, fra consumo diretto e indiretto. Il 55% delle uova prodotte proviene da allevamenti convenzionali, tuttavia, meno della metà di queste entra nel circuito della grande distribuzione organizzata per la vendita diretta. La parte maggioritaria è destinata all'industria alimentare per la produzione di ovo-prodotti.

Il consumatore negli anni ha dimostrato un crescente apprezzamento verso le uova da allevamenti che non usano gabbie, definiti anche *cage-free*, considerate a più alto valore etico: nel 2018, le uova da allevamento a terra hanno coperto il 45% del volume di mercato, con un incremento del 28%, quelle biologiche il 9%, con un incremento del 12% rispetto al 2017. Le uova provenienti da allevamenti tradizionali (gabbie arricchite) hanno invece subito una flessione del 19% rispetto al 2017, confermando il trend negativo degli anni precedenti (ISMEA, 2018).

Le galline ovaiole sono tra gli animali maggiormente allevati in gabbia in Europa. Di circa 400 milioni di capi allevati all'anno, il 50% vengono allevati in gabbia (Figura 3 e 4).




Figura 3. Ripartizione percentuale degli animali per tipologia di allevamento-UE (ISMEA, 2020)




Figura 4. Ripartizione percentuale degli animali per tipologia di allevamento-Italia (ISMEA, 2020)

A partire dal primo gennaio del 2012 le gabbie convenzionali sono state vietate per le galline ovaiole in tutto il territorio UE (direttiva 1999/74/CE). Ciò a seguito del crescente numero di istanze di una parte della popolazione rispetto al benessere animale. Le maggiori problematiche riscontrate in questo sistema di allevamento riguardavano la limitazione di spazio fisico e un mancato soddisfacimento di alcune delle esigenze comportamentali degli animali (Duncan, 2001; EFSA, 2020)

Ciò ha portato il mercato ad orientarsi verso l'adozione di gabbie arricchite, più spaziose e confortevoli per le ovaiole. Rispetto alle gabbie tradizionali, le gabbie arricchite presentano una superficie maggiore per capo (750 cm² rispetto a 550 cm²) oltre ad elementi di "arricchimento" che permettono agli animali di manifestare un comportamento naturale (posatoi, lettiera e nido), migliorando il benessere animale e, contemporaneamente, mantenendo elevati standard produttivi e igienici (Tactacan *et al.*, 2009; Campbell, *et al.*, 2019).

La presenza di condizioni controllate negli allevamenti in gabbia e in gabbie arricchite presenta alcuni vantaggi legati all'efficienza economica e al controllo di malattie e parassiti. Un ambiente complesso come quello degli allevamenti cage-free o con accesso all'esterno limita il controllo e la pulizia dell'allevamento e i grandi gruppi di galline presenti facilitano la circolazione di patogeni. Tuttavia, vi è una crescente pressione da parte dell'opinione pubblica diretta a eliminare le gabbie come tecnica di allevamento. L'iniziativa dei cittadini europei "End the Cage Age", lanciata nel 2018 e presentata alla Commissione europea nell'ottobre del 2020, chiede il divieto delle gabbie negli allevamenti zootecnici in tutta Europa. In risposta, la Commissione Europea ha richiesto all'EFSA nuove *scientific opinions* che descrivano le migliori pratiche per sistemi cage-free e che forniscano un parere scientifico sul benessere animale negli allevamenti, proponendo pratiche alternative alla stabulazione in gabbia (EFSA, 2020). Migliorare il benessere animale negli allevamenti è uno dei punti chiave della nuova strategia europea Farm to Fork. Questa politica mira a rendere le pratiche agricole più sostenibili, orientando la produzione verso pratiche alternative come i sistemi biologici.

Per quanto riguarda gli allevamenti, la strategia Farm to Fork si propone di intervenire su tutta la filiera produttiva orientando gli interventi all'allevamento, al trasporto e alla macellazione (European Commission, 2020). Per quanto riguarda

le galline ovaiole, i metodi alternativi alla gabbia arricchita (o modificata¹) ammessi in Europa sono: sistemi a terra, aviari compresi, sistemi all'aperto e sistemi biologici. Questi sistemi di stabulazione, seppur consentendo agli animali di esprimere un comportamento naturale, presentano ancora numerose criticità come di seguito discusso.

¹ Gabbie convenzionali modificate secondo dalla direttiva 1999/74/CE

2. BENESSERE DELLE GALLINE OVAIOLE NEI SISTEMI CAGE FREE

La necessità di una maggiore sicurezza alimentare e la maggiore richiesta di proteine di origine animale della seconda metà del Novecento hanno comportato una rivoluzione in zootecnia. Per far fronte a queste necessità sono stati compiuti numerosi cambiamenti sia a livello di allevamento che di miglioramento genetico degli animali allevati.

Questo processo di cambiamento, orientato a massimizzare esclusivamente la produzione, non ha però tenuto conto delle conseguenze sul benessere fisico e mentale dell'animale, considerato solo se dannoso agli obiettivi di resa prefissati. Gli effetti negativi sul benessere degli animali sono una inevitabile conseguenza di questo cambiamento e scaturiscono da molteplici fattori quali: allevamento selettivo per i tratti ad alta produzione; selezione genetica per i caratteri economicamente importanti, con effetti indiretti sulla reattività degli animali; limitazione del movimento degli animali e del contatto fra loro (Ferrante, 2008; Koknaroglu and Akunal, 2013; Grandin and Deesing, 2014). Queste problematiche legate al benessere animale negli allevamenti commerciali sono state per la prima volta messe in evidenza ed enfatizzate nel 1964 con la pubblicazione del libro "Animal Machines" di Ruth Harrison. L'autrice esponeva e faceva conoscere al grande pubblico la questione del benessere animale negli allevamenti intensivi. La pubblicazione di questo libro ebbe un certo impatto sull'opinione pubblica e sollecitò la Gran Bretagna ad affrontare queste tematiche attraverso un comitato governativo. I risultati di questa indagine furono pubblicati nel 1965 nel Rapporto Brambell che, oltre ad affermare la scarsità di studi sul benessere degli animali da allevamento, forniva una delle prime definizioni di *welfare* e proponeva una lista delle "cinque libertà fondamentali degli animali". Questa lista è stata poi modificata e perfezionata dal *Farm Animal Welfare Council* (FAWC) (2021) fino alle definizioni oggi conosciute:

- 1) libertà dalla fame e dalla sete;
- 2) libertà dal disagio;
- 3) libertà da dolore, ferite e malattie;
- 4) libertà di esprimere un comportamento normale;
- 5) libertà dalla paura e dal distress.

Nel 1987 anche l'Agricultural Committee del Parlamento Europeo pubblicava un report sul benessere degli animali allevati, nel quale giungeva a conclusioni analoghe al Rapporto Brambell. Questo ha spinto la Commissione europea ad adottare misure urgenti per la gestione dei sistemi di allevamento intensivi (Ferrante, 2008).

Per quanto riguarda la protezione delle galline ovaiole da parte dell'Unione Europea, nel 1988 è stata approvata dalla CEE la Direttiva 88/166 relativa alla protezione delle galline ovaiole in batteria. Tale direttiva forniva i requisiti minimi che le gabbie dovevano soddisfare. La direttiva Direttiva 88/166 è stata abrogata quando è entrata in vigore la Direttiva UE 1999/74 che bloccava prima, e poi vietava del tutto, gli impianti con gabbie tradizionali a partire dal 2012 e introduceva tre diverse tipologie di allevamento:

- allevamento in gabbia tradizionale (non modificate);
- allevamento in gabbie arricchite;
- allevamento in sistemi alternativi alla gabbia; in questa categoria ricadono i sistemi cage-free.

Inoltre, con il Regolamento 1804/99, la CE normava l'allevamento dell'ovaiola con il metodo biologico. La direttiva UE 1999/74 e la direttiva 98/58/CE costituiscono la normativa di riferimento per quanto riguarda il benessere della gallina ovaiole. La direttiva UE 1999/74 (recepimento: DL 267/2003) è la normativa specifica che stabilisce norme minime per la protezione delle galline ovaiole, mentre la direttiva 98/58/CE (recepimento: DL 146/2001) definisce norme minime per la protezione di tutti gli animali negli allevamenti. Queste direttive, oltre a definire parametri tecnici, come il dimensionamento degli impianti e delle gabbie, riportano disposizioni sulle condizioni da monitorare e garantire nell'allevamento per il benessere animale, oltre che indicazioni sul controllo, la verifica e gli obblighi dell'allevatore.

Come per gli altri animali, le condizioni di benessere della gallina ovaioia possono essere misurate utilizzando indicatori diretti, o animal-based, che riguardano le reazioni degli animali, o indiretti, se analizzano l'ambiente e tutto ciò che è esterno al corpo animale. Nella Tabella 1 vengono riportati gli indicatori diretti e indiretti utili alla valutazione dello stato di benessere di animali allevati (Ferrante, 2008).

Tabella 1: indicatori diretti (animal based) e indiretti per valutare il grado di benessere animale (Ferrante, 2008).

TIPOLOGIA DI INDICATORE	INDICATORE	MISURA EFFETTUATA
DIRETTI	Etologici	Test comportamentali Anomalie comportamentali
	Fisiologici	Immunitari, metabolici
	Patologici	Patologie, mortalità, lesioni, disordini metabolici
	Produttivi	Fertilità, quantità e qualità della produzione
INDIRETTI	Strutture e sistemi di allevamento	Tipo di stabulazione, areazione, sistema di ventilazione
	Gestione	Cure individuali, manutenzione impianti, alimentazione
	Relazione uomo-animale	Quantità e qualità

Naturalmente, l'espressione del comportamento e il benessere delle galline ovaiole variano in funzione del sistema di stabulazione. Tra i sistemi tuttora più utilizzati vi è la gabbia arricchita (Figura 5), questa dovrebbe consentire un aumento dell'espressione dei comportamenti tipici della specie rispetto alla gabbia tradizionale, tuttavia la misura in cui questi comportamenti possono essere espressi è stata messa in discussione (Hartcher and Jones, 2017).




Figura 5. Esempio di gabbia arricchita per 10 capi. Questo modello ha abbeveratoi (drinkers) e posatoi (perches) frontali, il nido (nest), oscurato da un telo, e la vaschetta per il bagno di sabbia (dustbath) posti anteriormente (Roll et al., 2009).

Per quanto riguarda l'allevamento a terra questo può declinarsi in varie tipologie. I nuovi sistemi ad aviario (Figure 6 e 7), rispetto ai sistemi a terra tradizionali, permettono uno sfruttamento tridimensionale dello spazio, portando ad un maggior numero di animali allevati a parità di superficie.

I sistemi cage free che utilizzano l'aviario presentano caratteristiche peculiari. Sono strutturati con voliere a più piani (massimo 4) di grigliato sovrapposti dove sono presenti nidi chiusi, abbeveratoi e mangiatoie e, al di sotto, nastri per la raccolta delle deiezioni. Le galline sono libere di muoversi, passando da un piano all'altro, accedendo alla zona dei nidi e al pavimento ricoperto da lettiera permanente.



Figura 6. Aviario modello Bolegg Terrace




Figura 7. Vista laterale schematica del sistema aviario Bolegg Terrace (Stratmann et al., 2015)

La libertà fornita dai sistemi cage-free, come l'allevamento a terra o in aviario, permette agli animali allevati di avere un maggior spazio e una maggiore possibilità di esibire il proprio repertorio comportamentale specie-specifico. Tra i comportamenti più interessanti in relazione al benessere animale, i comportamenti di comfort più significativi si manifestano attraverso diverse azioni quali stiracchiarsi, sbattere le ali, arruffare e lisciare le penne (preening) che sono importanti per mantenere il piumaggio in condizioni ottimali.

Questo genere di azioni è compiuto in modo, frequenza e intensità diversa a seconda del tipo di allevamento e, quindi, dello spazio e densità disponibile, oltre che a seconda di altri fattori.

Per esempio, in contesti di alta densità o di allevamento in gabbia in cui il preening è più difficile, un mantenimento inadeguato della livrea può promuovere feather pecking, attività che consiste nel beccare o strappare le piume di un altro soggetto con il becco. L'intensità e l'aggressività della beccata possono cambiare e dipendono da numerosi fattori.

Altri comportamenti tipici associati a comfort e benessere della gallina sono i bagni di sabbia e il razzolamento. Il bagno di sabbia serve all'animale per rimuovere l'eccesso di lipidi dalla cute alla base delle penne. Questa necessità fisiologica viene soddisfatta dalla gallina immergendosi e sfregando il corpo in materiale sabbioso. I granelli di sabbia, passando fra le penne, hanno un effetto leggermente abrasivo sulla cute. Sembra inoltre che questo comportamento sia utile per eliminare ectoparassiti e mantenere un certo comfort termico. La disponibilità di

un'area con materiale friabile permette anche alla gallina di razzolare e cercare il cibo (Tactacan *et al.*, 2009; Sosnówka-Czajka *et al.*, 2021). La possibilità di razzolare sulla lettiera limita la crescita eccessiva delle unghie delle zampe e quindi la possibilità di ferite (Vits *et al.*, 2005).

La particolare struttura delle voliere permette di avere posatoi ad una certa distanza dal suolo assecondando ulteriormente il comportamento naturale delle galline che cercano di raggiungere luoghi sicuri per allontanarsi dai predatori. I posatoi, inoltre, promuovono l'attività fisica dei volatili che, soprattutto nei sistemi a più livelli, compiono numerosi movimenti delle ali per spostarsi. Questa attività va a fortificare le ossa riducendo la possibilità di fratture e quindi incrementando il benessere dell'animale (Ferrante and Lolli, 2009; Rodriguez-Navarro *et al.*, 2018; Sosnówka-Czajka *et al.*, 2021).

Un ambiente libero rispetto alla gabbia confinata genera quindi diversi benefici sul benessere animale. Il maggior spazio disponibile permette alle galline di eseguire un repertorio di comportamenti più ampio, ma l'aumento della libertà dei capi può avere anche diversi risvolti negativi.

L'aumento dello spazio disponibile porta ad un aumento della dimensione dei gruppi e della complessità degli ambienti di stabulazione; ciò promuove alcuni comportamenti negativi, come il cannibalismo e soffocamento (*smothering*), che generalmente si riscontrano meno negli allevamenti in gabbia. Per definire la gravità del problema si riporta come diversi studi abbiano riportato come il feather peaking e il cannibalismo siano tra le principali cause di mortalità nelle galline ovaiole commerciali sia in allevamenti in gabbia che in quelli non in gabbia (Tabella 2) (Weitzenbürger *et al.*, 2006; Lay *et al.*, 2011).

Tabella 2: Livelli previsti di espressione comportamentale in diversi sistemi di allevamento per la produzione commerciale di uova (a seconda dello spazio e della disponibilità di risorse). + = nessuno o incompleto, ++ = relativamente basso, +++ = moderato, ++++ = pieno o relativamente alto. I risultati previsionali sono fortemente influenzati da altri fattori, tra cui condizioni e gestione dell' allevamento, ceppo, tipo di alloggiamento (Lay et al., 2011).

Opportunità comportamentali	Gabbia convenzionale	Gabbia arredata		Non gabbia (aviario)		All'aperto (ruspante)
		Piccolo	Grande	Doghe/ Lettieria	Voliere	
Volare	+	+	+	++++	++++	++++
Corsa	+	+	++	++++	++++	++++
A passeggio	++	++	+++	++++	++++	++++
Sbattere le ali	+	++	++	++++	++++	++++
Allungamento	++	+++	+++	++++	++++	++++
Pavoneggiarsi	+++	++++	++++	++++	++++	++++
In piedi	++++	++++	++++	++++	++++	++++
Seduta	+++	++++	++++	++++	++++	++++
Alimentazione	+++	+++	++++	++++	++++	++++
Potabile	+++	+++	++++	++++	++++	++++
Foraggiamento	+	++	++	+++	+++	++++
Bagno di polvere	+	++	++	++++	++++	++++
Nidificazione	+	+++	+++	++++	++++	++++
Appollaiarsi	+	++	++	+++	+++	+++
Comportamenti stereotipati e finti	++++	++	++	++	++	++
Cannibalismo e beccate di piume	++	++	+++	++++	++++	++++
Aggressione sociale	++	+++	+++	++	++	++
Soffocamento	++	++	+++	++++	++++	+++

Il soffocamento si realizza quando le galline si aggregano in gruppi molto densi di almeno 10-30 individui, quest'ultimi accatastandosi causano il soffocamento dei capi che si trovano al di sotto. Il soffocamento può portare alla morte di un numero limitato di capi (1-2) o consistente (>20), e può verificarsi una tantum o in maniera continuativa per tutto il periodo produttivo. Questo comportamento è imprevedibile, ma può verificarsi anche frequentemente portando a ingenti danni, questi possono essere stimati in una perdita tra il 2% e fino al 60% delle uova prodotte.

Ovviamente i danni aumentano se l'ammassamento avviene nelle prime fasi produttive. Le cause di questo comportamento non sono tuttora chiare e la letteratura in merito è limitata. Gray *et al.*, (2020) suggeriscono come non esista un'unica causa, ma l'ammassamento degli animali possa derivare da molteplici fattori quali: attrazione o repulsione; influenza sociale; influenza delle prime esperienze di vita; comportamento collettivo disadattivo. Non è ancora chiaro però se e quali siano le basi genetiche e quale il ruolo della paura in questi eventi.

Una maggior interazione tra i diversi individui, unita al maggior contatto con la lettiera e con le feci, facilita la trasmissione di malattie e parassiti. In uno studio scandinavo di 4 anni sulle galline ovaiole (Fossum *et al.*, 2009) è stata riscontrata una significativa differenza nell'incidenza di malattie batteriche (come erisipela, colibacillosi e pasteurellosi), virali e parassitarie nelle galline ovaiole allevate in sistemi di stabulazione con lettiera rispetto alle galline allevate in gabbia.

Lo stesso studio ha inoltre confermato un aumento di mortalità nei sistemi non in gabbia riportato anche da altri autori (Rodenburg *et al.*, 2008; Sherwin, Richards e Nicol, 2010). Il rischio di malattie infettive può però essere significativamente ridotto usando diversi approcci, come la biosicurezza e i programmi di vaccinazione (Hartcher and Jones, 2019).

Per quanto riguarda la salute dello scheletro, è stato osservato che la resistenza ossea delle ovaiole in allevamenti *cage free* è maggiore, ma il numero di vecchie fratture è superiore a quello degli allevamenti in gabbia. Ciò è dovuto all'aumento della mobilità e alla possibilità di urti dell'osso dello sterno durante gli spostamenti, soprattutto contro i posatoi. Per ridurre questo problema è possibile utilizzare posatoi morbidi o disporre in maniera strategica i posatoi (Stratmann *et al.*, 2015; Scott *et al.*, 1996; Sosnówka-Czajka *et al.*, 2021).

Un'ulteriore problematica riscontrata negli allevamenti *cage-free* riguarda la

deposizione a terra delle uova. Sebbene la maggioranza delle galline deponga entro i nidi, una quota variabile di capi depone al di fuori di essi e, occasionalmente, cova le uova (Lay *et al.*, 2011). Inoltre, queste uova sono più soggette a rottura a causa della locomozione degli animali. D'altra parte, le uova deposte nel nido sono tendenzialmente più pulite rispetto a quelle deposte in gabbia convenzionale. La produzione nei sistemi a voliera viene riportata dagli studi più recenti come paragonabile o lievemente inferiore ai sistemi in gabbia e anche i parametri di qualità interni dell'uovo risultano influenzati dal sistema di allevamento. Le uova in sistemi in gabbia di fatto presentando valori di HU, ovvero rapporto tra l'altezza dell'albume e il peso dell'uovo, e altezza dell'albume maggiori (Tactacan *et al.*, 2009; Singh *et al.*, 2009; Ahammed *et al.*, 2014).

Ahammed *et al.* (2014) riferiscono che, dal punto di vista economico, vi è un aumento del costo di produzione delle uova prodotte in sistemi "non in gabbia" dovuto principalmente alla maggiore assunzione di mangime che segue la maggior locomozione e attività motoria. D'altra parte, considerando il differenziale di prezzo di vendita delle uova conferito da un maggior benessere in allevamento, è possibile affermare che i sistemi cage free, ed in particolare gli aviari, possono essere adoperati in modo economicamente soddisfacente.

È opportuno ricordare che, quando si parla di allevamento "senza gabbia", non vi è una completa uniformità della gestione e delle strutture adottate, vale a dire la densità di capi e la complessità dell'allevamento possono essere molto diverse da un sistema all'altro.

Allo stesso modo anche la scelta della razza da allevare risulta importante, soprattutto per limitare quei problemi come il feather pecking, il cannibalismo, la sensibilità alle malattie o le fratture, che emergono come più problematici negli allevamenti senza gabbia e vanno ad incidere sul benessere animale. Le pratiche di gestione dovrebbero quindi essere abbinate ad una opportuna scelta della razza, perché nessuna singola razza o ibrido di gallina ovaiole si adatta perfettamente a tutti i tipi di sistemi di stabulazione (Tactacan *et al.*, 2009; Lay *et al.*, 2011; Villanueva *et al.*, 2017; Sokołowicz *et al.*, 2020).

3. SISTEMI INNOVATIVI PER LA VALUTAZIONE DEL BENESSERE IN ALLEVAMENTO

A seguito del passaggio dalla zootecnia tradizionale, caratterizzata da molte piccole aziende con bassa densità di capi e una maggior presenza dell'allevatore in allevamento, a una zootecnia moderna e più intensiva, si sono generate nuove esigenze di tipo gestionale, produttivo e, in particolare, di benessere animale. Negli anni il ricorso a tecnologie innovative come il machine learning e il livestock precision farming (PLF) sta diventando sempre più pervasivo nell'allevamento animale proprio in risposta a queste nuove necessità.

In Figura 8 è presente uno schema esemplificativo che dà evidenza di come attraverso vari tipi di sensori, nello specifico quelli bioacustici, sia possibile raccogliere informazioni in merito a diversi parametri e indici legati al benessere animale.

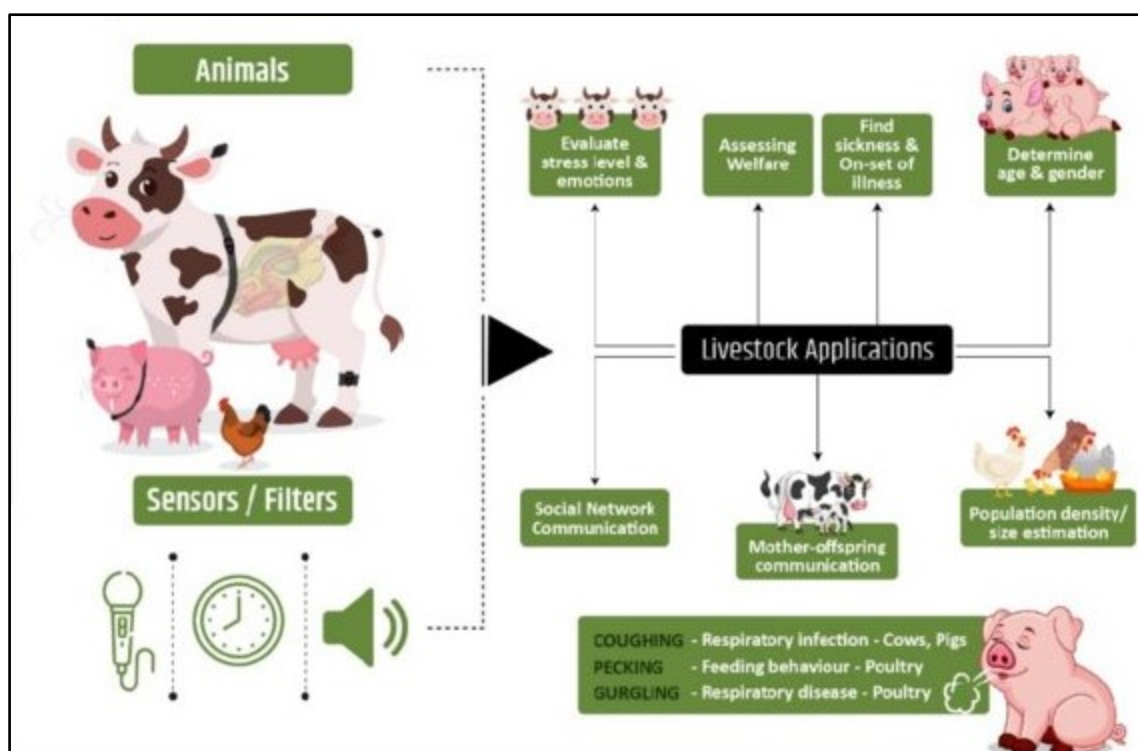


Figura 8. Applicazioni della bioacustica nell'allevamento di bestiame di precisione (modificata)(Neethirajan, 2020).

L'impiego e la diffusione di queste tecnologie sono inoltre giustificati dalla diminuzione del costo degli apparecchi elettronici, che in passato ne precludeva l'utilizzo in allevamento, e da un aumento di domanda di prodotti di origine animale parallelamente ad una emergente richiesta di benessere animale da parte della popolazione.

LIVESTOCK PRECISION FARMING (PLF)

Il PLF o “zootecnia di precisione” include quella serie di tecnologie che consentono il monitoraggio continuo e automatico di differenti parametri ambientali e misurazioni a livello degli animali in tempo reale. Queste tecnologie possono aiutare l'allevatore in particolar modo in un contesto aziendale dove sono presenti molti capi e il controllo dei singoli animali è pressoché impossibile. Questa situazione è sempre più presente nei moderni allevamenti.

Il PLF produce un gran numero di dati in formato digitale che possono essere trattati, e potenzialmente scambiati, per migliorare il controllo degli animali e l'efficienza di produzione di carne, latte e uova. Le tecnologie di PLF permettono di avere informazioni in tempo reale sullo stato degli animali assistendo l'agricoltore nelle sue decisioni e permettendogli di agire in maniera immediata quando si presenta qualche problematica (Van Hertem *et al.*, 2017).

Lo sviluppo dei sistemi di monitoraggio è articolato in due approcci distinti: monitoraggio su singolo capo, il più sviluppato in termini di mercato, e monitoraggio su gruppi di animali. Il monitoraggio sui singoli animali viene solitamente eseguito su animali ad alto valore, è il caso dei bovini, o su capi che necessitano di cure speciali. Il monitoraggio su gruppi di capi si presta bene nei sistemi a minor valore per animale, come pecore, capre, maiali, galline o pesci.

Il monitoraggio del singolo animale prevede il posizionamento di uno o più sensori posizionabili in aree specifiche dell'animale (collo, zampe, groppa, orecchio) o all'interno dell'animale (bolo). Come riportato da Firk *et al.* (2002), esempi di applicazioni per questo tipo di monitoraggio sono presenti nella letteratura scientifica a partire dagli anni 80.

Gli accelerometri, che misurano la variazione di velocità e la componente di accelerazione statica della gravità, montati sugli arti degli animali (podometri) sono stati tra i primi sensori ad essere usati nelle vacche da latte; questi primi utilizzi riguardavano la ricerca di estri (Figura 9). Sono tutt'oggi comunemente usati nei bovini e nei suini per il monitoraggio di diverse variabili, come il tempo di riposo, i passi, l'attività. Altre tipologie di accelerometri possono essere montati su collo o orecchie per registrare un'ampia gamma di comportamenti, come l'alimentazione, la ruminazione o per monitorare possibili zoppie. Ancora, altri sensori possono essere quelli di temperatura corporea interna e di pressione, oltre che i sensori di

posizione (radio o GPS) (Halachmi *et al.*, 2019).



Figura 9. Esempi di podometri (Vitali 2019).

I biosensori, infine, sono in grado di quantificare le risposte immunologiche, fisiologiche, e comportamentali degli animali in maniera altamente specifica con elevata sensibilità e affidabilità. Lo sviluppo di questa classe di sensori permetterebbe non solo un rilevamento precoce di malattie e altre problematiche sanitarie, ma anche di gestire al meglio il benessere dell'animale in maniera non invasiva (Neethirajan *et al.*, 2017).

In quanto agli avicoli, il monitoraggio di gruppo è la tipologia che più frequentemente viene applicata; si esegue con videocamere, fotocamere o sensori di diverso tipo presenti in numero ridotto per ogni gruppo.

L'analisi del suono risulta di particolare importanza in quanto è correlata a diversi parametri difficilmente valutabili se non con analisi più invasive o dispendiose. Il suono emesso da un gruppo di animali cambia per esempio con l'età e lo stato sanitario e sulla base di questo cambiamento è possibile effettuare diverse valutazioni (McCloughlin, Stewart and McElligott, 2019; Neethirajan, 2020b)

Lo stato di crescita viene normalmente controllato in allevamento tramite pesate periodiche di un campione di capi o tramite bilance elettroniche; questi sistemi però possono risultare o troppo dispendiosi in termini di tempo e personale addetto o, in certi casi, imprecisi. Diversi studi hanno stabilito come le vocalizzazioni emesse

dai polli da carne possano essere correlate con la crescita del gruppo (Fontana *et al.*, 2017; Halachmi *et al.*, 2019).

Du *et al.* (2020) e Li *et al.* (2020) riportano come l'analisi del suono possa fornire informazioni anche in merito a condizioni di comfort, o al contrario al livello di stress, dei volatili. I suoni vengono raccolti posizionando i microfoni al livello degli animali in modo da ricevere vocalizzi, rumori di beccate e suoni ambientali. I suoni registrati vengono poi analizzati sulla base di frequenza, ampiezza, durata e distribuzione del suono, anche in tempo reale. Anche la presenza di malattie va ad influenzare il suono emesso dagli animali. Diversi autori attraverso moderne tecnologie di data mining sono riusciti a rilevare la presenza di patogeni negli animali, come il *Clostridium perfringens* (accuratezza del 100% dopo 10 gg dall'infezione), o a distinguere differenti tipi di malattie in polli malati (malattia di Newcastle, dal virus della bronchite, dall'influenza aviaria) con un'accuratezza del 91% circa e a riconoscere quelli sani (Sadeghi *et al.*, 2015; Banakar, Sadeghi and Shushtari, 2016). In ultima analisi il suono può essere sfruttato dall'allevatore per determinare in maniera precoce numerose problematiche presenti in allevamento. Altro importante parametro è l'analisi dei gas attraverso il naso elettronico. Questo strumento è in grado di individuare modelli di odori (impronta olfattiva) piuttosto che la concentrazione di singole componenti gassose presenti nell'aria. Ciò permette non solo di monitorare la qualità dell'aria all'interno dell'allevamento ma anche di diagnosticare la presenza di malattie o la presenza di patogeni attraverso l'identificazione di composti organici volatili (COV) (Halachmi *et al.*, 2019). Nel loro studio Grilli *et al.* (2018) hanno evidenziato come, attraverso l'analisi dei COV, sia stato possibile discriminare animali sani e animali con coccidiosi in maniera precoce.

L'analisi delle immagini ottenute tramite videocamere o fotocamere e la successiva elaborazione tramite software appropriati all'area di studio permette di monitorare ciò che accade in allevamento e di raccogliere numerose informazioni come la temperatura, le immagini 3D dei singoli animali o il livello di attività.

Attraverso immagini termografiche (Figura 10) è possibile monitorare la temperatura dell'allevamento e, soprattutto, lo stato degli animali. Ciò riveste particolare importanza in quanto il mantenimento della temperatura corporea (omeostasi) è un indicatore sia della risposta all'ambiente che della salute generale

dell'animale. Negli avicoli la temperatura corporea viene rilevata considerando le parti non coperte da piume, come la testa o gli arti. Sono queste ultime quindi che subiscono mutamenti rilevabili dalle termocamere. Da diversi studi emerge come le immagini raccolte possano essere utili a valutare come gli animali reagiscano ad un cambiamento ambientale o ad un aumento di densità e possano permettere di individuare più facilmente animali in ambienti poco illuminati come il nido (Li *et al.*, 2020; Neethirajan, 2020).




Figura 10. Immagine termografica di gallina (Souza et al 2019).

MACHINE LEARNING (ML)

Con l'avvento della zootecnica di precisione e la diffusione di sensori più economici, il set di dati raccolti dai dispositivi è diventato elevatissimo. La gestione di enormi set di dati, complessi e differenziati tra loro, risulta molto complicata e comporta difficoltà di analisi con metodi statistici classici. Per poter gestire e analizzare questi dati, è necessario utilizzare una branca dell'intelligenza artificiale, ovvero il machines learning (ML). Il ML, o apprendimento automatico, utilizza sofisticati metodi statistici in grado di estrapolare e mettere in relazione un'enorme mole di dati, appunto big data, proveniente da schemi complessi (come quelli del comportamento animale) che presentano relazioni sconosciute tra le variabili considerate. In altre parole, il ML utilizza algoritmi che sono in grado di chiarire la casualità di modelli complessi. Per comprendere i modelli complessi generati dagli organismi viventi sono necessari algoritmi in grado di adattarsi velocemente ai cambiamenti dell'organismo studiato; gli algoritmi ML infatti sono in grado di adattarsi autonomamente per comprendere e trovare connessioni tra i dati forniti. Per poter elaborare i dati raccolti è però necessario archivarli in spazi appositi e non è possibile fare ciò con un normale computer. Per questo sono disponibili server remoti in grado di contenere i dati, che possiedono sufficiente capacità di calcolo per la loro elaborazione. Ovviamente ciò comporta per l'allevatore un dispendio di tempo e denaro.

Il ML funge quindi da strumento per la gestione e decifrazione di dati generati dalle tecnologie di PLF. Dati che in precedenza sarebbero stati difficilmente comprensibili o utilizzabili, ora sono diventati una potente fonte di informazione. I big data rappresentano una risorsa per comprendere meglio le esigenze degli animali e per soddisfare la necessità di rispondere a domande emergenti come la valutazione del benessere animale e la sicurezza alimentare pubblica (Berckmans, 2017; Li *et al.*, 2020; Neethirajan, 2020b, 2020a).

MACHINE LEARNING PER LA VALUTAZIONE DELLA DISTRIBUZIONE IN ALLEVAMENTO E DEL COMPORTAMENTO DEGLI ANIMALI

Un sistema di PLF che sfrutta la visione artificiale, già utilizzato e presente sul mercato, è il eYeNamic™ (Fancom BV, Paesi Bassi) (Figura 11). Si tratta di un sistema di allerta utilizzato in allevamenti di polli da carne che, attraverso immagini raccolte da telecamere montate sul soffitto dell'allevamento, consente di rilevare la maggior parte dei problemi che si potrebbero verificarsi, come malfunzionamenti nei sistemi di ventilazione alimentazione, o riscaldamento, semplicemente analizzando il comportamento dei polli.

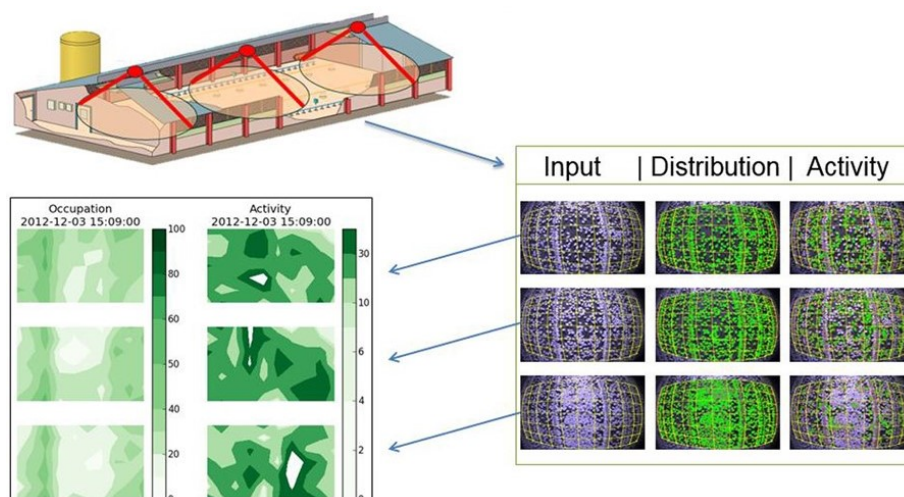


Figura 11. Tre telecamere con vista dall'alto e analisi delle immagini in tempo reale del comportamento dei polli da carne (Berckmans, 2017).


Questo sistema calcola in tempo reale l'attività e la distribuzione degli uccelli, rilevando come varia nel tempo la loro distribuzione nello spazio disponibile. L'indice di distribuzione viene calcolato sulla base dei rapporti derivanti dal confronto tra il numero di pixel dell'oggetto rispetto allo sfondo.

Attraverso un algoritmo che confronta la densità prevista con quella effettiva, il sistema invia un allarme se la densità effettiva supera quella prevista del 25%. Il sistema inoltre individua anche altre problematiche, come l'ostruzione delle linee di alimentazione. L'analisi del comportamento animale ha permesso a questo sistema di rilevare il 95% dei problemi che si sono verificati in un allevamento (Kashiha et al., 2013).


Uno studio di Peña Fernández (2018) ha inoltre dimostrato che è possibile correlare deviazioni dell'attività e nei modelli di distribuzione dei polli da carne con problemi di benessere legati a patologie alle zampe.

Anche i parametri comportamentali dei singoli animali possono essere monitorati per valutare lo stato di benessere degli animali. Lo studio di Pereira et al (2013) mette in risalto come, abbinando la tecnica dell'analisi delle immagini e il data mining, un algoritmo sia in grado di classificare diversi comportamenti con una correttezza del 70% nella modalità di "cross training" (validazione) e del 97% circa nella modalità di "set training" (calibrazione). In questo caso lo studio ha utilizzato dati ottenuti da registrazioni video effettuate su 10 capi in camere di controllo ambientale mantenute a temperatura e umidità controllate. L'esperimento si è articolato in quattro fasi. Nella prima parte dell'esperimento si sono studiate le forme del corpo assunte dagli animali durante l'espressione di comportamenti specie-specifici, utilizzando una sequenza di fotogrammi. In secondo luogo, sono stati classificati i diversi comportamenti. Nella terza fase, un algoritmo di elaborazione delle immagini è stato utilizzato per separare gli uccelli dallo sfondo. Infine, è stato costruito un albero di classificazione comportamentale successivamente validato.

Altre ricerche hanno avuto l'obiettivo di analizzare il comportamento per individuare precocemente la presenza di malattie. Lo studio di Zhuang et al (2018) ha prodotto un metodo che, attraverso l'analisi della postura di polli sani e malati, produce una classificazione automatica, permettendo quindi il suo utilizzo come strumento di allerta precoce. Le immagini raccolte dalle telecamere vengono prima sottoposte a due tipi di algoritmi di segmentazione per separare gli uccelli dallo sfondo (Figura 12) e per ottenere informazioni sullo scheletro. Infine, lo stato di salute del pollame viene valutato utilizzando un modello di apprendimento supervisionato chiamato Support Vector Machine (SVM).



(a)



(b)

Figura 12. (a) Segmentazione del pollame secondo il modello ellittico (b) Il pollo è stato estratto dallo sfondo (Zhuang et al 2018).

Sistemi recenti di visione artificiale sfruttano anche la tecnologia delle reti neurali per ricavare informazioni dalle immagini. Pu et al. (2018) hanno proposto per la prima volta un sistema in grado di riconoscere il comportamento del pollo utilizzando un sistema di rete neurale convoluzionale automatica (CNN) basato su immagini a colori e di profondità raccolte da telecamere fisse.

In questo esperimento 17135 immagini a colori e altrettante immagini di profondità sono state manualmente classificate in tre categorie di densità: non affollato, mediamente affollato e molto affollato. I risultati hanno dimostrato come la rete neurale (CNN) sia riuscita con elevata precisione a categorizzare le immagini di test. La precisione è stata calcolata come rapporto tra i veri positivi e la differenza tra i veri positivi e i falsi positivi. L'architettura della CNN proposta nello studio per il riconoscimento del comportamento dei polli ha raggiunto una precisione alta (95,8%) e un'accuratezza media della classificazione pari al 99,17% (Pu et al., 2018).

Gli algoritmi CNN sono stati usati da Wang et al. (2019) per individuare l'insorgenza di infezioni da malattie dell'apparato digerente negli uccelli analizzando gli escrementi prodotti da polli. Nello studio sono state raccolte e analizzate le immagini degli escrementi di 10000 polli da carne Ross allevati in gabbie su più piani.

Le immagini raccolte tramite una fotocamera sono state etichettate in base alle caratteristiche di colore, forma e presenza di acqua e poi sono state elaborate. A

scopo comparativo sono state esplorate due architetture di CNN: l'architettura Faster R-CNN e la YOLO-V3. La R-CNN è risultata migliore arrivando al 93,3% di precisione media, mentre quella YOLO-V3 ha raggiunto l'84,3% di precisione media sul set di dati di test. La tecnologia CNN è stata usata anche in altri studi come quello di Mbelwa et al. (2021) con il risultato di precisioni elevate.

L'algoritmo di deep learning YOLO v3 è stato usato da Juan Wang et al. (2019) per rilevare i comportamenti negli allevamenti di riproduttori. Nello studio, gli autori hanno addestrato un modello per identificare sei comportamenti a due livelli di densità differenti (alta e bassa). Sulla base dei risultati, il modello è riuscito a identificare i sei comportamenti oggetto di valutazione con diversa ma sempre elevata accuratezza: 94,72% (accoppiamento), 94,57% (in piedi), 93,10% (alimentazione), 92,02% (allargare le ali), 88,67% (combattimento) e 86,88% (abbeverata) (Figura 13). L'accuratezza del modello è risultata inferiore nell'allevamento al livello di densità maggiore a causa della schermatura tra i polli.




Figura 13. Risultati del rilevamento in gabbie da fecondazione a densità alta (Juan Wang et al. 2019).

Sulla base dei risultati ottenuti, gli autori hanno potuto formulare due giudizi sul benessere degli animali: uno basato sulla frequenza degli accoppiamenti nei giorni monitorati e uno sulla presenza di comportamenti anomali. La presenza di comportamenti anomali nei diversi giorni è stata legata ad aspetti quali combattimento, alimentazione e riposo. Quando le statistiche di comportamento

legate a questi aspetti si discostavano per più o meno del 3% da valori di soglia prefissati, il comportamento di quel giorno veniva considerato come anomalo.

Dalla letteratura disponibile si evince come le tecniche di analisi basate su immagini sviluppate per gli avicoli si siano concentrate principalmente su: monitoraggio degli individui e della loro attività e modelli di distribuzione in gruppi di polli da carne. Inoltre, solo recentemente questi studi hanno utilizzato algoritmi CNN. Il fine ultimo di questi studi è stato quello di valutare automaticamente il comportamento dei polli da carne e stabilire collegamenti con la salute e il benessere (Wurtz et al., 2019)..

OBIETTIVI

La crescente domanda di prodotti alimentari, come carne e uova, è associata alla sempre più pressante richiesta dei consumatori di allevare gli animali garantendo un livello di benessere elevato. Ciò ha portato importanti cambiamenti nella produzione avicola e, in Europa, all'eliminazione delle gabbie convenzionali per l'allevamento delle galline ovaiole a partire dal 2012. Nelle gabbie arricchite utilizzate in alternativa e nei sistemi a terra e in voliera, le galline allevate possono esprimere meglio il proprio repertorio comportamentale, ma sono sorte nuove problematiche, che da un lato minano il benessere animale nel suo complesso e dall'altro compromettono il risultato economico dell'allevatore. Queste problematiche assumono ancora più rilievo nei sistemi di allevamento cage free verso i quali si è più recentemente orientata la Commissione Europea.

D'altra parte, sono disponibili nuove tecnologie che possono consentire il monitoraggio del comportamento degli animali e l'individuazione di problemi in allevamento con un approccio di Precision Livestock Farming (PLF). Queste tecnologie non solo permettono di individuare problemi già esistenti, ma soprattutto di prevenirli attraverso un'allerta precoce. La progressiva disponibilità di queste tecnologie, data dall'avanzamento tecnologico e dalla riduzione dei costi, ha inoltre ampliato la platea di potenziali utilizzatori.

In questo contesto, l'obiettivo della presente tesi sperimentale è stato quello di mettere a punto un metodo indipendente dall'operatore per il rilievo della densità delle galline ovaiole allevate in aviari, utilizzando il modello YOLO (You Only Look Once), con l'obiettivo di monitorare, e in futuro prevenire, le condizioni che possono portare all'affollamento e al soffocamento degli animali. Inoltre, il sistema è stato testato anche per valutare la possibilità di monitorare il benessere degli animali in termini di comportamenti di comfort e, nello specifico, in termini di animali impegnati nel bagno di sabbia. Lo studio realizzato ha quindi confrontato due diverse versioni di YOLO, v4 e v4-tiny, al fine di trovare il modello che localizzasse e classificasse in maniera più accurata possibile i capi e il comportamento di comfort considerato.

CASO STUDIO

DESCRIZIONE DELL'ALLEVAMENTO

Gli animali sono stati allevati presso l'allevamento di galline ovaiole dell'Azienda Sperimentale "Lucio Toniolo" dell'Università degli Studi di Padova, Legnaro (PD) (Figure 14-16).



Figura 14. Scatto satellitare da Google Maps dell'Azienda Agraria Lucio Toniolo: nel cerchio, l'area dedicata alle ovaiole (2021).

La stalla con illuminazione esclusivamente artificiale, provvista di finestre invernali per l'ingresso dell'aria ad apertura automatica, ventilatori ad estrazione e cooling system per il raffrescamento, era attrezzata con un aviario di 2,50 m di larghezza × 19,52 m di lunghezza × 2,24 m di altezza. Lo spazio a disposizione degli animali era rappresentato da un'area a terra di 5,70 m di larghezza × 19,52 m di lunghezza. L'aviario era costituito da due piani in rete collocati al centro della struttura ed equipaggiati con abbeveratoi a goccia e mangiatoie lineari per la distribuzione automatizzata del mangime oltre che un terzo piano di soli trespoli con una linea di mangiatoie (Figura 16).

Sui due piani erano anche collocati un totale di 32 nidi collettivi (1 nido ogni 60 animali, superficie del nido 0,547 m²) disposti in maniera alternata, con accesso schermato da tendine in plastica, illuminazione autonoma rispetto al resto

dell'impianto e sistema di espulsione delle galline per la chiusura del nido. Il fondo del nido era costituito da un tappetino in materiale plastico (astroturf) con setole alte 20 mm. L'aviaro era attrezzato con trespoli (lunghezza 1,38 cm), due esterni alla struttura sfalsati per piano, e altri trespoli interni alla struttura disposti sopra e a fianco delle mangiatoie del primo, secondo e terzo livello.



Figura 15. Stalla galline ovaiole nell'azienda agraria sperimentale "L. Toniolo".




Figura 16. Interno dello stabulario prima dell'accasamento degli animali (sinistra) e dopo l'accasamento degli animali (destra)

L'aviario ospitava 1800 ovaiole a una densità di 9 animali/m² con superficie disponibile a terra pari a 0,025 m²/animale; 0,10 m di mangiatoia/animale; un abbeveratoio a goccia/10 animali; 0,15 m di trespolo/animale; e 1,00 m² di superficie nido/120 animali.

Gli animali erano divisi casualmente in 8 moduli della voliera (225 galline per recinto). La raccolta delle deiezioni era automatizzata con nastro feci per ogni piano dell'aviario e raschietti per la rimozione della pollina a terra sotto l'aviario. La gestione di luce, distribuzione di acqua e alimento, apertura e chiusura dei nidi, pulizia dei nastri e azionamento dei raschietti, oltre che nastro raccolta uova, era regolata automaticamente con centralina di automazione Smart2 (Officine Facco).

SISTEMA DI REGISTRAZIONE E TEMPI DI REGISTRAZIONE

Il sistema era attrezzato per il monitoraggio da remoto con un sistema di video-sorveglianza in tempo reale che utilizzava 48 telecamere Infrared mini-dome 4 mp con obiettivo fisso da 36 mm, risoluzione 1080 p, grado di protezione IP67 (HAC-HDW1220MP, Zhejiang Dahua Technology Co., Ltd., Hangzhou, Cina). Le telecamere erano installate su un solo lato dell'aviario e posizionate in modo da registrare gli animali a terra, al piano inferiore e al piano superiore dell'aviario (incluso il terzo livello) oltre che l'interno dei nidi. Il sistema contava anche due videoregistratori digitali full HD (NVR2116HS-4KS2, Zhejiang Dahua Technology Co., Ltd., Hangzhou, Hangzhou, Cina).

Dalla settimana 34 alla 43 di età, il comportamento degli animali è stato video-registrato una volta la settimana sui quattro moduli dalle 18:30 alle 20:30 del giorno successivo (26 h) e nel fine settimana per evitare che le operazioni settimanali di gestione dell'aviario potessero interferire con le registrazioni. Dalla settimana 44 e fino alla 65, le registrazioni sono state effettuate su tutti gli otto moduli, sempre un solo lato dell'aviario, negli stessi orari e con la stessa cadenza. Le video registrazioni sono state quindi utilizzate per effettuare le valutazioni di seguito riportate.

DATASET

È importante evidenziare come i dati sono gestiti nella fase preliminare all'utilizzo della rete neurale. Infatti, i dati che vengono utilizzati nella fase di formazione della rete e nella fase di valutazione, o test, sono distinti. Una volta raccolti, i dati vengono inizialmente divisi in due gruppi. Il primo gruppo è quello utilizzato per l'allenamento dell'algoritmo (*training set*); l'altro viene utilizzato alla fine, in fase di valutazione (*test set*). In questo modo sarà possibile verificare come l'algoritmo operi con materiale nuovo (Figura 17). Il totale dei dati disponibili può essere diviso in maniera diversa nei due gruppi. Generalmente le percentuali di ripartizione utilizzate sono di 80:20, 70:30, 85:15 ecc.

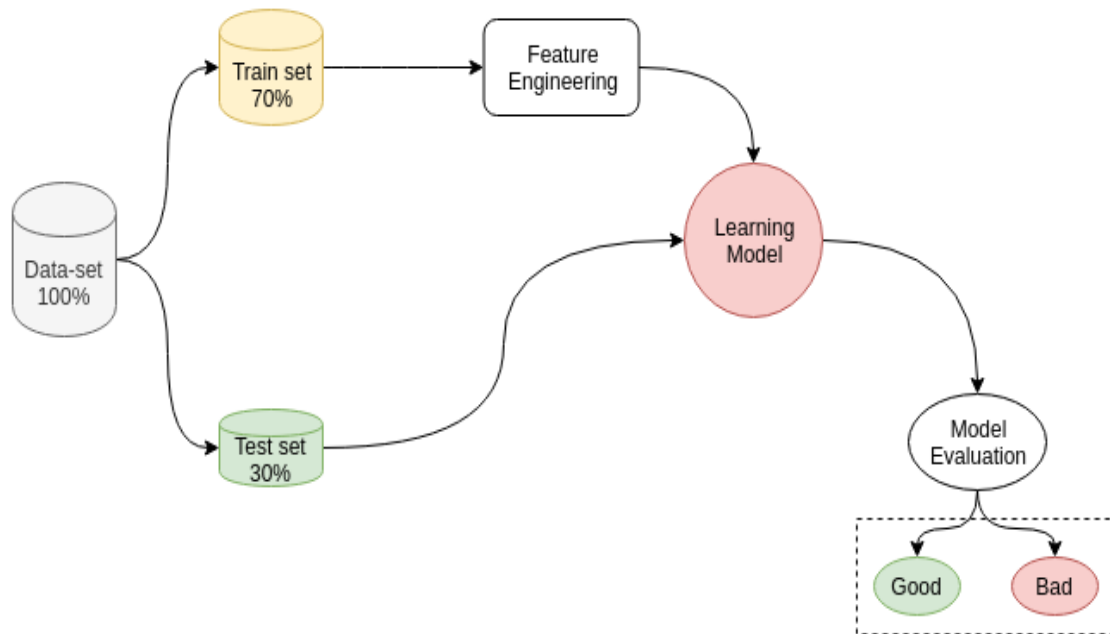


Figura 17. Rappresentazione del modello e della pipeline di valutazione (Bose, 2019)

Il volume di dati e la qualità delle informazioni usate in fase di apprendimento possono influenzare notevolmente le performance degli algoritmi di apprendimento automatico. Se in questa fase vengono forniti molti dati che presentano rumore l'algoritmo potrebbe "apprendere" rumore o dettagli eccessivi dal set di input, portando al sovra adattamento (*overfitting*). Questa situazione incide negativamente sulla capacità di generalizzazione del modello in quanto quest'ultimo predice bene gli output del set di allenamento, ma le prestazioni sui dati non visionati saranno peggiori. Per evitare l'*overfitting* il set di dati usati per l'addestramento o *training set* può essere diviso nuovamente per formare il set di convalida (*validation set*). Attraverso questa tecnica statistica, che prende il nome di *cross-validation*, un nuovo gruppo di dati permette di testare il modello sul set di convalida ed eventualmente ottimizzare gli iperparametri del modello. Ciò permette quindi di ottimizzare il modello senza utilizzare i dati vergini del *test set* ed evitare l'*overfitting*.

In ultima analisi quando qualsiasi parametro di classificazione deve essere regolato, è necessario avere un set di dati di convalida oltre al set di addestramento e di test (Patrício and Rieder, 2018).

Nel presente studio le immagini etichettate sono state 1150, di queste, 50 sono state scelte a caso e separate dal dataset totale per diventare il set di test. Quindi,

il dataset disponibile per il *training* è stato di 1100 immagini totali. Due terzi del dataset totale (734 immagini) sono state scelte casualmente e usate per il training. Le restanti 366 immagini etichettate sono state usate per la fase di valutazione.

ALGORITMO DI RILEVAMENTO DEGLI OGGETTI

Gli algoritmi di rilevamento degli oggetti "*Object Detection*" costituiscono una sotto disciplina del Deep Learning che a sua volta fa parte del più ampio gruppo del Machines Learning. Questi algoritmi sfruttano la visione artificiale e l'elaborazione delle immagini per riconoscere gli oggetti e definirne una collocazione spaziale nell'immagine fornita.

Le reti di deep learning rispetto dalle reti neurali convenzionali presentano più nodi, mezzi di interconnessione a strati più complessi, hanno l'estrazione automatica dei parametri e necessitano di sistemi con forte capacità computazionale. Questi sistemi si sono sviluppati e diffusi anche grazie all'avvento di GPU (*graphics processing unit*) più performanti che permettono una maggiore capacità di calcolo (Patrício and Rieder, 2018).

Nella pratica gli algoritmi di rilevamento sono in grado di classificare gli oggetti presenti nelle immagini sulla base delle caratteristiche peculiari di ogni oggetto; successivamente gli oggetti sono localizzati disegnandogli attorno, per esempio, un riquadro che ne delimita l'area (Figura 18).

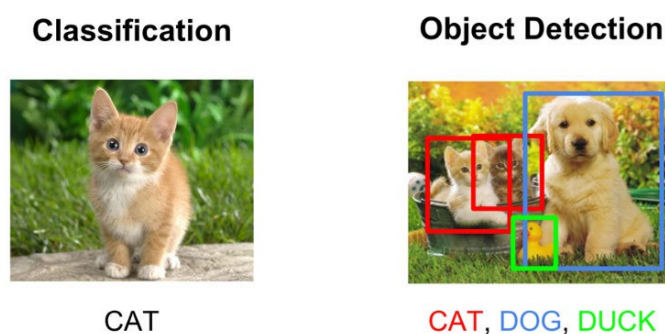


Figura 18. Esempio di immagine con classificazione su singolo oggetto e classificazione e localizzazione su oggetti multipli.

Esistono diversi modelli o algoritmi che sono stati prodotti negli anni per il rilevamento di oggetti. Diversi algoritmi però hanno caratteristiche e funzionamento differente. A titolo esemplificativo, Faster R-CNN e Mask R-CNN sono reti neurali convoluzionali basate su regione. Queste reti sono tendenzialmente più precise ma più lente.

La necessità di avere reti che lavorano ad alte velocità o in tempo reale ha spinto il mondo della ricerca a sviluppare nuovi modelli come Single Shot MultiBox Detector (SSD) e il modello You Only Look Once (YOLO) che risultano molto più veloci anche se meno precisi (Bresilla et al., 2019). I modelli SSD e YOLO trattano il rilevamento di oggetti come un semplice problema di regressione che prende un'immagine di input e impara le probabilità di classe e le coordinate dei riquadri di delimitazione (Bresilla et al., 2019). Il modello YOLO appartiene alla categoria di algoritmi di apprendimento supervisionato. Questi algoritmi per funzionare necessitano di un insieme di risposte corrette (training test), già etichettate, per poter poi generalizzare e rispondere correttamente a tutti gli input sottoposti.

Altri algoritmi disponibili sono: apprendimento non supervisionato, apprendimento semi-supervisionato e apprendimento per rinforzo. Nell'apprendimento non supervisionato non vengono usati dati etichettati ma viene studiata la struttura nascosta dei dati, ciò permette di raggrupparli. In questo caso l'algoritmo stesso trova dei *pattern* tra i dati. L'apprendimento semi-supervisionato rappresenta una via di mezzo in cui pochi dati del *training set* sono etichettati. I modelli che seguono l'apprendimento di rinforzo non hanno dati etichettati ma imparano ricevendo segnali di ricompensa o penalità in base al grado di errore commesso nel raggiungere un obiettivo. Quest'ultimi devono esplorare le varie possibilità presenti in uno specifico sistema per poter individuare la risposta corretta.

In generale il processo di apprendimento automatico consta in diverse fasi:

- preparazione e acquisizione dati: fase iniziale in cui si costruisce il set di dati che contengono la caratteristica che l'algoritmo dovrà ricercare a partire dalla fase di apprendimento. Generalmente gli algoritmi necessitano di una grande quantità di dati e, preferibilmente, con poco "rumore";
- selezione delle caratteristiche di interesse: ciò significa, identificare le caratteristiche più significative del problema che sarà affrontato;
- selezione dell'algoritmo: viene scelto l'algoritmo più appropriato per trattare

il problema oggetto di studio.

- selezione dei parametri: alcuni algoritmi devono essere regolati con parametri che richiedono sperimentazione per essere definiti;
- formazione della rete: dopo avere raccolto una consistente quantità di dati da impiegare come input, aver scelto l'algoritmo e i parametri, l'addestramento consiste nella costruzione del modello computazionale che verrà utilizzato nella previsione delle risposte ai nuovi dati. In altre parole, in questa fase viene allenato un algoritmo usando un certo numero di esempi (*training set*) il cui risultato (output) è, a noi, già noto. L'obbiettivo è far raggiungere all'algoritmo uno stato in cui sarà in grado di prevedere gli output di input a lui ignoti, ovvero generalizzare;
- valutazione: il sistema deve essere valutato per la sua accuratezza nell'identificazione del parametro prestabilito per i dati su cui è stato addestrato (Patrício and Rieder, 2018);
- test: si utilizza il test set per misurare le prestazioni del modello. Il test set è utilizzato anche per confrontare differenti modelli sul medesimo test set, in questo modo sarà possibile scegliere il modello che presenta il minor errore.

RETE CONVOLUZIONALE YOLO

YOLO è una rete neurale convoluzionale all'avanguardia per il rilevamento degli oggetti presente in diverse versioni (YOLO, YOLO 9000, YOLOv2-v3-v4-v5, Fast YOLO, versioni "tiny"). Il funzionamento di YOLO prevede che l'immagine sia divisa in una griglia SxS celle, per ogni griglia, vengono presi un certo numero (M) di riquadri di delimitazione (*bounding box*). Per ogni riquadro di delimitazione, la rete restituisce una classe di appartenenza con la rispettiva probabilità. Viene prestabilito un valore soglia di probabilità, al di sopra del quale vengono selezionati i riquadri di delimitazione per individuare l'oggetto. Questo consente di selezionare solo i riquadri che hanno elevate possibilità di contenere l'oggetto (Figura 19).




Figura 19. Modello YOLO. Il modello divide l'immagine in $S * S$ celle; per ogni griglia predice M riquadri di delimitazione, ciascuna con una certa classe e probabilità di classe (Redmon et al., 2018).

YOLO non divide il riconoscimento in più fasi, ma predice la posizione, probabilità e la classificazione dell'oggetto su una rete end-to-end in un unico passaggio. Questa struttura permette a YOLO di essere decisamente più veloce rispetto ai modelli di *object detection* preesistenti. La velocità di questo modello consenta la sua utilizzazione per la rilevazione in tempo reale anche se ha presentato dei limiti in termini di precisione nel rilevamento di oggetti di piccola dimensione (Yi et al., 2019) (Figura 20).

Model	Input size	Train set	Test set	mAP	FPS
YOLOv1	448x448	VOC 2007+2012	VOC 2007	63.4%	45
Fast YOLOv1	448x448	VOC 2007+2012	VOC 2007	52.7%	155
YOLOv2	416x416	VOC 2007+2012	VOC 2007	76.8%	67
tiny-YOLOv2	416x416	VOC 2007+2012	VOC 2007	57.1%	207
YOLOv2	608x608	COCO	COCO	48.1%	40
YOLOv3	608x608	COCO	COCO	57.9%	20

Figura 20. Prestazioni di diverse versioni di YOLO. La versione YOLO più veloce è tiny- YOLO v2, la versione più accurata è YOLOv3 con una mean Average Precision (mAP) del 57,9% sul set di dati COCO. I valori di frame per seconds (FPS) sono stati ottenuti su un processore grafico (GPU) Titan X (Reyes et al., 2018).

L'algoritmo YOLO è costantemente migliorato e aggiornato e la modifica dei parametri può mitigare questo problema.

La possibilità di fornire degli output in tempo reale è di primaria importanza in un sistema di allerta precoce.

VERSIONI DI YOLO UTILIZZATE IN QUESTO LAVORO

Le versioni di YOLO utilizzate e messe a confronto in questo lavoro sono state YOLO v4 e YOLO v4-tiny.

- YOLO v4 è la penultima versione di YOLO proposta da Bochkovskiy et. al. (2020) come miglioramento di YOLOv3. Questa versione risulta più veloce del 12% (FPS, frame per seconds) e più precisa del 10 % (AP, average precision) rispetto a YOLO v3. I principali cambiamenti riguardano l'aggiunta di: connessioni residue ponderate , normalizzazione incrociata Mini Batch, Attivazione Mish, Formazione in contraddittorio, Regolarizzazione DropBlock e connessioni parziali tra stadi. Inoltre, sono stati apportati miglioramenti nella fase di *data augmentation*.

La spina dorsale della rete è una CSPDarknet53 come modello di estrazione delle caratteristiche (Bochkovskiy et al., 2020).

- YOLO v4-tiny: Le diverse versioni di YOLO possono essere modificate per scopi diversi. Nelle versioni "Tiny", la dimensione della rete è notevolmente ridotta e il numero di strati convoluzionali nella spina dorsale viene compresso. Ciò fornisce un rilevamento più rapido degli oggetti con un FPS più elevato, compromettendo però l'accuratezza della previsione. Queste qualità lo rendono adatto se si dispone di una potenza di calcolo ridotta.

LINGUAGGIO DI PROGRAMMAZIONE PYTHON E PIATTAFORMA GOOGLE COLABORATORY

Per poter realizzare un programma è necessario utilizzare un linguaggio di programmazione. Attraverso questo linguaggio vengono fornite una serie di istruzioni che costituiscono il programma stesso. I linguaggi di programmazione sono diversi e ognuno è adatto ad uno specifico scopo. Per questo lavoro di tesi è

stato utilizzato il linguaggio Python.

Python è un linguaggio di programmazione interpretato che ricorda la lingua inglese, possiede una elevata astrazione e ciò lo rende più semplice da capire in quanto più simile a linguaggio umano (*Wikipedia.org*).

Per poter realizzare un programma è necessaria una piattaforma nella quale scrivere il programma, che sappia interpretare il linguaggio di programmazione utilizzato e che sia associata ad un'adeguata potenza di calcolo.

Google Colaboratory, o più semplicemente Colab, è un ambiente per notebook Jupyter presente in diverse versioni, gratuite o a pagamento, che viene eseguito nel cloud e archivia i propri notebook su Google Drive. In questo lavoro è stata utilizzata la versione Colab Pro a pagamento. La potenza di calcolo è fornita dagli hardware Google. Avere a disposizione una potenza di calcolo elevata è molto importante per il machine learning dove è necessario gestire e analizzare una elevata quantità di dati.

Un documento Jupyter Notebook non è altro che un ambiente virtuale contenente delle celle di input/output che possono contenere codici. All'interno di un singolo documento è possibile inserire tutti i codici necessari alla formazione di un programma.

ACQUISIZIONE DATI

Il set dati disponibili derivava dalle registrazioni video eseguite presso l'allevamento dell'Azienda Sperimentale "Lucio Toniolo" dell'Università degli Studi di Padova.

Le ore di registrazione utilizzate per la formazione del dataset sono state 112. Sono state escluse le registrazioni fatte su aree diverse dalla lettiera e le registrazioni notturne, in quanto inutilizzabili data l'assenza di mobilità delle galline.

Per impiegare le riprese video con la rete YOLO è stato necessario dividere in immagini le videoregistrazioni. A tale scopo è stato utilizzato il programma "Free Video to JPG Converter (v. 5.0.101)" estraendo un singolo frame per secondo e ottenendo quindi un totale di 403200 immagini, di queste sono state etichettate casualmente 1150 immagini.

ETICHETTATURA

Il processo di etichettatura, o *labeling*, prevede di assegnare un certo valore o categoria a ciascuna istanza dei dati, dove per istanza si intende una porzione di dato. Nel caso delle immagini, l'etichettatura prevede di inserire uno o più tag informativi sulle immagini che verranno poi usate nella successiva fase di addestramento. Questo lavoro deve essere eseguito manualmente e la precisione dell'etichettatura incide sulla qualità del modello finale. In questo lavoro l'etichettatura è stata completamente manuale in quanto non erano disponibili set di dati già etichettati.

Ci sono diversi tipi di etichettatura delle immagini, in funzione della forma utilizzata, tra i quali:

- *Bounding box*: Le scatole di delimitazione sono il tipo di annotazione più comune. Le scatole di delimitazione sono dei rettangolari che delimitano la posizione dell'oggetto ricercato e sono associate ad un tag informativo. I riquadri di delimitazione sono generalmente rappresentati da due coordinate (x e y) e dalla larghezza (w) e dall'altezza (h). I *bounding box* sono generalmente utilizzati in compiti di rilevamento e localizzazione di oggetti.

- Cuboidi 3D: I cuboidi 3D sono come scatole di delimitazione con informazioni aggiuntive sulla profondità sull'oggetto. Ciò permette al modello di riconoscere misure come il volume e posizione in un contesto 3D

- Segmentazione poligonale: è un tipo di annotazione in cui i dati vengono etichettati circondando gli oggetti con poligoni complessi, definendo in modo molto più preciso forma e posizione dell'oggetto.

- *Key-Point e Landmark*: è usato per rilevare piccoli oggetti e variazioni di forma creando punti sull'immagine.

Lines and Splines e Semantic Segmentation sono altri tipi di annotazione utilizzati nelle tecnologie per auto a guida autonoma.

In questo lavoro di tesi sono state etichettate manualmente 1150 immagini con *bounding box* e considerando due tag informativi diversi:

- Dust: capi che stavano effettuando il bagno di sabbia "attivo" sulla lettiera. Ovvero sono state etichettati i capi che eseguivano movimenti con il corpo contro la sabbia, come rotazioni complete o mezze rotazione (Figura

21). È stato deciso di etichettare i capi in questo modo per distinguere le immagini di bagno di sabbia vero è proprio dalle immagini in cui l'animale è in posa statica o sta raspare il suolo.



Figura 21. Esempio di bagno di sabbia con la rotazione completa del corpo

- Ground: tutti gli altri capi sulla lettiera ad eccezione di quelli che stavano salendo o scendendo dai trespoli e che presentavano una postura con ali aperte.

Per il tipo di etichetta sono state considerate adatte le *bounding box* (Figura 22). Il software utilizzato per l'etichettatura è stato YOLO Label v3. Il programma è

semplice e veloce da usare, necessita di una directory di dati; quindi, una cartella con tutte le foto non etichettate e di un file di testo (file .txt) con il nome delle etichette.

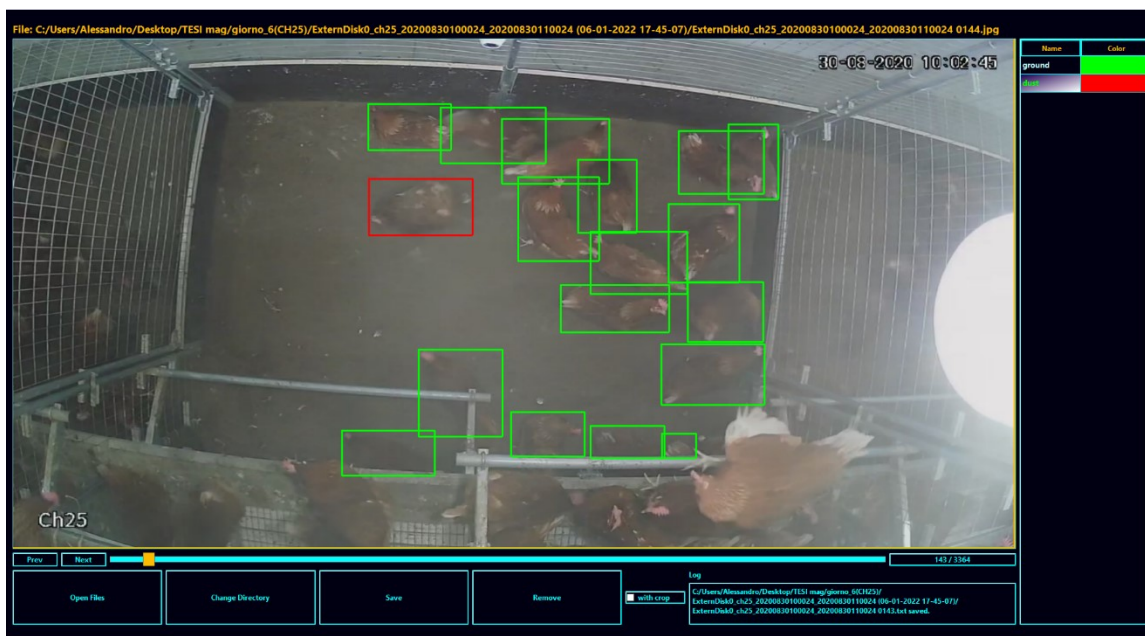


Figura 22. Esempio di etichettatura (labeling) utilizzando il software YOLO Label v3 con due tag informativi. Ground in verde e Dust in rosso.

DATA AUGMENTATION

Il processo di addestramento di un modello permette ad una macchina di generalizzare, ovvero gli permette lavorare su un set di dati nuovi (input) per portare a compimento un determinato compito (output), basandosi sull'esperienza maturata su un set di dati di apprendimento (*training set*).

L'aumento dei dati, o più propriamente *data augmentation*, è una fase molto importante in quanto migliora ed amplia il *training set* esponendo il modello a nuovi esempi. Sarebbe infatti impossibile utilizzare un set di dati di addestramento che riporti tutti gli scenari possibili nella realtà.

Nella pratica dell'*object detection* le immagini utilizzate per l'addestramento vengono alterate leggermente. Le alterazioni possono riguardare la geometria (ridimensionamento, ritaglio, traslazione, rotazione), la fotometria (luminosità, saturazione, contrasto, rumore), cancellazione di parti casuali (esempio in figura 23) o specifiche delle immagini e abbinamento o sovrapposizione di immagini.

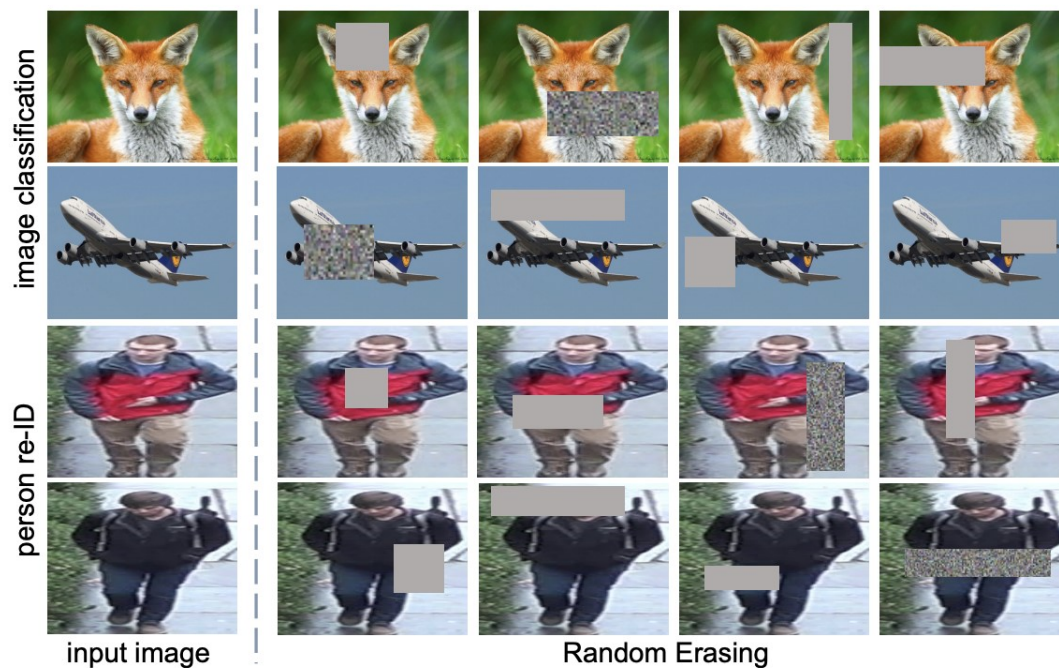


Figura 23. Esempio di cancellazione a vari livelli di parti casuali su immagini etichettate (Zhong et al., 2020)

Durante la fase di allenamento di entrambi i modelli, YOLO v4 e v4-tiny, le immagini sono state sottoposte a modifiche della saturazione, esposizione e colore. Inoltre, per l'allenamento del modello YOLO v4 le immagini sono state sottoposte a sfocatura *CutMix* (ritaglio casualmente porzioni di un'immagine e riposizionamento su un'altra) e *MixUp* (interpolare i valori dei pixel tra due immagini) e *mosaic* (quattro immagini vengono abbinate in una).

SETTAGGIO DI GOOGLE COLAB

Per poter eseguire la formazione e il test del modello è stato necessario impostare prima la macchina virtuale Google Colab. Per prima cosa è stato installato il pacchetto per la visualizzazione delle foto, poi è stata associata la cartella compressa (`data_for_colab_CHICKS_DETECTOR`) che conteneva le immagini per l'allenamento. Dopodiché è stato possibile associare Darknet alla macchina virtuale, dove Darknet è un framework di rete neurale open source scritto in C e CUDA. Dopo questo passaggio è stato scelto il tipo di YOLO da utilizzare, versione YOLO v4 e v4-tiny.

TRAINING DEL MODELLO

Nella fase di *training* il modello è stato allenato per svolgere un preciso compito. L'obiettivo del *training* era quello di minimizzare l'errore di generalizzazione, ovvero ridurre l'errore tra la previsione attesa e quella generata. In altre parole, il *training* cerca di minimizzare la "perdita". La "perdita" è un numero che indica quanto è sbagliata la previsione di un modello. Più è basso questo numero (vicino a 0) maggiore è la precisione della previsione. Per calcolare la perdita serve una funzione, detta di costo, o di perdita, che quantifichi la discrepanza tra l'output nell'esempio e quello realmente prodotto dalla rete. Esistono diversi tipi di funzioni di costo che si possono utilizzare come ad esempio l'errore quadratico medio. In ogni caso è necessario trovare i valori dei parametri che compongono la funzione che minimizzino la perdita. I parametri che compongono le possibili funzioni sono diversi ma ciò che viene modificato sono pesi e bias. Considerando una semplice rete neurale (Figura 24) è possibile osservare come questa presenti tra ogni input e nodo, un peso, o *weights* (W), e ogni nodo sia a sua volta connesso ad un bias (B).

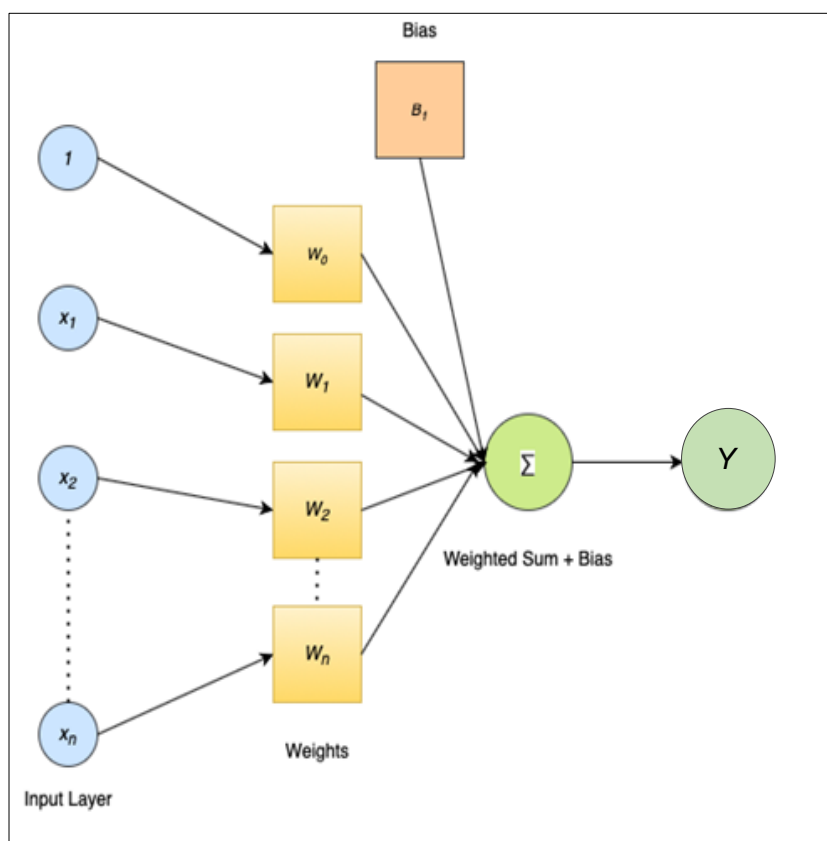


Figura 24. Struttura generale di una rete neurale ad un singolo livello nascosto.

I pesi sono utilizzati come moltiplicatori degli input. Questi valori vanno a “ponderare” il dato fornito influenzando la previsione finale (output) e indirizzandola verso la risposta corretta. Il bias può essere considerato come l'intercetta aggiunta in un'equazione lineare. Questo si comporta come una costante che aiuta il modello, insieme ai pesi, a adattare il modello ai dati forniti.

In una rete non allenata i parametri che regolano la risposta, e che si trovano tra input e output, sono inizialmente casuali, è necessario quindi un processo che tari progressivamente pesi e bias man mano che gli esempi vengano sottoposti alla rete. Questo processo prende il nome di retropropagazione o *backpropagation*. La retropropagazione è un algoritmo che sfrutta la discesa stocastica del gradiente, o *stochastic gradient descent* (SDG), e attraverso un metodo iterativo minimizza l'errore (Huang *et al.*, 2017). Il SDG di base sfrutta il metodo di discesa del gradiente, o *steepest descent method*. Lo schema generale per l'ottimizzazione di una funzione $f(x)$ presente in figura 25 mostra come partendo da $k=0$ si forma un ciclo *while*, il programma quindi eseguirà lo stesso comando fintanto che non si verifica un particolare evento, ovvero che in, questo caso, il gradienti si annulli. La direzione corrisponderà all'antigradiente mentre il passo varierà a seconda della formula scelta per calcolarlo.

```
 $x_0 \in R^n, k = 0$   
while  $\nabla f(\mathbf{x}_k) \neq 0$   
    calcolare la direzione di discesa  $\mathbf{d}_k := -\nabla f(\mathbf{x}_k)$   
    calcolare il passo di discesa  $\alpha_k$   
     $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha_k \mathbf{d}_k$   
     $k = k + 1$   
end.
```

Figura 25. schema generale per l'ottimizzazione di una funzione $f(x)$ utilizzando il metodo della discesa di gradiente

In sintesi, ciò che succede è che una volta calcolata la funzione di costo, il modello ha un'idea abbastanza precisa di quanto ciascun neurone di output sia lontano dal proprio valore atteso, e in che direzione (positiva o negativa). Questo significa che i dati hanno attraversato la rete ma questa ha fornito un output più o meno distante dal risultato voluto. Sfruttando il gradiente sarà possibile raggiungere con una certa velocità i valori dei parametri che minimizzino l'errore.

La velocità con cui questo risultato si otterrà dipende dalla dimensione del passo, o *learning rate*. Nella determinazione del *learning rate* si forma però un compromesso: valori di *learning rate* troppo elevati permettono di allenare velocemente il modello ma raggiungendo valori dei pesi sub ottimali. Con valori troppo bassi il modello si bloccherà o risulterà troppo lento. Valori ottimali sono associati ad un rapido calo delle perdite (figura 26) (Ruder, 2017; Ghosh *et al.*, 2020).




Figura 26. Discesa stocastica del gradiente: valori di learning rate ottimali. (Ghosh *et al.*, 2020)

Il passaggio di tutto il *training set* attraverso la rete neurale per una singola volta viene comunemente chiamato "epoca". Generalmente sono necessarie molte epoche, spesso centinaia o migliaia, per permettere all'algoritmo di apprendimento di minimizzare l'errore del modello. Nel nostro studio il numero di epoche è stato regolato a 6000 epoche

Per ridurre il tempo impiegato nella fase di *training* è stato deciso di utilizzare una rete già allenata per un problema simile. Questo permette di avere pesi e bias predeterminati. Ovviamente ciò non sostituisce in toto l'addestramento che dovrà comunque avvenire per ottimizzare pesi e bias. Questo approccio viene definito come *Fine-tune a pre-trained model*.

Il passo successivo dopo l'addestramento è valutare la bontà del modello su dati nuovi. Questa fase è importante per capire come il modello potrebbe comportarsi con dati nuovi; in questo caso presi da un altro allevamento di ovaiole.

VALIDAZIONE

Al termine delle 6000 epoche di training, è stata creata automaticamente in Google Drive una cartella di "backup" che contiene i risultati dell'allenamento. È stato possibile valutare i risultati attraverso diverse metriche, per questo studio sono state scelte *precision*, *recall* e *F1-score*. Sono stati inoltre confrontati i valori di mAP (*mean Average Precision*) e FPS (*Frame Per Second*).

La *precision* rappresenta la precisione e viene definita come il numero dei veri positivi (TP) diviso per la somma dei veri positivi più i falsi positivi. I veri positivi (TP) e i falsi positivi (FP) vengono distinti sulla base dello *Intersection over Union* (IoU), ovvero il rapporto tra l'area individuata dal *bounding box* e l'area effettivamente etichettata. Al di sopra di una soglia predeterminata, che nel presente lavoro è stata fissata a 0,5, il risultato è considerato un vero positivo, al di sotto di 0,5 un falso positivo. La *Recall* è il rapporto tra i veri positivi e la somma di veri positivi e falsi negativi (FN). L' *F1-score*, o semplicemente F1, è la media armonica della *precision* e del *recall*. Questo valore è una misura dell'accuratezza del modello. La perdita in YOLO, o *Loss*, rappresentata in blu nei grafici, è la somma di tre perdite: perdita di classificazione, perdita di localizzazione e perdita di fiducia. Il primo è l'errore al quadrato delle probabilità condizionali di ciascuna classe. La perdita di localizzazione misura gli errori nelle posizioni e nelle dimensioni dei *bounding box*, mentre la perdita di fiducia misura l'oggettività del riquadro. La funzione di perdita considera la perdita di classificazione e di fiducia solo se l'oggetto viene rilevato. Il valore di mAP corrisponde alla media delle precisioni medie, rappresentata in rosso nei grafici di cui sopra; misura quanto sono accurate le previsioni e quante

delle previsioni del modello fatte sono effettivamente corrette tenendo conto dei valori di confidenza previsti. Questo punteggio è definito come l'area sotto la curva di richiamo di precisione (Everingham et al., 2010).

Il Frame per second (FPS) infine esprime la velocità raggiunta dalla rete neurale, ovvero il numero di immagini per secondo che la rete riesce a processare.

Terminata la fase di training è stato possibile osservare i risultati dell'allenamento con Yolo v4-tiny e Yolo v4 (Figure 27 e 28).

YOLO v4-tiny utilizza un acceleratore Tesla P100-CUDA 10.1-cuDNN7.6.5 16GB. Il *learning rate* è 0,002. Durante la fase di addestramento ha ottenuto una mAP del 90,7%. Il tempo di addestramento è stato di 4,26 ore.




Figura 27. Grafico del Training di Yolo v4-tiny.

YOLO v4 ha utilizzato anch'esso un acceleratore Tesla P100. Il tasso di apprendimento è risultato pari a 0,002. La mAP ottenuta durante l'addestramento è stata pari all' 87,3%. Il tempo di addestramento per raggiungere questo risultato è stato pari a 23,2 ore.




Figura 28. Grafico del Training di Yolo v4.

FASE DI TEST

I dati ottenuti durante la fase di test hanno rispecchiato le performance ottenute durante la fase di allenamento con una maggiore precisione di YOLO v4-tiny che ha ottenuto un punteggio F1 di 0,95 e un mAP di 0,82 rispetto al punteggio F1 di 0,94 e al mAP di 0,81 del modello YOLO v4 (Tabella 3). Sulla base di questi dati è quindi possibile affermare che il modello v4-tiny è risultato più preciso per le valutazioni

effettuate in questa tesi. È però importante sottolineare che entrambi i modelli hanno raggiunto risultati soddisfacenti in termini di precisione anche se migliorabili.

Tabella 3: Performances delle due versioni di YOLO sul test set di immagini utilizzato per la valutazione del numero di galline a terra e del numero di galline impegnati nel bagno di sabbia utilizzando le due versioni di YOLO

Modello	IoU	Precision	Recall	F1-score	mAP
Yolo v4-tiny	0,5	0,94	0,96	0,95	0,82
Yolo v4	0,5	0,92	0,96	0,94	0,81

Il valore di FPS medio raggiunto durante la fase di test (50 immagini) da YOLO v4 è risultato pari a 31,35 immagini al secondo a fronte di 208,45 immagini al secondo nel caso della versione Yolo 4 tiny (Tabella 4).

Tabella 4: Velocità (FPS) delle due versioni di YOLO sul test set di immagini utilizzato per la valutazione del numero di galline a terra e del numero di galline impegnati nel bagno di sabbia utilizzando le due versioni di YOLO

Modello	FPS medi
Yolo v4-tiny	208,45
Yolo v4	31,35

Considerando gli FPS, dato che esprime la velocità del modello, il modello v4-tiny è risultato quindi più veloce e adatto a fornire informazioni in tempo reale sui comportamenti considerati. Il modello più semplice, YOLO v4-tiny, è risultato più performante del modello più complesso YOLO v4. Ciò si può presupporre essere dovuto alla bassa risoluzione delle immagini dovuta ad una limitata potenza di calcolo a noi disponibile per il processo di *training*.

Il modello ha permesso di ottenere una misurazione della densità in maniera indiretta. Il numero di galline osservate dal modello corrisponde al valore ottenuto da una stima visiva fatta da un operatore con un'accuratezza media rispettivamente di 0,95 e 0,94 per Yolo v4- tiny e Yolo v4.

Il modello è stato in grado di individuare con un'elevata accuratezza i capi e di classificarli nelle due categorie considerate: capi che fanno i bagni di sabbia "Dust", *bounding box* verde; capi che non fanno i bagni di sabbia "Ground", *bounding box* viola (Figure 27-31).

Il modello è stato in grado, inoltre, di escludere dal conteggio i capi sui trespoli e sui box adiacenti, limitando la localizzazione e la classificazione ai soli capi sulla lettiera del box sottostante la camera.




Figura 27. Immagine elaborata da Yolo V4 relativa al box 19.




Figura 28. Immagine elaborata da Yolo V4 relativa al box 7.



Figura 29. Immagine elaborata da Yolo V4 relativa al box 1.

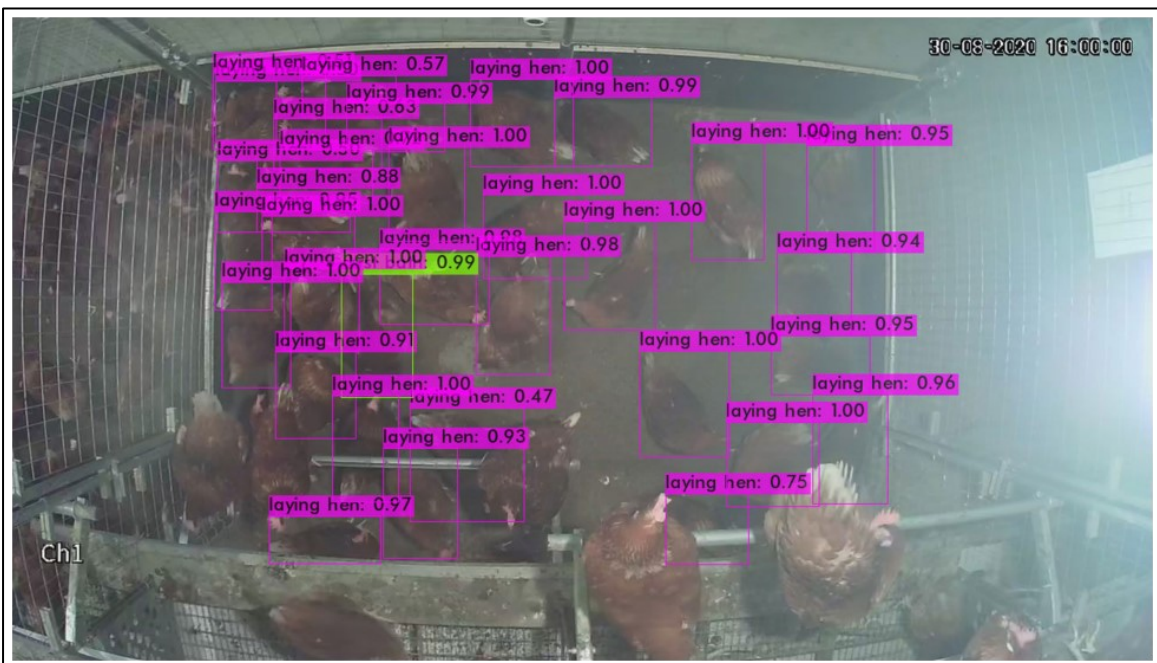


Figura 30. Immagine elaborate da Yolo v4-tiny relativa al box 1



Figura 41. Immagine elaborata da Yolo v4-tiny relativa al box 1

CONCLUSIONI

Il presente lavoro di tesi ha approfondito le problematiche relative all'allevamento cage free per galline ovaiole mettendo in risalto i benefici e i rischi di questo sistema rispetto al benessere degli animali e alla possibilità di realizzare comportamenti specie specifici. Sono stati poi introdotti i concetti base sugli approcci di PLF e machine learning che permettono di controllare il benessere degli animali in allevamento.

Questi nuovi approcci tecnologici permettono la raccolta di ingenti quantità di dati e la loro elaborazione in maniera sempre più facile ed economica; ciò permette il riconoscimento in tempo reale e la prevenzione delle problematiche in allevamento, garantendo potenzialmente una maggior sicurezza del reddito all'allevatore e un maggiore benessere agli animali.

Il caso studio della presente tesi ha quindi considerato la possibilità di mettere a punto un metodo indipendente dall'operatore per il rilievo della densità a terra e per il riconoscimento di un comportamento specie specifico, il bagno di sabbia, eseguito dalle galline ovaiole in aviario, utilizzando la rete neurale YOLO. Si tratta di una rete neurale convoluzionale progettata per il rilevamento di oggetti che predice la posizione, probabilità e classificazione dell'oggetto su una rete end-to-end in un unico passaggio. Questa struttura permette a YOLO di essere decisamente più veloce rispetto ai modelli di *object detection* preesistenti, consentendo rilevazioni ed elaborazioni immagine in tempo reale.

Lo studio ha verificato la possibilità di utilizzare con successo il modello YOLO per l'identificazione degli animali a terra e la classificazione degli animali impegnati nel bagno di sabbia, identificando la versione di YOLO migliore per queste valutazioni, i.e. v4-tiny.

In prospettiva, il modello potrebbe essere perfezionato per l'utilizzo in allevamenti commerciali utilizzando immagini etichettate in strutture che possiedono modelli di aviari diversi da quello aziendale, aumentandone la generalizzazione. Inoltre, potrebbe essere addestrato a riconoscere altri comportamenti legati al benessere o a condizioni non adeguate al benessere delle ovaiole. In conclusione, questo modello implementato su un sistema completo avrebbe le potenzialità di quantificare il livello di benessere degli animali in tempo reale.

BIBLIOGRAFIA

Ahammed, M. Chae, B. J. Lohakare, J. Keohavong, B. Lee, M. H. Lee, S. J. Kim, D. M. Lee, J. Y. Ohh, S. J. (2014) 'Comparison of Aviary, Barn and Conventional Cage Raising of Chickens on Laying Performance and Egg Quality', *Asian-Australasian Journal of Animal Sciences* 27, 1196.

Alexandratos, N. and Bruinsma, J. (2012) *World Agriculture towards 2030/2050: the 2012 revision*, ESA Working Paper 12-03, 2.

Banakar, A., Sadeghi, M. and Shushtari, A. (2016) 'An intelligent device for diagnosing avian diseases: Newcastle, infectious bronchitis, avian influenza', *Computers and Electronics in Agriculture* 127, 744–753.

Berckmans, D. (2017) 'General introduction to precision livestock farming', *Animal Frontiers* 7, 6–11.

Bochkovskiy, A., Wang, C.Y. and Liao, H.Y. M. (2020) 'YOLOv4: Optimal Speed and Accuracy of Object Detection'. Available at: <https://github.com/AlexeyAB/darknet>. Accessed on 12/01/2022.

Bose, Amitrajit. (2019) 'Cross Validation — Why & How', *Towards Data Science* Available at: <https://towardsdatascience.com/cross-validation-430d9a5fee22>.

Bresilla, K. Perulli, G.D. Boini, A. Morandi, B. Corelli Grappadelli, L. Manfrini, L. (2019) 'Single-Shot Convolution Neural Networks for Real-Time Fruit Detection Within the Tree', *Frontiers in Plant Science* 10, 611.

Campbell, D. L. M., De Haas, E. N. and Lee, C. (2019) 'A review of environmental enrichment for laying hens during rearing in relation to their behavioral and physiological development', *Poultry Science* 98, 9–28.

Du X, Carpentier L, Teng G, Liu M, Wang C, Norton T. (2020) 'Assessment of Laying Hens' Thermal Comfort Using Sound Technology', *Sensors* 20, 473.

Duncan, I. J. H. (2001) 'The pros and cons of cages', *World's Poultry Science Journal* 57, 386–390.

EFSA (2020) End the cage age: Looking for alternatives. Available at: [https://www.europarl.europa.eu/RegData/etudes/STUD/2020/658539/IPOL_STU\(2020\)658539_EN.pdf](https://www.europarl.europa.eu/RegData/etudes/STUD/2020/658539/IPOL_STU(2020)658539_EN.pdf). Accessed on 13/01/2022.

European Commission (2020) COMMITTEE AND THE COMMITTEE OF THE REGIONS A Farm to Fork Strategy for a fair, healthy and environmentally-friendly food system CONTENTS. Available at: https://agridata.ec.europa.eu/Qlik_Downloads/Jobs-Growth-sources.htm. Accessed on 22/09/2021.

Everingham, M., Van Gool, L., Williams, C.K.I. et al. The PASCAL Visual Object Classes (VOC) Challenge (2010). *Int J Comput Vis* 88, 303–338.

FAO (2018) The future of food and agriculture. Alternative pathways to 2050, 2018. Available at: <https://www.fao.org/policy-support/tools-and-publications/resources-details/en/c/1259562/>. Accessed on 09/02/2022.

FAOSTAT (2021). Available at: <http://www.fao.org/faostat/en/#data/QL>. Accessed on 09/02/2022.

Farm Animal Welfare Council - 5 Freedoms (2011). Available at: <https://webarchive.nationalarchives.gov.uk/ukgwa/20130106170359/http://www.defra.gov.uk/fawc/about/five-freedoms/> Accessed on 19/05/2021.

Ferrante, V. (2008) 'Benessere animale', In: Carenzi C. (Eds.) *Etologia applicata e benessere animale – Volume I – Parte generale*, Le Point Vétérinaire Italie, Milano, Italy, ISBN: 889599552X, 29–47.

Ferrante Velentina and Lolli Susanna (2009) 'Specie avicole' In: Carenzi C. (Eds.)

Etologia applicata e benessere animale – Volume II – Parte generale, Le Point Vétérinaire Italie, Milano, Italy, ISBN: 889599552X, 89–106.

Firk, R. Stamer, E. Junge, W. Krieter, J. (2002) 'Automation of oestrus detection in dairy cows: a review', *Livestock Production Science* 75, 219–232.

Fontana, I. Tullo, E. Carpentier, L. Berckmans, D. Butterworth, A. Vranken, E. Norton, T. Berckmans, D. Guarino, M. (2017) 'Sound analysis to model weight of broiler chickens', *Poultry Science* 96, 3938–3943.

Fossum, O. Jansson, D.S. Etterlin, P.E Vågsholm, I. (2009) 'Causes of mortality in laying hens in different housing systems in 2001 to 2004', *Acta Veterinaria Scandinavica* 51, 1–9.

Ghosh, B. Dutta, I. Carlson, A. Totaro, M. Bayoumi, M. (2020) 'An Empirical Analysis of Generative Adversarial Network Training Times with Varying Batch Sizes', 2020 11th IEEE Annual Ubiquitous Computing, Electronics and Mobile Communication Conference, UEMCON 2020. Institute of Electrical and Electronics Engineers Inc., 0643–0648.

Grandin, T. and Deesing, M. J. (2014) 'Genetics and Animal Welfare' in: Temple Grandin e Mark J. Deesing, in *Genetics and the Behavior of Domestic Animals*, Academic Press, Colorado State University, USA. ISBN 9780123945860, 435–472.

Grilli, G. Borghonovo, F. Tullo, E. Fontana, I. Guarino, M. Ferrante, V. (2018) 'A pilot study to detect coccidiosis in poultry farms at early stage from air analysis', *Biosystems Engineering* 173, 64–70.

Gray H, Davies, R and Bright, A, Rayner, A, Asher, L (2020) 'Why Do Hens Pile? Hypothesizing the Causes and Consequences.', *Frontiers in Veterinary Science* 7, 1047.

Halachmi, I. Guarino, M. Bewley, J. Pastell, M. (2019) 'Smart Animal Agriculture: Application of Real-Time Sensors to Improve Animal Well-Being and Production'. *Annual Reviews* 7, 403–425.

Hartcher, K. M. and Jones, B. (2017) 'The welfare of layer hens in cage and cage-free housing systems', *World's Poultry Science Journal* 73,767–781.

Van Hertem, T. Rooijackers, L. Berckmans, D. Peña Fernández, A. Norton, T. and Vranken, E. (2017) 'Appropriate data visualisation is key to Precision Livestock Farming acceptance', *Computers and Electronics in Agriculture* 138, 1–10.

Huang, G. Li, Y. Pleiss, G. Hopcroft, J. E. and Weinberger, K. Q. (2017). 'Snapshot Ensembles: Train 1, get M for free', 5th International Conference on Learning Representations, ICLR 2017 - Conference Track Proceedings, arXiv, 2017.

Parmigiani, P. (2018) 'Il comparto delle uova da consumo 2018'. Istituto di Servizi per il Mercato Agricolo Alimentare (ISMEA)

Parmigiani, P. (2020) 'Il quadro Europeo - tendenze uova maggio 2020'. Istituto di Servizi per il Mercato Agricolo Alimentare (ISMEA).

Kashiha, M. Pluk, A Bahr, C. Vranken, E. Berckmans, D. (2013) 'Development of an early warning system for a broiler house using computer vision', *Biosystems Engineering* 116, 36–45.

Koknaroglu, H. and Akunal, T. (2013) 'Animal welfare: An animal science approach', *Meat Science* 95, 821–827.

Lay, D. C. Fulton, R. M. Hester, P. Y. Karcher, D. M. Kjaer, J. B. Mench, J. A. Mullens, B. A. Newberry, R. C. Nicol, C. J. O'Sullivan, N. P. and Porter, R. E. (2011) 'Hen welfare in different housing systems', *Poultry Science* 90, 278–294.

Li, N. Ren, Z. Li, D. Zeng, L. (2020) 'Review: Automated techniques for monitoring

the behaviour and welfare of broilers and laying hens: towards the goal of precision livestock farming', *Animal* 14, 617–625.

High-level programming language - Wikipedia (2022). Available at: https://en.wikipedia.org/wiki/High-level_programming_language.

Mbelwa, H., Machuve, D. and Mbelwa, J. (2021) 'Deep Convolutional Neural Network for Chicken Diseases Detection', *International Journal of Advanced Computer Science and Applications* 12, 759- 765.

Mcloughlin, M. P., Stewart, R. and McElligott, A. G. (2019) 'Automated bioacoustics: methods in ecology and conservation and their potential for animal welfare monitoring', *Journal of the Royal Society Interface* 16, 155.

MPyK (2021) 'Object Detection with Javascript, the Easy Way!', Medium, Available at: <https://medium.com/the-web-tub/object-detection-with-javascript-the-easy-way-74fbe98741cf>

Neethirajan, S. Tuteja, S.K. Huang, S.T Kelton, D. (2017) 'Recent advancement in biosensors technology for animal and livestock health management', *Biosensors and Bioelectronics* 98, 398–407.

Neethirajan, S. (2020a) 'The role of sensors, big data and machine learning in modern animal farming', *Sensing and Bio-Sensing Research* 29, 100367.

Neethirajan, S. (2020b) 'Transforming the adaptation physiology of farm animals through sensors', *Animals* 10, 1–24.

Patrício, D. I. and Rieder, R. (2018) 'Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review', *Computers and Electronics in Agriculture* 153, 69–81.

Peña Fernández, A. Norton, T. Tullo, E. van Hertem, T. Youssef, A. Exadaktylos,

V. Vranken, E. Guarino, M., and Berckmans, D. (2018) 'Real-time monitoring of broiler flock's welfare status using camera-based technology', *Biosystems Engineering* 173, 103–114.

Florentino Pereira, D. Miyamoto, B. Maia, G. Sales, G. Magalhães, M. and Gates, R. (2013) 'Machine vision to identify broiler breeder behavior', *Computers and Electronics in Agriculture* 99, 194–199.

Pu, H., Lian, J. and Fan, M. (2018) 'Automatic Recognition of Flock Behavior of Chickens with Convolutional Neural Network and Kinect Sensor', *International Journal of Pattern Recognition and Artificial Intelligence* 32, 7.

Redmon, J. Divvala, S. Girshick, R. Farhadi, A. (2018) 'You Only Look Once: Unified, Real-Time Object Detection'. Available at: <http://pjreddie.com/yolo/>.

Reyes, E. Gómez, C. Norambuena, E. Ruiz-del-Solar, J. (2018) 'Near Real-Time Object Recognition for Pepper based on Deep Neural Networks Running on a Backpack'. Available at: <http://arxiv.org/abs/1811.08352>.

Rodenburg, TB. Tuytens, FAM. de Reu, K. Herman, L. Zoon, J. Sonk, B. (2008) 'Welfare assessment of laying hens in furnished cages and non-cage system: an on-farm comparison'. *Animal Welfare* 17, 363–373.

Rodriguez-Navarro, A. B. McCormack, H. Fleming, R. Alvarez-Lloret, P. Romero-Pastor, J. Dominguez-Gasca, N. Prozorov, T. (2018) 'Influence of physical activity on tibial bone material properties in laying hens', *Journal of Structural Biology* 201, 36–45.

Roll, V. F. B., Briz, R. C. and Levrino, G. A. M. (2009) 'Floor versus cage rearing: Effects on production, egg quality and physical condition of laying hens housed in furnished cages', *Ciencia Rural* 39, 1527–1532.

Ruder, S. (2017) 'An overview of gradient descent optimization algorithms *'.

Available at: <http://caffe.berkeleyvision.org/tutorial/solver.html>. Accessed on 23/03/2022.

Sadeghi, M. Banak, U. Khazaei, M. Soleimani, MR. (2015) 'An Intelligent Procedure for the Detection and Classification of Chickens Infected by *Clostridium Perfringens* Based on their Vocalization', *Brazilian Journal of Poultry Science* 17, 537–544.

Scott, G. B., Lambe, N. R. and Hitchcock, D. (1996) 'Ability of laying hens to negotiate horizontal perches at different heights, separated by different angles' *British Poultry Science* 38, 48–54.

Sherwin, D. C. M., Richards, G. J. and Nicol, C. J. (2010) 'Comparison of the welfare of layer hens in 4 housing systems in the UK'. *British Poultry Science* 51, 488–499.

Singh, R., Cheng, K. and Silversides, F. (2009) 'Production performance and egg quality of four strains of laying hens kept in conventional cages and floor pens', *Poultry Science* 88, 256–264.

Sosnowka-Czajka, E., Skomorucha, I. and Herbut, E. (2021) 'The welfare status of hens in different housing systems', *Annals of Animal Science* 21, 1235-1255.

Stadelman, W. J. (1999) 'World's poultry science association invited lecture: The incredibly functional egg', *Poultry Science* 78, 807–811.

Stratmann, A. Fröhlich, E.K. Harlander-Matauschek, A. Schrader, L. Toscano, M.J. Würbel, H., and Gebhardt-Henrich, S.G. (2015) 'Soft Perches in an Aviary System Reduce Incidence of Keel Bone Damage in Laying Hens', *PLoS One* 10, 3.

Sumner, D.A., Gow, H., Hayes, D., Matthews, W., Norwood, B., Rosen-Molina, J.T. and Thurman, W. (2011) 'Economic and market issues on the sustainability of egg production in the United States: Analysis of alternative production systems', *Poultry*

Science 90,241–250.

Tactacan, G.B., Guenter, W., Lewis, N.J., Rodriguez-Lecompte, J.C. and House, J.D. (2009) 'Performance and welfare of laying hens in conventional and enriched cages', *Poultry Science* 88, 698–707.

USDA (2019) Eggs in shell from farm to table | Food inspection and safety service. Available at: <https://www.fsis.usda.gov/food-safety/safe-food-handling-and-preparation/eggs/shell-eggs-farm-table>.

Villanueva, S. Ali, A.B.A. Campbell, D.L.M. and Siegford, J.M. (2017) 'Nest use and patterns of egg laying and damage by 4 strains of laying hens in an aviary system¹', *Poultry Science* 96,3011–3020.

Vitali, S. (2019) 'Rilevazione dei calori, la tecnologia va oltre il contapassi', *Terra e vita* Available at: <https://terraevita.edagricole.it/allevamento-zootecnia/rilevazione-calori-tecnologia-oltre-il-contapassi/>.

Vits, A. Weitzenbürger, D. Hamann, H. and Distl, O. (2005) 'Production, egg quality, bone strength, claw length, and keel bone deformities of laying hens housed in furnished cages with different group sizes', *Poultry Science* 84, 1511–1519.

Wang, J. Shen, M. Liu, L. Xu, Y. and Okinda, C. (2019) 'Recognition and Classification of Broiler Droppings Based on Deep Convolutional Neural Network', *Journal of Sensors* 2019, 1–10.

Wang, J. Wang, N. Li, L. Ren, Z. (2019) 'Real-time behavior detection and judgment of egg breeders based on YOLO v3', *Neural Computing and Applications* 32, 5471–5481.

Weitzenbürger, D. Vits, A. Hamann, H. Distl, O. (2006) 'Effect of furnished small group housing systems and furnished cages on mortality and causes of death in

two layer strains'. *British Poultry Science* 46, 553–559.

Wurtz, K. Camerlink, I. D'Eath, RB. Fernández, AP. Norton, T. Steibel, J. and Siegford, J. (2019) 'Recording behaviour of indoor-housed farm animals automatically using machine vision technology: A systematic review', *PLoS One* 14, 12.

Yi, Z., Yongliang, S. and Jun, Z. (2019) 'An improved tiny-yolov3 pedestrian detection algorithm', *Optik* 183, 17–23.

Souza-Junior, J. El-Sabrou, K. De Arruda, A. Costa, L.L. (2019). 'Estimating sensible heat loss in laying hens through thermal imaging'. *Computers and Electronics in Agriculture* 166, 105038.

Sokołowicz, Z. Dykiel, M. Topczewska, J. Krawczyk, J. Augustyńska-Prejsnar, A. (2020) 'The Effect of the Type of Non-Caged Housing System, Genotype and Age on the Behaviour of Laying Hens', *Animals* 10, 1–13.

Zhong, Z. Zheng, L. Kang, G. Li, S. and Yang, Y. (2020) 'Random Erasing Data Augmentation'. *Proceedings of the AAAI Conference on Artificial Intelligence*, 34, 07, 13001-13008.

Zhuang, X. Bi, M. Guo, J. Wu, S. and Zhang, T. (2018) 'Development of an early warning algorithm to detect sick broilers', *Computers and Electronics in Agriculture* 144, 102–113.