

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ  
ДОНЕЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ВАСИЛЯ СТУСА

КЛАПАЙ ТЕТЯНА БОРИСІВНА

Допускається до захисту:  
завідувач кафедри біофізики і фізіології  
кандидат хім. наук, доцент  
\_\_\_\_\_ О. І. Доценко  
« \_\_\_\_\_ » \_\_\_\_\_ 20\_\_ р.

ВИКОРИСТАННЯ МАШИННОГО НАВЧАННЯ ДЛЯ ІДЕНТИФІКАЦІЇ  
ВИДУ КОМАХ ЗА ЗВУКАМИ ЗМАХІВ КРИЛ

Спеціальність 091 Біологія

Кваліфікаційна (магістерська) робота

Науковий керівник:  
А. М. Міщенко, старший викладач  
кафедри біофізики та фізіології  
канд. біол. наук  
\_\_\_\_\_

Оцінка: \_\_\_\_\_ / \_\_\_\_\_ / \_\_\_\_\_  
(бал/за шкалою ЄКТС/за національною шкалою)  
Голова Е.К.: \_\_\_\_\_  
(підпис)

Вінниця 2023

**Клапай Т. Б.** Використання машинного навчання для ідентифікації виду комах за звуками змахів крил. Спеціальність 091 «Біологія». Освітня програма «Біологія». Донецький національний університет імені Василя Стуса, Вінниця, 2023.

Завдяки використанню методів машинного навчання, було здійснено розробку ефективного методу розпізнавання виду комарів за звуком змахів їх крил. Проводилось порівняння точності розпізнавання для різних методів глибокого навчання. Більша ефективність виявлена у роботі з послідовними нейронними мережами.

Ключові слова: спектрограма, звуки крил комах, машинне навчання.  
59 с., 11 табл., 37 рис., 139 джерел.

**Klapai T. B.** Machine learn-based insect species identification from wingbeat sounds. Specialty 091 “Biology”. Educational program “Biology”. Vasyl Stus Donetsk National University, Vinnytsia, 2023.

Thanks to the use of machine learning methods, the development of an effective method of recognizing the species of mosquitoes by the sound of their wing beats was carried out. Comparison of recognition accuracy for various deep learning methods was carried out. Greater efficiency was found in work with sequential neural networks.

Keywords: spectrogram, sounds of insect wings, machine learning.  
59 pp., 11 tabl., 37 fig., 139 sources.

**ЗМІСТ**

<b>ВСТУП.....</b>	<b>5</b>
<b>РОЗДІЛ I ОГЛЯД ЛІТЕРАТУРИ.....</b>	<b>7</b>
1.1 Комарі, як переносники захворювань .....	7
1.2 Згорткові нейромережі .....	10
1.3 Переваги машинного навчання над традиційними методами.....	14
<b>РОЗДІЛ II МАТЕРІАЛИ І МЕТОДИ ДОСЛІДЖЕННЯ.....</b>	<b>17</b>
2.1 Методи машинного навчання .....	17
2.2 Набір даних .....	19
2.3 Конструювання набору ознак .....	26
2.4 Відбір найбільш релевантних ознак.....	29
2.5 Програмне забезпечення .....	30
<b>РОЗДІЛ III РЕЗУЛЬТАТИ ЕКСПЕРИМЕНТУ І ЇХ ОБГОВОРЕННЯ ...</b>	<b>31</b>
3.1 Попередня обробка даних .....	31
3.2 Кореляційний аналіз набору ознак.....	37
3.3 Вплив попередньої обробки аудіо сигналу .....	44
3.4 Архітектура нейромережі SNN.....	45
3.5 Вибір функції активації та алгоритму оптимізації .....	46
3.6 Вибір методів глибокого навчання.....	47
<b>ВИСНОВКИ .....</b>	<b>52</b>
<b>СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ .....</b>	<b>54</b>

**ПЕРЕЛІК УМОВНИХ ПОЗНАЧЕНЬ, СИМВОЛІВ, ОДИНИЦЬ,  
СКОРОЧЕНЬ І ТЕРМІНІВ**

CNN	Концепція згорткових нейронних мереж
MLP	Багатошаровий перцептрон
ML	Машинне навчання
SNN	Послідовна нейронна мережа
AdaMax	Алгоритм оптимізації вагових коефіцієнтів
MSC	Класифікація видів комарів

## ВСТУП

**Актуальність теми дослідження.** Щороку через здатність комарів переносити смертельні захворювання, такі як малярія, лімфатичний філяріатоз, Зіка, денге та жовта лихоманка, помирає сотні тисяч людей [1,2]. Здатність комарів до передачі хвороб широко відома понад сто років, тому, задля запобігання їх впливу на здоров'я та життя людей, були впроваджені певні практики до яких включають москітні сітки, оброблені інсектицидами [3,4] та стерильні методи захисту від комах [5,6].

Однак подальший прогрес у боротьбі з хворобами, що переносяться комарами, вимагає більш точної ідентифікації видів та їхнього точного розташування, оскільки не всі комарі є переносниками хвороб, проте морфологічно ідентичні високоефективним видам-переносникам. Поточні дослідження покладаються або на записи зроблені людьми, або на менш ефективні світлові пастки. Частково це пов'язано з відсутністю дешевих, але точних датчиків спостереження, які могли б допомогти виявити комарів. Наша робота використовує акустичну сигнатуру польоту комарів як тригер для виявлення. Акустичний моніторинг комарів є переконливим методом, оскільки комахи виробляють звук як побічний продукт свого польоту та як засіб для спілкування та спаровування. Виявлення та розпізнавання цього звуку є ефективним методом визначення присутності комарів і навіть пропонує потенціал для класифікації за видами. Тим не менш, автоматичне виявлення комарів представляє фундаментальну проблему обробки сигналу, а саме виявлення слабкого сигналу, вбудованого в шум. Поточні механізми виявлення значною мірою покладаються на знання предметної області, такі як вірогідна основна частота та гармоніки, а також широке ручне створення функцій – часто схоже на традиційне представлення мови. Сьогодні, з'являється можливість використовувати глибоке машинне навчання, включаючи біоакустику у багатьох галузях [7].

**Мета роботи:** розробка ефективного методу розпізнавання виду комарів за звуком їх крил під час польоту з використанням методів машинного навчання.

**Задачі дослідження:**

- 1) здійснити попередню обробку аудіо даних, на їх основі отримати набір ознак для навчання нейромережі;
- 2) провести кореляційний аналіз звукових ознак, здійснити відбір найбільш релевантних для навчання ознак, способів їх попередньої обробки;
- 3) оптимізувати архітектуру нейромережі, обрати оптимальний алгоритм її навчання;
- 4) знайти оптимальний метод глибокого навчання.

**Предмет дослідження:** машинне навчання.

**Об'єкт дослідження:** ідентифікація комах за звуками змахів крил.

**Методом дослідження** є обробка 7105 аудіозаписів звуків 14 різних видів комарів з відкритої бази даних HumBugDB.

Магістерська робота складається зі вступу, трьох розділів, висновків, списку використаних посилань із 39 найменувань. Загальний обсяг роботи становить 59 сторінок.

## РОЗДІЛ І ОГЛЯД ЛІТЕРАТУРИ

Ідентифікація комах відіграє вирішальну роль у захисті здоров'я людини в різних аспектах, насамперед у сферах медицини, охорони здоров'я та профілактики захворювань. Важливість точної ідентифікації комах для здоров'я людини очевидна в багатьох сферах, оскільки багато комах діють як переносники захворювань, які вражають людей, наприклад комарі, що передають малярію, денге, вірус Зіка, і кліщі, що поширюють хворобу Лайма. Виявлення та моніторинг цих видів переносників мають важливе значення для впровадження цілеспрямованих заходів контролю, зменшення передачі захворювань та захисту здоров'я населення [4].

### **1.1 Комарі, як переносники захворювань**

Точна ідентифікація комах є фундаментальною для розуміння епідеміології трансмісивних захворювань. Це дозволяє дослідникам відстежувати розповсюдження переносників захворювань, аналізувати моделі передачі та оцінювати ризики спалахів захворювань, сприяючи ефективному епідемічному нагляду та стратегіям боротьби з хворобами [8,9]. Деякі комахи опосередковано сприяють ризикам для здоров'я, наприклад, через поширення бактерій, стійких до антимікробних препаратів. Ідентифікація комах, залучених до передачі цих бактерій, важлива для розуміння та управління потенційними загрозами здоров'ю населення [3].

Певні комахи можуть викликати алергічні реакції або передавати алергени. Наприклад, ідентифікація конкретних жалячих комах, відповідальних за алергічні реакції, має вирішальне значення для осіб, чутливих до алергії на отруту комах. Точна ідентифікація допомагає медичним працівникам призначати відповідне лікування та профілактичні заходи [10].

Важливий моніторинг спалахів, які передаються комахами. Визначення конкретних видів комах під час спалахів має вирішальне значення для швидкого реагування та стримування. Це особливо важливо для моніторингу поширення інвазивних видів, таких як комар *Aedes*, що відповідальний за передачу таких хвороб, як Зіка та Чікунгунья [11].

Вірус Зіка передається членистоногим (арбовірус), який переважно передається через укуси інфікованих комарів *Aedes*, зокрема *Aedes aegypti* [12]. Структурно він належить до роду *Flavivirus* і має схожість з іншими сумнозвісними представниками, такими як віруси денге, гарячки Західного Нілу та жовтої лихоманки [14]. Передача вірусу Зіка в основному відбувається через укуси інфікованих комарів. проте вірус може передаватися вертикально від матері до дитини під час вагітності або пологів, становлячи значний ризик для розвитку плоду.

Вірус Зіка, член родини *Flaviviridae*, став серйозною проблемою для громадської охорони здоров'я в усьому світі. Вперше виявлений у лісі Зіка в Уганді в 1947 році, вірус не привертав уваги протягом кількох десятиліть, оскільки в Африці та Південно-Східній Азії траплялися спорадичні легкі спалахи. Однак у 2015 році відбулася зміна парадигми, коли спалахи вірусу Зіка в Америці виявили безпрецедентний зв'язок із серйозними неврологічними ускладненнями, особливо у новонароджених [13]. Ця раптова ескалація спонукала до широких досліджень і зусиль громадської охорони здоров'я, щоб зрозуміти вірус і боротися з ним. Розробка вакцини досі триває [13].

*Mansonia uniformis* - це вид комарів, який належить до сімейства *Culicidae*, зокрема племені *Mansoniini*. На відміну від більш широко вивчених комарів *Aedes*, комарі *Mansonia* характеризуються чіткими біологічними та екологічними особливостями. Хоча *Mansonia uniformis* не так ретельно досліджується, як деякі інші види комарів, його ідентифікують як понетційного переносника різних арбовірусів, включаючи певні типи



енцефаліту [16]. Ці віруси, часто присутні в дикій природі, можуть передаватися людям через укуси інфікованих комарів. Хоча роль *Mansonia uniformis* у передачі арбовірусів не так ретельно вивчена, як деякі інші види комарів, підкреслює потребу в подальших дослідженнях, щоб краще зрозуміти його компетенцію переносників і пов'язані з цим ризики для здоров'я населення [15].

*Culex quinquefasciatus* є важливим представником родини Culicidae. Широко поширений у тропічних і субтропічних регіонах, цей вид комарів відіграє роль потенційного переносника різноманітних патогенів. Незважаючи на те, що *Culex quinquefasciatus* не такий сумнозвісний, як певні види *Aedes*, він відомий своєю роллю в передачі хвороб, які вражають мільйони людей у всьому світі [17].

*Culex quinquefasciatus* виявляє здатність адаптуватися до різноманітних середовищ, віддаючи перевагу міським і приміським районам. На відміну від комарів *Aedes*, *Culex quinquefasciatus* відкладає яйця на плотах у стоячій воді, включаючи штучні контейнери, стічні води та відкриті водойми. Личинки розвиваються в цих водних середовищах існування, сприяючи здатності виду процвітати як у природному, так і в зміненому людиною середовищі [19].

Однією з значних проблем охорони здоров'я, пов'язаних із *Culex quinquefasciatus*, є його роль як переносника патогенів, таких як філярійні черв'яки (*Wuchereria bancrofti*), відповідальні за лімфатичний філяріоз і різні арбовіруси, включаючи вірус Західного Нілу та вірус енцефаліту Сент-Луїса. Харчові звички комарів, які часто включають укуси птахів і ссавців, сприяють циклу передачі цих збудників [18].

*Anopheles maculatus* — представник роду *Anopheles*, відомий тим, що є основним переносником малярії в ендемічних регіонах. Він відіграє вирішальну роль у передачі паразитів *Plasmodium*, причому *Plasmodium falciparum* і *Plasmodium vivax* є переважаючими видами [21].

*Anopheles maculatus* широко поширений у Південно-Східній Азії, зокрема в таких країнах, як Таїланд, Малайзія, Індонезія та Філіппіни. На відміну від деяких інших видів *Anopheles*, він віддає перевагу лісистим і горбистим районам, часто розмножується в невеликих затінених водоймах, таких як лісові басейни, калюжі та повільні струмки. Вид відомий своєю здатністю адаптуватися до різноманітних екологічних умов [20].

*Anopheles harrisoni*, представник роду *Anopheles*, відіграє роль в передачі паразитів *Plasmodium falciparum* і *Plasmodium vivax*, двох основних малярійних паразитів, які вражають людей [22]. В основному зустрічається в Південно-Східній Азії, із задокументованою присутністю в таких країнах, як Таїланд, В'єтнам і Камбоджа. Його поширення часто пов'язане з певними екологічними умовами, і відомо, що він мешкає як у лісистих, так і в горбистих районах. Поведінка *Anopheles harrisoni*, включно з уподобаннями щодо пошуку господаря та харчовими звичками, відіграє вирішальну роль в ефективності передачі малярії в регіонах, де вона поширена [14].

Підсумовуючи, точна ідентифікація комах необхідна для вирішення та запобігання різноманітним ризикам для здоров'я, пов'язаним із трансмісивними захворюваннями, алергічними реакціями, безпекою харчових продуктів та іншими проблемами здоров'я, пов'язаними з комахами. Ці знання формують основу для прийняття обґрунтованих рішень у сфері охорони здоров'я та сприяють загальному добробуту людей.

## **1.2 Згорткові нейромережі**

Концепція згорткових нейронних мереж (CNN) продемонстрована доктором природничих наук Метью Стъатортом за допомогою багатьох зображень лебедів і розповідає про використання CNN над звичайними багатосаровими нейронними мережами перцептронів для обробки зображень [28].

Для створення нейронної мережі, яка може розпізнати лебедя на зображенні, нам необхідно позначити певні характеристики, що допоможуть нам у визначенні, таких як, довжина шиї, колір окрасу, колір дзьобу та інше. Проте трапляються випадки, коли мережі важко визначити певну характерну рису у екстремальних випадках, наприклад, шия може бути повернута в сторону або бути зігнутою, недостатньо видимі крила, дзьоб та очі можуть мати різний розмір та форму тощо.

Для вирішення проблеми з визначенням, дослідники вирішення цих проблем: SIFT, FAST, SURF, BRIEF тощо. Проте виникла подібна проблема: детектори були або надто загальними, або надто складними.

Нам відомо про традиційні нейронні мережі, які мають назву багатошаровий перцептрон (MLP). Дані мережі змодельовані на основі людського мозку, за допомогою якого нейрони стимулюються зв'язаними вузлами та активуються лише тоді, коли досягається певне порогове значення.




Рисунок 1.1 - Стандартний багатошаровий перцептрон (традиційна нейронна мережа)

При обробці фото традиційний метод нейронної мережі має недоліки, оскільки використовує один перцептрон для кожного входу (наприклад, піксель у зображенні, помножений на 3 у випадку RGB). Кількість ваг швидко стає неконтрольованою для великих зображень. Для зображення розміром 224 x 224 пікселя з 3 кольоровими каналами потрібно навчитися близько 150 000 ваг. Таким чином виникають труднощі під час тренувань, що може

потребувати переобладнання. Наступний недолік полягає у тому, що традиційна нейронна мережа реагує на нові зображення у основному зображенні, вона намагається виправити себе та припускає, що нове зображення буде завжди присутнім в основному зображенні.

Для вирішення вище названих проблем використовують згорткові нейронні мережі (CNN), які можуть проаналізувати вплив найближчих пікселів за допомогою фільтрів, які можуть бути пов'язані з будь-якими параметрами, кожен для окремої ознаки. Це надає інформацію про те, наскільки сильно показується ознака, скільки разів та в якому місці. Вказаний фільтр у статті вказаний за емпіричним правилом –  $3 \times 3$  або  $5 \times 5$ . Його необхідно перемістити по зображенню з верхнього лівого кута до нижнього правого. Для усіх точок на даному зображенні обчислюється значення на основі фільтра за допомогою згорткових операцій. Перевагою є те, що нейронна мережа не вимикається при зміні розташувань цих параметрів.

Під час створення мережі автор випадковим чином вказує значення фільтрів, які постійно оновлюються при навчанні мережі. Створення двох однакових фільтрів мало ймовірно, при умові не надто великої кількості вибраних фільтрів.

Після проходження фільтрів по зображенню, вони приймаються за допомогою функції активації, яка визначає чи присутній певний елемент у певному місці зображення, що дає змогу надалі додавати більше шарів фільтрації та створювати більше карт функцій. Щоб вибрати найбільші значення на картах об'єктів і використовувати їх у подальшому як вхідні дані для наступних шарів, використовується об'єднання шарів.




Рисунок 1.2 - Архітектура CNN

Згорткові нейронні мережі також складаються з шарів, але вони не пов'язані між собою. Шари мають фільтри, набори ваг у формі куба, які застосовуються по всьому зображенні. Такі фільтри вводять інваріабельність перекладу та спільне використання параметрів.

Кожен двохвимірний фрагмент фільтра називається ядром. Такий фільтр згортається з усім 3D-вхідним кубом, але генерує 2D-карту функцій. Оскільки важливо, щоб вихід зображення не був зменшений (область  $2 \times 2$ ), ядра фільтрів створюють заповнення карт функцій, що передбачає кращий результат для роботи з глибокими CNN. Таким чином, отримуємо тривимірний результат – одна двовимірна карта об'єктів на фільтр. Від одного згорткового шару до іншого може змінюватися розмір карти функцій, наприклад, ми можемо ввійти в шар із вхідними розмірами  $32 \times 32 \times 16$  і вийти з вихідними  $32 \times 32 \times 128$ , якщо цей шар має 128 фільтрів.

У згортковій нейронній мережі існує три типи шарів: згортковий шар, шар об'єднання та повністю зв'язаний рівень. Кожен з цих шарів має різні параметри, які можна оптимізувати, і кожен виконує різні завдання на вхідних даних.

Згорткові шари – це шари, де фільтри застосовуються до оригінального зображення або до інших карт функцій у глибокій CNN. Більшість заданих параметрів у мережі знаходиться саме у цих шарах. Найважливішими параметрами є кількість та розмір ядер.

Шари об'єднання подібні до згорткових шарів, але вони виконують певну функцію, наприклад максимальне об'єднання, яке приймає максимальне значення в певній області фільтра, або об'єднання середніх даних, яке приймає середнє значення в області фільтра. Зазвичай вони використовуються для зменшення розмірності мережі.

Повністю пов'язані шари розміщуються перед результатом класифікації CNN і використовуються для зведення результатів перед класифікацією. Це схоже на вихідний рівень MLP.

### **1.3 Переваги машинного навчання над традиційними методами**

Машинне навчання (ML) пропонує ряд переваг порівняно з традиційними методами вивчення комарів, революціонізуючи дослідження та спостереження за комарами.

#### **1) Неінвазивний метод**

Для формування належних та своєчасних заходів боротьби з хворобами, які передаються комарами, проводиться безпосередній моніторинг популяції комарів у польових умовах. Науковці провели роботу зі звичайними мобільними телефонами – різними видами смартфонів та звичайними «розкладачками». Результати показали, що мікрофони в цих телефонах достатньо чутливі, щоб точно записати дзижчання комара, навіть за наявності фонового шуму.

У підсумку, записані звуки 20 видів комарів, які поширюють захворювання на людей, порівняли з колекцією звуків отриманих з різних смартфонів, правильний результат виду був автоматично визначений для двох третин записів [23].

Автори вказали, що навіть недорогі мобільні телефони з дуже базовою функціональністю здатні чутливо отримувати акустичні дані про характерні для виду звуки комарів, записуючи час і місце зустрічі людини з комаром. Такий метод дає змогу провести моніторинг для бідних ресурсів регіонів, які

зазвичай мають найвищий рівень захворювань, що передаються комарами [24].

## 2) Економічні витрати

Підходи на основі машинного навчання можуть запропонувати економічно ефективні рішення порівняно з традиційними методами. Зменшення ручної праці та здатність ефективно обробляти дані сприяють загальній економії витрат на дослідження та спостереження за комарами.

Щоб задовольнити потребу у відстеженні та оцінці якості дослідження для успішного застосування машинного навчання систематичний огляд проводить вичерпну та комплексну ідентифікацію, узагальнення та синтез багатфакторних моделей, які використовують методи машинного навчання для прогнозування витрат особи на охорону здоров'я [25].

## 3) Висока пропускна здатність

Моделі машинного навчання можуть швидко опрацювати великий обсяг аудіоданих, забезпечуючи високопродуктивний аналіз у реальному часі. Досліджується широкий спектр важливих з медичної точки зору видів комарів, щоб кількісно продемонструвати, як акустичні записи, що підтримуються просторово-часовими метаданими, дозволяють швидко, неінвазивно ідентифікувати види.

Таким чином, найефективнішим способом боротьби з цими захворюваннями є зменшення кількості комарів на ураженій території. Однак ця стратегія контролю базується на знанні того, які види комарів поширюють захворювання на людей і де вони знаходяться. Це особливо корисно для моніторингу популяції комарів у великих географічних районах [23].

## 4) Постійне спостереження

Автоматизовані системи моніторингу на основі машинного навчання можуть працювати безперервно, забезпечуючи безперервний потік даних у реальному часі. Це постійне спостереження покращує здатність відстежувати

зміни в популяціях комарів і оперативно реагувати на потенційні спалахи захворювань.

Спостерігаємо застосування ML для аналізу великої кількості складних даних, які клініцисти повинні інтерпретувати в сфері постійного фізіологічного моніторингу. Машинне навчання, особливо застосовуване у двонаправленому поєднанні з даними електронних медичних записів, має потенціал для отримання набагато більше корисної інформації [26].

5) Покращена точність і об'єктивність даних.

Алгоритми ML зменшують суб'єктивність, пов'язану з ручним аналізом даних, забезпечуючи більш точні та об'єктивні результати. Це особливо важливо при роботі з великими наборами даних і складними шаблонами.

Машинне навчання відіграє ключову роль у виробництві, обробці та зберіганні клінічних і експериментальних даних. Використання штучного інтелекту в медицині може зменшити витрати, пов'язані з хірургічним лікуванням, і забезпечити високоякісну медичну допомогу більш широким верствам населення. Крім того, ML та медицина можуть побудувати симбіотичні відносини, де ML допомагає розширити межі медицини, а медицина може допомогти ML розробити кращі та надійніші алгоритми. Вивчалась роль машинного навчання в інтервенційних та неінтервенційних аспектах медицини під час перед-, інтра- та післяопераційної допомоги, таких як діагностика, прийняття клінічних рішень, хірургічна операція, прогноз, збір даних та дослідження в нейрохірургічній сфері [27].



## РОЗДІЛ II МАТЕРІАЛИ І МЕТОДИ ДОСЛІДЖЕННЯ

### 2.1 Методи машинного навчання

Для класифікації звуків комарів, було реалізовано два методи глибокого навчання, а саме послідовну нейронну мережу (Sequential Neural Network, SNN) та згорткову нейронну мережу (Convolutional Neural Network, CNN).

SNN для класифікації використовує числові набори ознак, що отримуються для кожного аудіозапису (хромодіаграма, спектральний центроїд, спектральна ширина, рівномірність спектральної характеристики, спектральне спадання, швидкість перетину нуля, мел-частотні кеспральні коефіцієнти і т.і.). SNN це метод обчислювальної нейронної мережі, який складається з кількох змінних обробки, які отримують вхідні дані та надають виходи на основі їх попередньо визначеного оптимізатора та функції активації. SNN складається з декількох повністю з'єднаних (full connected) шарів нейронів. Розмір вхідного шару співпадає з кількістю ознак, що використовуються для класифікації. За ним йдуть декілька прихованих шарів. В нашому випадку їх кількість, а також кількість нейронів в кожному з них варіювались, на етапі оптимізації топології. Для цих шарів ми використовували функцію активації Relu. Розмір вихідного шару нейронів співпадає з кількістю класів (кількістю видів комарів). Цей шар мав функцію активації softmax. На рисунку 2.1 представлена узагальнена схема SNN. На етапі навчання, використовувався алгоритм оптимізації вагових коефіцієнтів AdaMax.

Кінцева архітектура SNN (кількість та розмір прихованих шарів) визначалась шляхом навчання нейромереж з різною архітектурою і вибору серед них такої яка б дозволяла отримати найбільшу точність розпізнавання.




Рисунок 2.1 - Конфігурація послідовної нейронної мережі.

CNN (Згорткова нейронна мережа) — це ефективна та важлива техніка побудови штучних нейронних мереж, яка використовується для багаторівневої обробки даних. Для аналізу продуктивності CNN у даній конфігурації використовуються оптимізатор Sigmoid, функція активації AdaMax, 1000 epoch і розмір партії 128. На рис. 2.2 представлена архітектура моделі. Використовували ту саму техніку Sequential NN від Keras і додаємо 2D Conv Layer із 64 фільтрами та 8,8 розміром сітки ядра, а також функцію активації Sigmoid. Вказано, що тривимірна вхідна форма в групу X складається з 26 значень ознак із моноримірним каналом. Після процесу згортання карти функцій мають розмір 20 x 64 за такою формулою: розмір карти функцій = (розмір вхідних функцій – розмір ядра + розмір кроку) x розмір фільтра. Потім ми додаємо 2D-шар із максимальним об'єднанням із 2, 2 розміром басейну/сітки, 1,1 розміром кроку (значення за замовчуванням) і нульовими відступами. Об'єднані карти функцій = розмір карти об'єктів/об'єднаний розмір) x розмір фільтра = 20/2 x 64=10x64. Потім об'єднані карти об'єктів вирівнюються та поширюються через чотири щільні шари (256, 128, 64, 1).

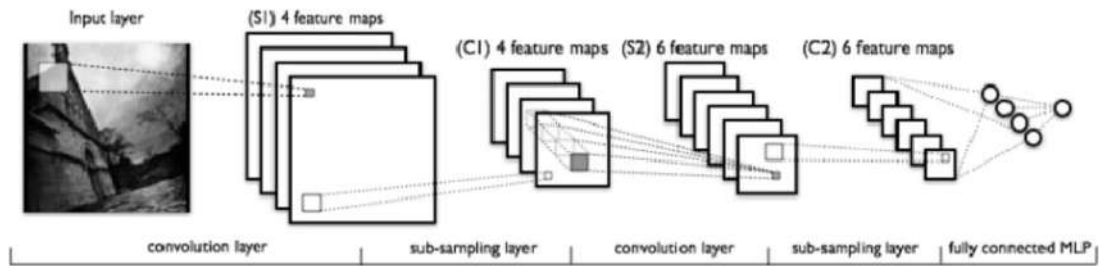


Рисунок 2.2 - Конфігурація згорткової нейронної мережі

## 2.2 Набір даних

Використовувалась велика база даних із записами 20 годин звуків комарів і 15 годин пов'язаних даних щодо боротьби з комарами, побудованих на основі ретельно визначених парадигм запису. Ентомологи брали участь у співпраці по збору записів. Дані збиралися протягом п'яти років. За допомогою недорогих смартфонів та професійних записуючих пристроїв, було зроблено записи 36 видів комарів. Намагалися зафіксувати звук без стороннього шуму, та зі звуками, які характерні для місцевості перебування комах. Різноманітну кількість диких і лабораторних комарів включено до бази даних, щоб охопити біорізноманіття природних видів. Ці дані зберігаються та обслуговуються в базі даних PostgreSQL, що забезпечує правильність міток, цілісність даних і дозволяє ефективно оновлення та повторне оприлюднення даних.

Характерний тон польоту комарів забезпечують їхні короткі, усічені крила, завдяки чому, вони роблять змах крилами швидше, ніж будь-яка інша комаха еквівалентного розміру – до 1000 ударів на секунду [29]. Саме це спонукало дослідників спробувати використати ці звуки, щоб дослідити їх, захопити або знищити.

**Опто-акустичний підхід.** Використовувався набір даних «Wingbeats» і «UCR Flying Insect Classification», що були зібрані за допомогою оптичних датчиків із високим співвідношенням сигнал/шум (SNR) [30]. Автор зазначив, що це додатковий підхід у дослідженні.

**Акустичний підхід.** Вказано, що набір даних складається із зразків комарів із середньою тривалістю звуку 10 секунд. Крім того, автори постачають однакову кількість фону, зібраного в тих самих контрольованих умовах, щоб сформувати збалансований клас розподілу випадків появи комарів і групу негативного контролю. Це зроблено для запобігання тому, щоб записуючий пристрій або фонове середовище ставали фактором, що перешкоджає виявленню акустичних подій.

Підібрані дані цієї роботи є підмножиною HumBugDB, у якій вдосконалюється попередній випуск завдяки спільним зусиллям спільнот зоології та машинного навчання. Цей проект є результатом співпраці між Оксфордським університетом та ентомологами з усього світу. Однією з цілей проекту є розробка акустичного датчика від комарів, щоб допомогти контролювати та ідентифікувати види комарів, забезпечуючи цілеспрямований та ефективний контроль переносників. Датчики такого типу можна розгортати в будинках людей в ендемічних по малярії районах.

**Запис комарів за допомогою смартфонів.** Був розроблений спеціальний енергозберігаючий додаток для запису звуку польоту комарів з вбудованим мікрофоном на смартфоні. Автори використовували 16-бітне монохвильове аудіо PCM із частотою дискретизації 8000 Гц на основі попередніх недорогих акустичних рішень для запису смартфонів для комарів [31]. Авторами була розроблена адаптована сітка [32], щоб москіти підлітали досить близько до смартфона.

**MongoDB.** Після запису програми аудіо синхронізується програмою з центральним файловим сервером для зберігання звукових записів і екземпляром MongoDB для зберігання метаданих. Сервер має зовнішню інформаційну панель, де можна отримати доступ до записів і прогнозів, отриманих від моделі. Неструктурований характер механізму NoSQL забезпечує додаткову гнучкість у зберіганні метаданих, особливо коли стає доступною нова інформація.

**Класифікація видів комарів (MSC).** Другий BCNN навчається спеціально для класифікації видів. Після ідентифікації комарів створюється розподіл ймовірностей за видами. Звіт доступний через інформаційну панель HTML і може бути переданий у програму для надання відгуків користувачам.

**База даних PostgreSQL.** Ця реляційна база даних була розроблена через складні вимоги до змінних і зберігання даних [34], яка забезпечує стандартизацію процесу маркування та метаданих. Це пом'якшує основну причину проблем із якістю даних і витрат часу на польові дослідження. Дані були отримані в результаті контрольованих досліджень у цілеспрямованих експериментах за допомогою моделей MED, де це можливо.

**Конфіденційність.** Як підмножина даних з бази даних може містити людську мову та інші типи особистих даних, було включено в цей документ лише аудіо, якому присвоєно чітку позначку «москіт», «аудіо», «фон» або іншим чином отримано повну згоду від учасників (наприклад, якщо експерти з ентомології вказують ідентифікатор запису). Щоб переконатися, що жодне мовлення, на яке не було отримано чіткої згоди, не буде включено в майбутні випуски, було виконано виявлення голосової активності (VAD) і видалення за допомогою проекту Google WebRTC, який є відкритим і легким у використанні [36]. Дослідник [35] протестував метод WebRTC VAD протягом 396 годин даних у різних типах запису. Підхід був точним від 77% до 99,8%.

**The HumBugDB dataset** - це великомасштабний набір даних, що містить записи комарів, зібрані з різних місць у всьому світі, а також за допомогою різних методів збору. На рис. 2.3 показано різні місця з доступністю позначеного звуку комарів (у секундах) і кількістю видів, а також кількістю експериментів, проведених у кожному місці. Загалом нам представлено 71 286 секунд (20 годин) позначених даних про комарів із 53 227 секундами (15 годин) відповідного фонового шуму, щоб допомогти в процесі наукової оцінки, записаних у місцях 8 експериментів. З них 64 843 секунди

містять метадані про види, що складаються з 36 видів (або видових комплексів).

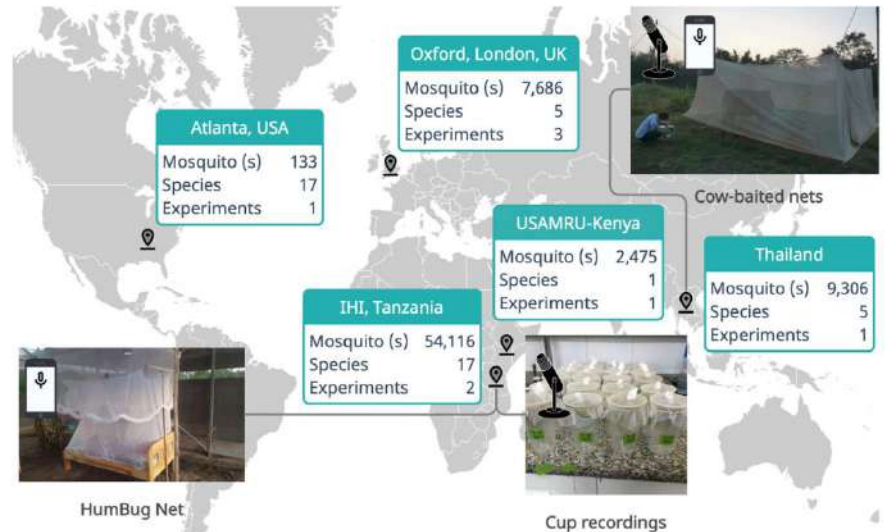


Рисунок 2.3 – Місця з доступністю позначеного звуку комарів, кількістю видів та експериментів

Збір даних проводився у лабораторних умовах та серед диких упійманих комарів. Багато інститутів, які проводять дослідження захворювань, що передаються комарами, зберігають лабораторні культури поширених видів переносників. До них належать первинні переносники малярії (наприклад, *An. arabiensis*), первинні переносники вірусу денге (*Aedes albopictus*), вірусу жовтої лихоманки (*Aedes aegypti*) і вірусу Західного Нілу (*Culex quinquefasciatus*). Контрольовані умови лабораторних культур виробляють повністю розвинених комарів однакового розміру, які використовуються для різних цілей, включаючи випробування нових інсектицидів або дослідження геному цих комах.

У Великій Британії, Кенії та США комарів реєстрували шляхом розміщення записуючого пристрою в культуральних клітках, де літав один чи кілька комарів, або шляхом розміщення окремих комарів у великі чашки та тримаючи їх близько до записуючих пристроїв (позначених `device_type`). Для

досягнення цілеспрямованого контролю переносників за допомогою розміщення в будинках людей, потрібно було мати можливість пасивно вловлювати тон польоту комарів. Тому в базу даних, збір у Танзанії, включили комарів, пасивно зареєстрованих у напівпольовому приміщенні Інституту здоров'я Іфакара (ІНІ).

Дикі комарі природно виявляють набагато більшу мінливість і тому мають вирішальне значення для зразків для оцінки здатності виявлення в реальному світі. Експерименти у Таїланді та Танзанії були проведені з метою вивчення, як це впливає на здатність розрізняти різні види. Записи, зроблені в Таїланді, були використані, щоб продемонструвати, що тон польоту має потенціал для розрізнення різних видів [37].

Азія має найбільше домінуючих видів переносників (комарів, чия чисельність або схильність кусати людей робить їх особливо ефективними переносниками хвороби), у всьому ендемічному по малярії світу. Зразки комарів відбирали за допомогою сітки з наживкою для тварин, сітки з приманкою для людини і колекції личинок протягом двох місяців у пік сезону комарів (з травня по жовтень 2018 року). Відбір зразків проводився в селі Пу Теуй на станції моніторингу векторів, що належить університету Касетсарт, Бангкок. Фауна комарів на цьому місці включає ряд домінуючих видів переносників, включаючи *An. dirus* і *An. minimus* разом зі своїми братами і сестрами *An. baimaii* і *An. harrisoni* відповідно. Комарів збирали вночі, обережно поміщали у великі чашки для зразків і записували наступного дня за допомогою високотехнічного польового мікрофона Telinga EM23 і бюджетного смартфона.

У Африці, в Танзанії, на відміну від Азії, на південь від Сахари переважають найнебезпечніші види комарів (*An. gambiae*), відповідальні за найбільшу кількість передач малярії серед людей у світі та найбільшу кількість смертей [38]. Таким чином, завдяки співпраці за допомогою сітки з наживкою для тварин, сітки з приманкою для людини і колекції личинок були

зроблені для відбору зразки диких комарів у долині Кіломберо. Також були здобуті записи *An. gambiae* і *An. Funestus*, інших дуже небезпечних комарів, що зустрічаються в Африці на південь від Сахари. За допомогою стандартних методів ідентифікації полімеразної ланцюгової реакції (ПЛР), було ідентифіковано комарів цих груп. Для всіх записів у Таїланді та Танзанії проводився моніторинг умов навколишнього середовища (температура, вологість) по всій території.

**Метадані бази даних.** Дані, представлені в цьому документі, регулярно зберігаються в базі даних PostgreSQL. Для повноти ми включаємо повну схему на рис. 2.4, 2.5 та 2.6. Потрібно зауважити, що, оскільки завантаження даних постійно триває, деякі поля ще не заповнено достатньо, щоб бути корисними під час вилучення даних. Таким чином, метадані обмежені полями, які були перевірені та, швидше за все, будуть найбільш корисними.

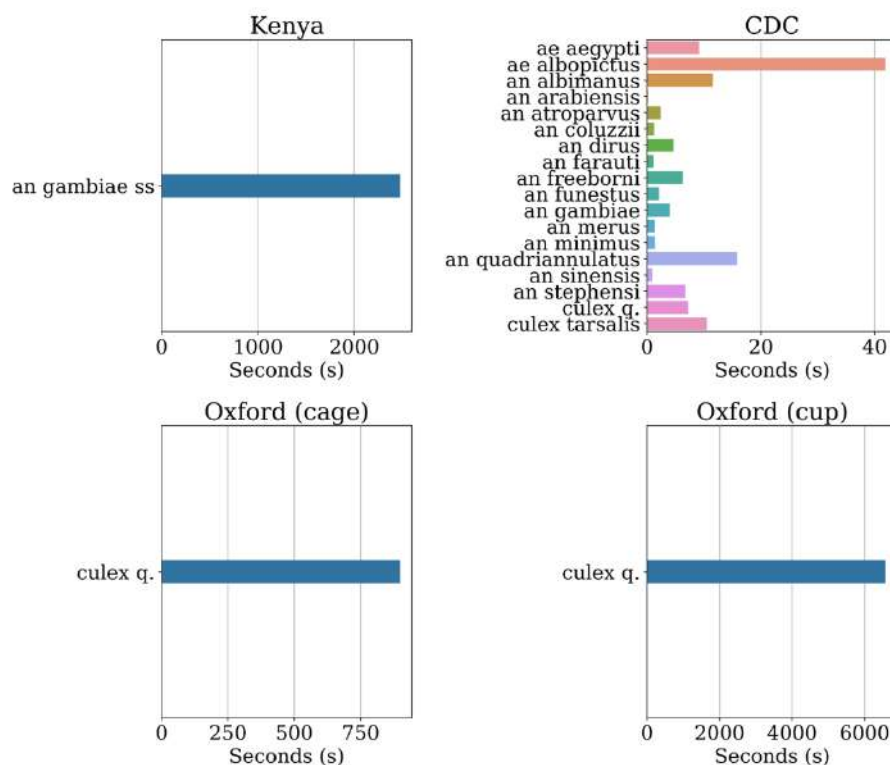


Рисунок 2.4 – Розподіл видів для експерименту



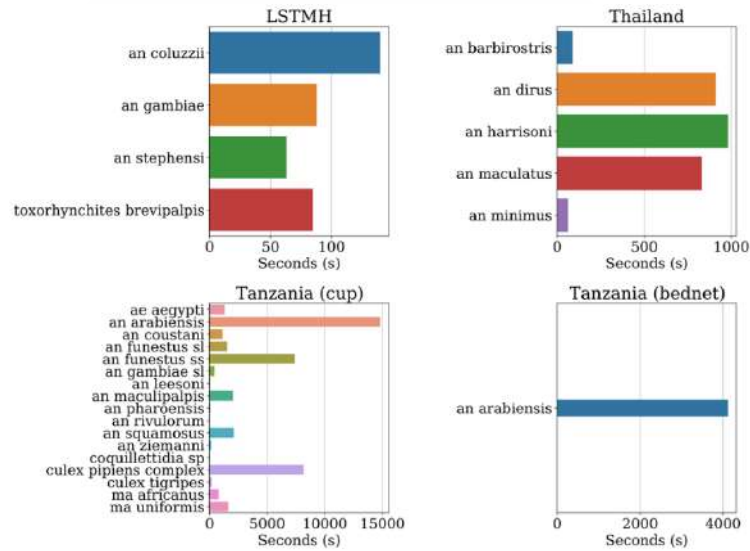


Рисунок 2.5. – Розподіл видів для експерименту

Species	Species per location (seconds)								Total
	Kenya	USA (CDC)	Oxford (cup)	Oxford (cage)	LSTMH	Thailand	Tanzania (cup)	Tanzania (bednet)	
<i>Ae. aegypti</i>	0	9.1	0	0	0	0	1322.4	0	1333.6
<i>Ae. albopictus</i>	0	41.9	0	0	0	0	0	0	41.9
<i>An. albimanus</i>	0	11.6	0	0	0	0	0	0	11.6
<i>An. arabiensis</i>	0	0.1	0	0	0	0	14815.2	4118.2	18933.6
<i>An. atroparvus</i>	0	2.3	0	0	0	0	0	0	2.4
<i>An. barbirostris</i>	0	0	0	0	0	87.8	0	0	87.8
<i>An. coluzzii</i>	0	1.3	0	0	140.0	0	0	0	141.3
<i>An. coustani</i>	0	0	0	0	0	0	1140.6	0	1140.6
<i>An. dirus</i>	0	4.7	0	0	0	909.8	0	0	914.5
<i>An. farauti</i>	0	1.1	0	0	0	0	0	0	1.1
<i>An. freeborni</i>	0	6.3	0	0	0	0	0	0	6.2
<i>An. funestus</i>	0	2.1	0	0	0	0	0	0	2.1
<i>An. funestus s.l.</i>	0	0	0	0	0	0	1542.1	0	1542.1
<i>An. funestus s.s.</i>	0	0	0	0	0	0	7414.2	0	7414.2
<i>An. gambiae</i>	0	4.0	0	0	88.2	0	0	0	92.2
<i>An. gambiae s.l.</i>	0	0	0	0	0	0	406.7	0	406.7
<i>An. gambiae s.s.</i>	2474.2	0	0	0	0	0	0	0	2474.2
<i>An. harrisoni</i>	0	0	0	0	0	980.4	0	0	980.4
<i>An. leesoni</i>	0	0	0	0	0	0	43.5	0	43.5
<i>An. maculatus</i>	0	0	0	0	0	830.4	0	0	830.4
<i>An. maculipalpis</i>	0	0	0	0	0	0	2013.0	0	2013.0
<i>An. merus</i>	0	1.4	0	0	0	0	0	0	1.4
<i>An. minimus</i>	0	1.4	0	0	0	61.5	0	0	63.0
<i>An. pharoensis</i>	0	0	0	0	0	0	56.3	0	56.3
<i>An. quadriannulatus</i>	0	15.9	0	0	0	0	0	0	15.9
<i>An. rivulorum</i>	0	0	0	0	0	0	5.1	0	5.1
<i>An. sinensis</i>	0	1.0	0	0	0	0	0	0	1.0
<i>An. squamosus</i>	0	0	0	0	0	0	2091.8	0	2091.8
<i>An. stephensi</i>	0	6.7	0	0	63.1	0	0	0	69.9
<i>An. ziemanni</i>	0	0	0	0	0	0	110.0	0	110.0
<i>Coquillettidia sp.</i>	0	0	0	0	0	0	25.6	0	25.6
<i>Culex pipiens</i>	0	0	0	0	0	0	8157.8	0	8157.8
<i>Culex q.</i>	0	7.3	6573.1	898.1	0	0	0	0	7478.5
<i>Culex tarsalis</i>	0	10.5	0	0	0	0	0	0	10.5
<i>Culex tigripes</i>	0	0	0	0	0	0	158.7	0	158.7
<i>Ma. africanus</i>	0	0	0	0	0	0	785.2	0	785.2
<i>Ma. uniformis</i>	0	0	0	0	0	0	1654.5	0	1654.6
<i>Toxorhynchites br.</i>	0	0	0	0	84.6	0	0	0	84.6

Рисунок 2.6 – Розподіл видів для експериментальних груп

Перед процесом навчання всіх обраних методів машинного навчання набір даних розділявся в пропорції 80:20 для наборів даних для навчання та тестування.

### 2.3 Конструювання набору ознак

Ознаки - це певні важливі характеристики для точного опису великого набору даних. Процес їх конструювання включає процес їх оцінки на основі вибіркового набору даних з використанням певних математичних алгоритмів. Також важливий етап добір найбільш важливих ознак з точки зору процесу машинного навчання. Основні переваги попереднього відбору найбільш релевантних ознак, перед відбором що його буде здійснювати машинне навчання включають:

- простіші моделі: прості моделі легше пояснити і навпаки занадто складна і незрозуміла модель є менш цінною
- коротший час навчання: відбір більш релевантних ознак зменшує кількість часу, необхідного для навчання моделі
- зменшення дисперсії: підвищення точності оцінок, які можна отримати для даної симуляції

Таблиця 2.1 - Набір ознак звукового сигналу

Ознака	Опис	Позначення в таблиці Pandas
Середньоквадратичне значення (RMS)	Root-mean-square (RMS) energy for each frame, either from the audio samples <code>y</code> or from a spectrogram <code>S</code>	<code>rmse_y</code> <code>rmse</code>
Хромограма	Chromagram from a waveform or power spectrogram	<code>chroma_y</code> <code>chroma</code>
Спектральний центроїд	Compute the spectral centroid (spectrogram)	<code>spec_cent</code>
Спектральна ширина (ширина спектральної смуги)	Compute <code>p</code> 'th-order spectral bandwidth (spectrogram)	<code>spec_bw</code>

Продовження таблиці 2.1

Рівномірність спектральної характеристики	Compute spectral flatness (spectrogram)	spec_flat
Спектральне спадання	Compute roll-off frequency (spectrogram)	spec_rolloff
Швидкість перетину нуля	Compute the rate of an audio time series (from the audio samples)	zcr_y
Мел-частотні кеспральні коефіцієнти	Mel-frequency cepstral coefficients (MFCCs), either from the audio samples $y$ or from a spectrogram $S$ 20 коефіцієнтів	mfcc_y_i
Спектрограма	Spectrogram	mfcc_i

Кожен з аудіозаписів вибірки перетворювався на вектор ознак із мітками класів. Всі ознаки, що видобувались з аудіосигналів, наведені в таблиці 2.1.

Спектральний центроїд звуку представляє «центр маси» цього звуку, і його виводять, беручи середню вагу звукових частот (у рівнянні 1). Якщо частоти звуку є незмінними, спектральний центроїд розташований навколо його центру; і навпаки, якщо звук має високі частоти в кінцевій частині, центроїд буде знайдений біля його кінця. Центроїд вимірює спектральну форму, і відносно високі значення центроїда пов'язані з «яскравішими» тембральними текстурами з більшою часткою високих частот. Для цілей цього рівняння  $M[n]$  позначає значення перетворення Фур'є в часовому кадрі  $t$  і частотному діапазоні  $n$ .

$$C_t = \sum_{n=1}^N nM_t[n] / \sum_{n=1}^N M_t[n] \quad (1)$$

Спектральна смуга пропускання обчислюється за спектральним центроїдом. Він надає інформацію про дисперсію звукового сигналу відносно

спектрального центроїда. Спектральна смуга пропускання має тісний зв'язок із сприйманим тембром у термінах сприйманого тембру. Смуга пропускання пропорційна кількості енергії, яка розподіляється між різними діапазонами частот. Математично це середня вага відстаней між діапазонами частот і центроїдом спектру.

Хромограма - це точно корельована висота звукового сигналу. Висоту можна розділити на дві категорії, які називають кольоровістю тону та висотою. Висота тону відноситься до номера октави; крім того, кольоровість пов'язана з орфографічними характеристиками висоти. Щоб відобразити дані висоти сигналів, ми провели Chromagram STFT, щоб отримати характеристики кольоровості. Основна концепція характеристик кольоровості полягає в тому, щоб зібрати всю спектральну інформацію, пов'язану з конкретним класом висоти, в єдиний коефіцієнт. Відповідно до аудіооктави аудіопотік можна розділити на 12 різних тонів. Хромограма проектує весь спектр на 12 тонів.

Швидкість переходу через нуль сповіщає про сигнал, який змінюється від полярного положення горизонтальної осі. Інформація, надана перетинанням нуля у часовій області, використовується для кількісного визначення шуму сигналу, а середнє значення та дисперсія перетину нуля за часовий період у вікні текстури використовуються як характеристики. Здатність сигналу переходити від позитивного до нуля до негативного та від негативного до нуля до позитивного за певний період вимірюється цим параметром. Рівняння 2 зображує рівняння Zero Crossing Rate протягом заданого часового домену.

$$Z_t = 1/2 \sum_{n=1}^N |\text{sign}(x[n] - \text{sign}(x[n - 1]))| \quad (2)$$

Roll Off вказує на межі високих високих і низьких частот на кривій частотної характеристики. Крім того, частота  $R_t$  позначає Roll Off, і вона зосередила 85% розподілу величини  $\sum_{n=1}^{R_t} M_t[n] = 0.85 \sum_{n=1}^{R_t} M_t[n]$ . Кілька функцій створюються за допомогою дисперсії та середнього значення Roll Off за часові проміжки у вікні текстури.

Крім того, RMSE ще одна важлива функція для дослідження класифікації аудіосигналу. Він представляє середньоквадратичне значення енергії хвильового сигналу як характеристику. Середньоквадратична помилка використовується для характеристики середнього безперервно змінюваних аудіосигналів. Його значення обчислюється покадрово з аудіосигналу.

Кепстральні коефіцієнти - Mel Frequency — популярні функції в процесі розпізнавання звуку. MFCC містять дані про зміну швидкості різних діапазонів спектру. Відповідно до перетворення Фур'є, MFCC розглядаються як перцептивно детерміновані ознаки. Після отримання перетворення Фур'є, спектр величини обробляється через банк фільтрів Мела з динамічною смугою пропускання, що імітує людське вухо, тобто коротка смуга пропускання на нижчій частоті та широка смуга пропускання на вищій частоті. Енергія, що генерується з групи фільтрів, логарифмічно перетворюється, а MFCC формуються за допомогою дискретного косинусного перетворення згенерованих вихідних сигналів. Крім того, бібліотека Python функції MFCC може генерувати максимум від 1 до 128 послідовностей MFCC на основі вимоги.

#### **2.4 Відбір найбільш релевантних ознак**

Для відбору релевантних ознак ми використовували:

- кореляційний аналіз
- проводили навчання нейромережі використовуючи кілька різних наборів ознак

При проведенні кореляційного аналізу нормальність даних перевірялась з використанням тесту Шапіро-Уїлка. Якщо дані були нормальними коефіцієнт кореляції оцінювався за допомогою методу Пірсон, в протилежному випадку за допомогою методу Спірмана. Він показав, що серед них немає нормально розподілених, тому ми використовували метод Спірмана.

Таблиця 2.2. Кореляційний аналіз релевантних ознак

Коефіцієнт кореляції	Категорія
$0.1 <  r  < 0.3$	слабка (weak)
$ r  < 0.1$	дуже слабка (negligible) слабка (weak)
$0.3 <  r  < 0.7$	помірна (moderate)
$0.7 <  r  < 0.9$	сильна (strong)
$ r  > 0.9$	дуже сильна (very strong)

## 2.5 Програмне забезпечення

Побудова та навчання нейромереж, здійснювалась з використанням Python бібліотеки keras. Обчислення ознаки виконувалось з використанням Python бібліотеки librosa. Статистичний аналіз та візуалізація виконувались за допомогою команд Python бібліотек scipy, plotly. Обчислення виконувались в хмарній платформі GoogleCollab.

## РОЗДІЛ ІІІ РЕЗУЛЬТАТИ ЕКСПЕРИМЕНТУ І ЇХ ОБГОВОРЕННЯ

Ми вивчали яким чином архітектура нейромережі, варіювавши кількість шарів та їх розмір, функції активації, алгоритми її оптимізації, вибір набору ознак для навчання, вибір методів глибокого навчання, впливають на її кінцеву ефективність розпізнавати вид комара за його звуками.

### 3.1 Попередня обробка даних

Нами було здійснено попередню обробку даних. Ми залишили для подальшого аналізу тільки ті види комарів, для яких було зібрано більше ніж 80 аудіозаписів.

Таблиця 3.1. – Кількість вимірювань для різних видів комарів в рамках дослідження

Вид комара	Кількість аудіозаписів
An. arabiensis	1984
Background	1891
An. gambiae ss	718
Culex quinquefasciatus	674
Culex pipiens complex	545
An. funestus ss	381
An. squamosus	141
Ma. uniformis	131
An. harrisoni	124
An. maculatus	117
An. dirus	111
An. funestus sl	104
Ae. aegypti	92
An. coustani	92

Нижче на рис. 3.1. – 3.7 - наведені приклади спектрограм комарів різних видів.




Рисунок 3.1 - Спектрограма для аудіозапису комара виду *an dirus*




Рисунок 3.2 - Спектрограма для аудіозапису комара виду *culex quinquefasciatus*.




Рисунок 3.3 - Спектрограма для аудіозапису комара виду *culex quinquefasciatus*.






Рисунок 3.4 - Спектрограма для аудіозапису комара виду *Culex quinquefasciatus*.




Рисунок 3.5 - Спектрограма для аудіозапису комара виду *Anopheles arabiensis*




Рисунок 3.6 - Спектрограма для аудіозапису комара виду *Anopheles arabiensis*




Рисунок 3.7 - Спектрограма для аудіозапису комара виду *an funestus* sl

Також на рис. 3.8 – 3.14 наведені результати віконного перетворення Фур'є тих же аудіосигналів.




Рисунок 3.8 - Спектр для аудіозапису комара виду *an dirus*




Рисунок 3.9 - Спектр для аудіозапису комара виду *culex quinquefasciatus*




Рисунок 3.10 - Спектр для аудіозапису комара виду *Culex quinquefasciatus*




Рисунок 3.11 - Спектр для аудіозапису комара виду *Culex quinquefasciatus*




Рисунок 3.12 - Спектр для аудіозапису комара виду *An. arabiensis*




Рисунок 3.13 - Спектр для аудіозапису комара виду *An. arabiensis*




Рисунок 3.14 - Спектр для аудіозапису комара виду *an funestus sl*

На цих графіках спостерігаємо, що комарі різних видів мають різний основний тон та набір гармонік. Друга, третя та наступні гармоніки кратні частоті основного тону. Амплітуди гармонік є меншими за амплітуду основного тону, оскільки, чим більший порядок гармоніки, тим меншою стає її амплітуда. Між різними видами комарів також спостерігаємо, що основний тон не є сталим і дещо відрізняється у межах одного виду.

Нами була здійснена оцінка фундаментальної частоти для звуків комарів різних видів. Для цього ми використовували алгоритм YIN [39]. Для реалізації цього алгоритму ми використовували Python бібліотеку librosa.

На рис. 3.15 - наведені гістограми фундаментальних частот визначених для всіх аудіозаписів різних видів. На вісі абсцис показані одиниці вимірювання Гц. Як можна бачити, фундаментальна частота для різних видів лежить в межах діапазону від 350 до 650 Гц.

Можна бачити, що розподіл деяких гістограм є полімодальним, тобто є більш ніж один пік. Це може бути пов'язане з тим, що для деяких аудіозаписів алгоритм замість основного тону, ідентифікував другу або третю гармоніки. Також полімодальність може бути пов'язана з тим, що фундаментальна частота може залежати від статті комара чи від його маси.

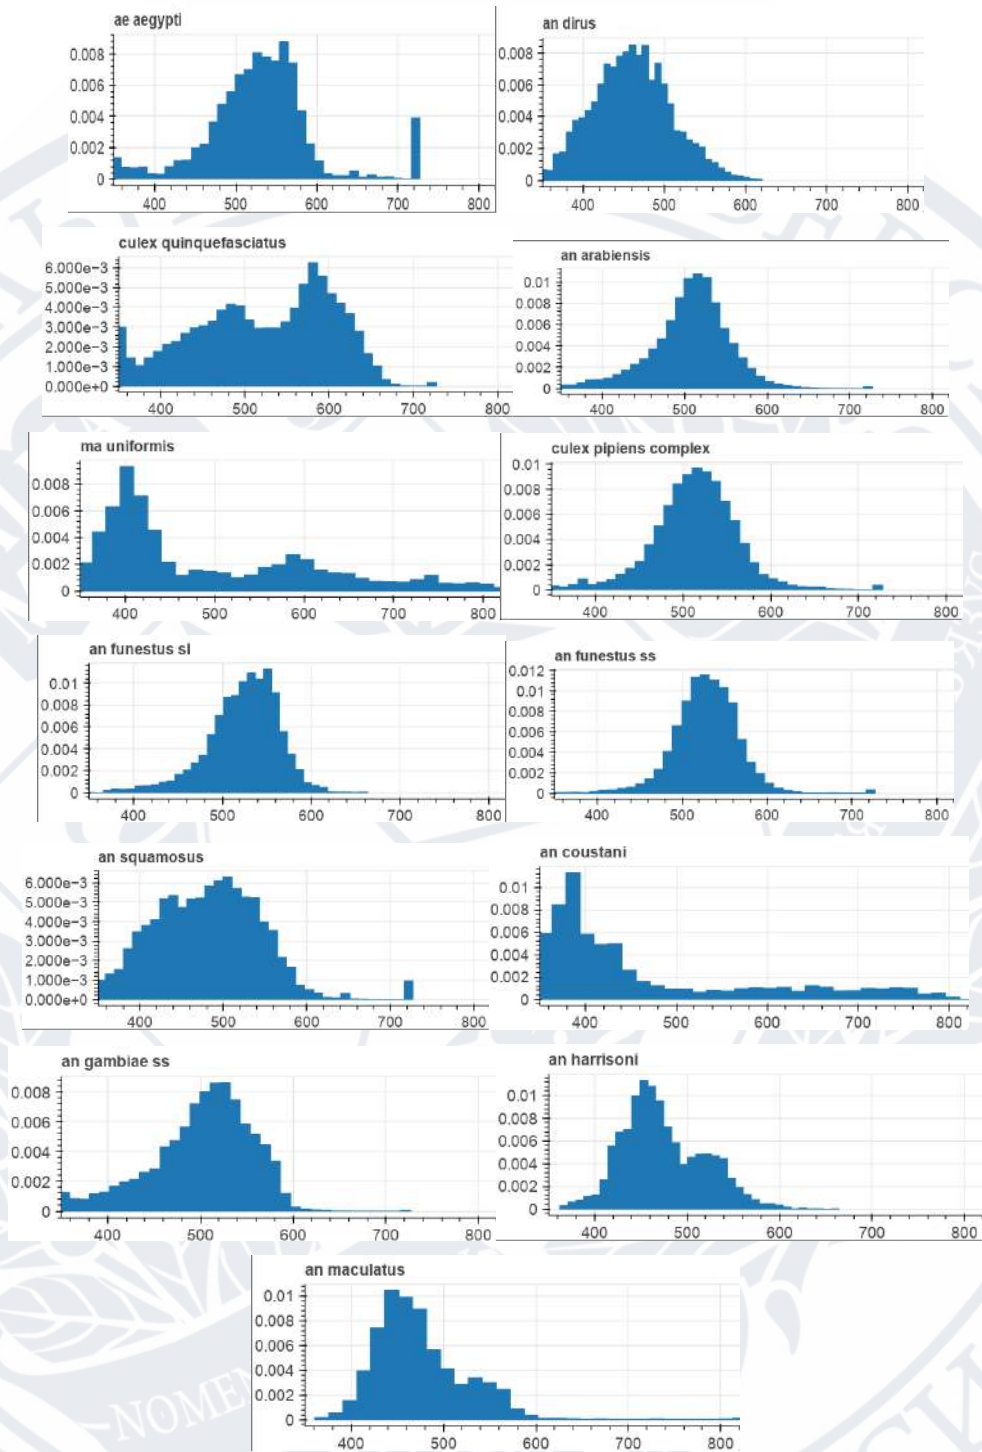


Рисунок 3.15 - Гістограми фундаментальних частот

### 3.2 Кореляційний аналіз набору ознак

Для вивчення впливу вибору ознак на ефективність нейромережі розпізнавати види комарів ми використовували два підходи. По-перше, ми

проводили кореляційний аналіз ознак самих з собою. По-друге, ми використовували різні набори ознак для навчання SNN, при цьому ми спостерігали як це впливало на кінцеву точність роботи нейромережі після її навчання.

Розглянемо результати кореляційного аналізу між різними ознаками на рис. 3.16 -3.21.

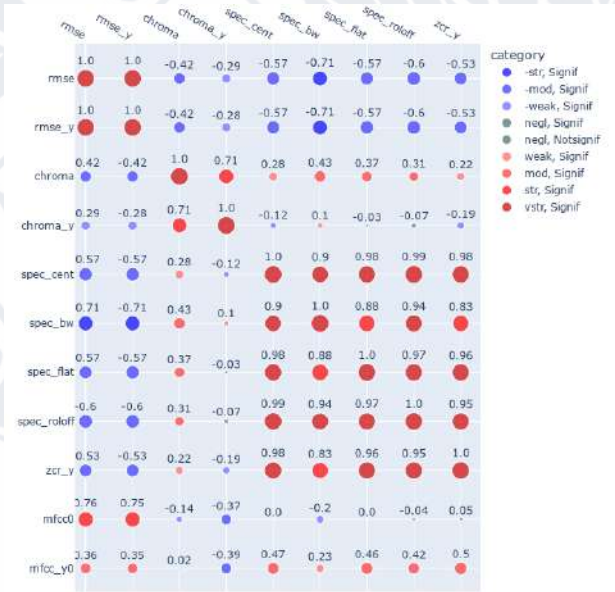


Рисунок 3.16 - Кореляційна матриця для ознак обчислених як середнє їх віконних значень




Рисунок 3.17 - Кореляційна матриця для ознак обчислених як середнє їх віконних значень

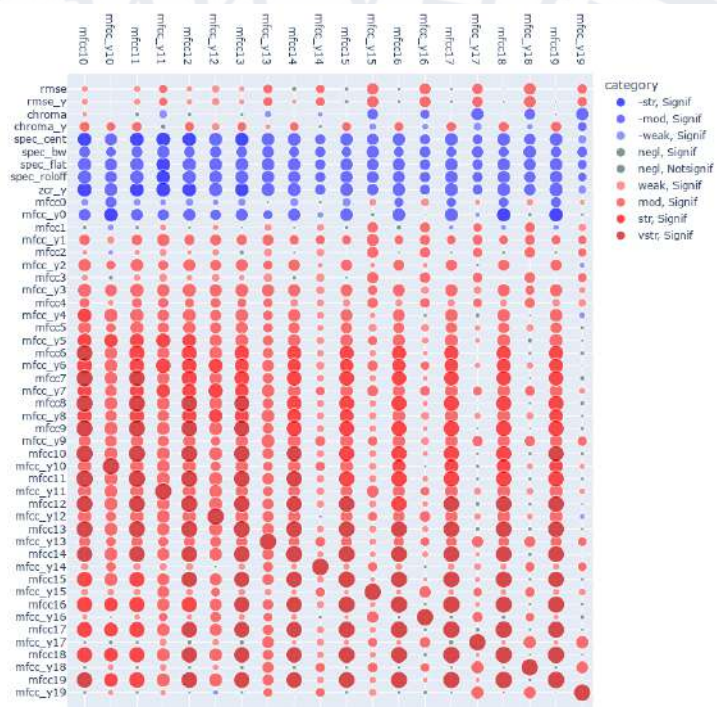


Рисунок 3.18 - Кореляційна матриця для ознак обчислених як середнє їх віконних значень



Рисунок 3.19 - Кореляційна матриця для ознак обчислених як стандартне відхилення їх віконних значень

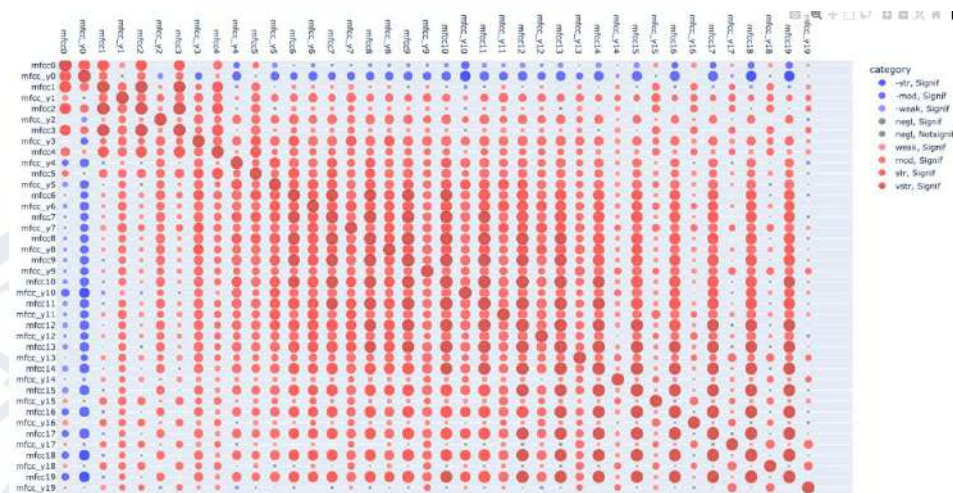


Рисунок 3.20 - Кореляційна матриця для ознак обчислених як стандартне відхилення їх віконних значень




Рисунок 3.21 - Кореляційна матриця для ознак обчислених як стандартне відхилення їх віконних значень

Аналізуючи наведені вище результати можна сказати, що між певними параметрами відбувається абсолютна кореляція. Якщо ознаки корелюють між собою, одна з таких ознак є надлишковою. Ознаки залежні одна від одних не впливають на якість навчання не впливають і можуть бути виключені при обробці даних.

Далі ми спробували навчати SNN різними наборами параметрів, при цьому ми дивились яким це чином впливає на ефективність нейромережі. Ми використовували SNN з трьома прихованими шарами в яких було по 256, 128 та 64 нейронів. використовувалась функція активації `relu`, оптимізатор `Adam`.



Ми навчали цю нейромережу різними наборами ознак. Були використані 5 таких наборів:

- **набір 1** (всі доступні ознаки ) - rmse, rmse\_y, chroma, chroma\_y, spec\_cent, spec\_bw, spec\_flat, spec\_rolloff, zcr\_y, mfcc\_i, mfcc\_y\_i
- **набір 2** (тільки мел-частотні кеспральні коефіцієнти) - mfcc\_i, mfcc\_y\_i
- **набір 3** (всі ознаки за виключенням мел-частотних кеспральні коефіцієнтів) -rmse, rmse\_y, chroma, chroma\_y, spec\_cent, spec\_bw, spec\_flat, spec\_rolloff, zcr\_y
- **набір 4** (ознаки обчислені для аудіосигналу) - rmse\_y, chroma\_y, zcr\_y, mfcc\_y\_i
- **набір 5** (ознаки обчислені для спектрограми) - rmse, chroma, spec\_cent, spec\_bw, spec\_flat, spec\_rolloff, mfcc\_i

Ці ознаки обчислювались в ковзаючому вікні, відповідно для кожного аудіозапису вони представлені набором значень, ці значення усереднювались і також від них знаходилося стандартне відхилення. Таким чином ефективність навчання SNN ми перевіряли з 15 наборами ознак: 5 це середні ознаки для кожного аудіозапису Табл. 3.2, 5 стандартне відхилення Табл. 3.3 і 5 це об'єднані набори з середніми та стандартними відхиленнями Табл. 3.4.

Таблиця 3.2 - Вплив вибору ознак для навчання SNN на відсоток невірних відповідей розпізнавання зразків тестового набору даних, для ознак обчислених як середнє їх віконних значень

<b>Набір ознак</b>	<b>Відсоток невірних відповідей, %</b>	<b>Функція величини втрат</b>
<b>Набір 1.</b> Всі ознаки	16.47	1.87e-4
<b>Набір 2.</b> Тільки мел-частотні кеспральні коефіцієнти	17.17	1.41e-4

## Продовження таблиці 3.2

<b>Набір 3.</b> Всі ознаки за виключенням мел-частотних кеспральні коефіцієнтів	31.67	3.48e-1
<b>Набір 4.</b> Ознаки обчислені для аудіосигналу	17.66	4.96e-4
<b>Набір 5.</b> Ознаки обчислені для спектрограми	23.36	1.95e-1

Таблиця 3.3 - Вплив вибору ознак для навчання SNN на відсоток невірних відповідей розпізнавання зразків тестового набору даних, для ознак обчислених як стандартне відхилення їх віконних значень

<b>Набір ознак</b>	<b>Відсоток невірних відповідей, %</b>	<b>Функція величини втрат</b>
<b>Набір 1.</b> Всі ознаки	24.98	1.17e-3
<b>Набір 2.</b> Тільки мел-частотні кеспральні коефіцієнти	27.80	4.54e-3
<b>Набір 3.</b> Всі ознаки за виключенням мел-частотних кеспральні коефіцієнтів	33.64	1.55e-1
<b>Набір 4.</b> Ознаки обчислені для аудіосигналу	27.80 27.66	6.37e-3 8.38e-2
<b>Набір 5.</b> Ознаки обчислені для спектрограми	32.09	2.18e-1

Таблиця 3.4 - Вплив вибору ознак для навчання SNN на відсоток невірних відповідей розпізнавання зразків тестового набору даних, для ознак обчислених як середнє та стандартне відхилення їх віконних значень

<b>Набір ознак</b>	<b>Відсоток невірних відповідей, %</b>	<b>Функція величини втрат</b>
<b>Набір 1.</b> Всі ознаки	15.48	9.47e-5
<b>Набір 2.</b> Тільки мел-частотні кеспральні коефіцієнти	16.33	6.88e-5
<b>Набір 3.</b> Всі ознаки за виключенням мел-частотних кеспральні коефіцієнтів	24.49	1.03e-2
<b>Набір 4.</b> Ознаки обчислені для аудіосигналу	15.48	1.08e-5
<b>Набір 5.</b> Ознаки обчислені для спектрограми	23.65	5.07e-2

З аналізу наведених вище результатів можна зробити висновок, що найбільш ефективним є використання набору з усіх ознак, що включає ознаки обчислені як середнє їх віконних значень так і як стандартне відхилення.

Причому найбільш релевантними в цьому наборі є:

- ознаки обчислені як середнє їх віконних значень а не як стандартне відхилення
- ознаки обчислені для аудіосигналу, а не на основі спектрограми
- мілко-частотні кеспральні коефіцієнти

Виключення з набору ознак тих які не перелічені в цьому списку, буде призводити до лише незначного погіршення якості розпізнавання (в межах декількох відсотків).

### 3.3 Вплив попередньої обробки аудіо сигналу

Оскільки основний тон та достатньо потужні гармоніки комарів розглянутих нами видів лежать приблизно в діапазоні 350-4000 Гц ми спробували покращити точність розпізнавання пропускаючи аудіосигнали через смуговий фільтр перед оцінкою ознак. Нами був використаний смуговий фільтр Баттерворта 16-го порядку. В таблицях 3.6 та 3.7 наведені результати такого аналізу.

Таблиця 3.6 - Вплив вибору діапазону смуги пропускання фільтра, що застосовувався до аудіосигналів перед отриманням з них ознак на ефективність навчання SNN. Для ознак обчислених як середнє їх віконних значень

Смуга пропускання фільтра, Гц	Відсоток невірних відповідей, %	Функція величини втрат
Без фільтрації	15.62	3.79e-4
300-1000	21.11	1.19e-3
300-2000	18.37	4.25e-4
300-3000	16.89	2.60e-4
1000-3000	17.52	5.69e-4

Таблиця 3.7 - Вплив вибору діапазону смуги пропускання фільтра, що застосовувався до аудіосигналів перед отриманням з них ознак на ефективність навчання SNN. Для ознак обчислених як стандартне відхилення їх віконних значень.

Смуга пропускання фільтра, Гц	Відсоток невірних відповідей, %	Функція величини втрат
Без фільтрації	24.63	3.36e-3
300-1000	27.66	3.36e-4
300-2000	25.69	4.48e-4
300-3000	25.76	6.20e-4
1000-3000	24.42	8.56e-5

З аналізу наведених вище результатів можна зробити висновок, що фільтрація не підвищила ефективність навчання нейромережи. Найбільш релевантною смугою частот важливою для розпізнавання видів комарів можна вважати смугу частот 300–3000 Гц.

### 3.4 Архітектура нейромережі SNN

Ефективність навчання нейромережі може залежати від її архітектури, вибору функції активації та алгоритмів оптимізації.

Використовуючи набір ознак обчислених як середнє їх віконних значень, ми дослідили як впливають на ефективність SNN кількість та розмір прихованих шарів. Навчання тривало 400 епох, функція активації *relu*, оптимізатор Adam. Результати симуляції наведені в табл. 3.8.

Таблиця 3.8 - Вплив кількості та розміру прихованих шарів SNN на відсоток невірних відповідей розпізнавання зразків тестового набору даних

Архітектура прихованих шарів		Відсоток невірних відповідей	Функція величини витрат
Кількість шарів	Кількість нейронів		
1	256	17.95	2.66e-2
2	128, 64	17.10	5.36e-3
2	256, 128	15.76	7.62e-4
2	512, 256	15.76	6.22e-4
3	128, 64, 32	16.33	1.58e-3
3	256, 128, 64	15.20	4.84e-4
3	512, 256, 128	15.62	4.83e-5
4	256, 128, 64, 32	16.12	1.26e-4

З аналізу наведених вище результатів можна зробити висновок, що найбільш ефективним є використання архітектури SNN з двома чи трьома прихованими шарами з кількістю нейронів 256, 128, 64. Подальше збільшення шарів не призводить до покращення якості та точності розпізнавання. Впливає

лише на збільшення машинних ресурсів та кількості часу потрібного на навчання нейромережі.

### 3.5 Вибір функції активації та алгоритму оптимізації

Спочатку нам потрібно знайти найкращу архітектуру для Sequential NN. У бібліотеці Python Keras є три функції активації — Relu (випрямлена лінійна одиниця), Sigmoid і Tanh (функція гіперболічної дотичної активації). Крім того, вісім оптимізаторів - Adam (Adaptive Moment Estimation), AdaDelta, AdaGrad, AdaMax, FTRL (Follow the Regularized Leader), Nadam (Nesterov-accelerated Adaptive Moment Estimation), RMSProp (Root Mean Squared Propagation), SGD (Stochastic Gradient. Descent) – також доступні в Keras. Таким чином, у цьому дослідженні необхідно вибрати найкращу функцію активації та оптимізатор із згаданого вище списку функцій активації та оптимізаторів для аналізу продуктивності.

Ми дослідили як впливають на ефективність SNN вибір функції активації та алгоритму оптимізації вагових коефіцієнтів табл. 3.9.

Таблиця 3.9 - Вплив вибору функції активації та оптимізатора на відсоток невірних відповідей(величину функції витрат) розпізнавання зразків тестового набору даних

Активатор	Алгоритм оптимізації			
	adam	SGD	Adamax	Adadelta
relu	16.47 (7.19e-05)	20.48 (2.61e-01)	18.37 (3.73e-03)	54.05 (1.02e+00)
sigmoid	17.80 (5.57e-02)	45.74 (9.93e-01)	23.01 (3.85e-01)	100.00 (2.02e+00)
tanh	19.56 (4.62e-02)	22.59 (3.62e-01)	17.31 (1.61e-03)	47.57 (9.30e-01)

З аналізу наведених вище результатів можна зробити висновок, що найбільш ефективним є використання для нейронів прихованих шарів функції активації relu, алгоритм оптимізації вагових коефіцієнтів adam.

### 3.6 Вибір методів глибокого навчання

Нарешті ми дослідили як впливає на ефективність вибір методу глибокого навчання, ми порівнювали дві нейромережі SNN та CNN Табл. Ми використовували нейромережу SNN в якій було 3 прихованих повнозв'язаних шарів з кількістю нейронів 256, 128, 64, та функцією активації 'relu'. Вихідний шар мав 14 нейронів, що відповідають 14 класам, які мали функцію активації 'softmax'. Функція втрат `sparse_categorical_crossentropy`, оптимізатор 'adam'. Для навчання використовувався повний набір ознак, що отримувались для необроблених записів. Результати симуляції наведені на рис. 3.22 – 3.25.




Рисунок 3.22 - Втрати тренувальної і перевіркої вибірки, для нейромережі SNN

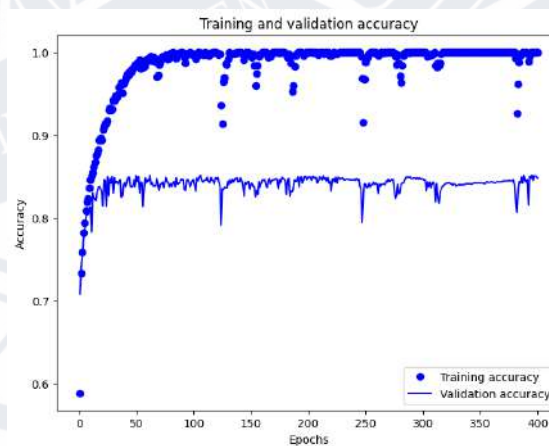


Рисунок 3.23 - Точність тренувальної і перевіркої вибірки, для нейромережі SNN

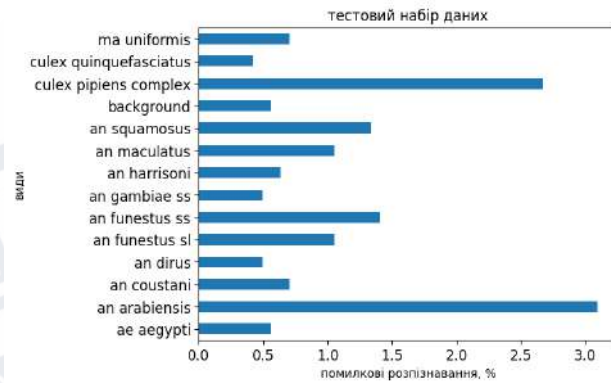


Рисунок 3.24 - Розподіл помилок розпізнавання за класами, для нейромережі SNN

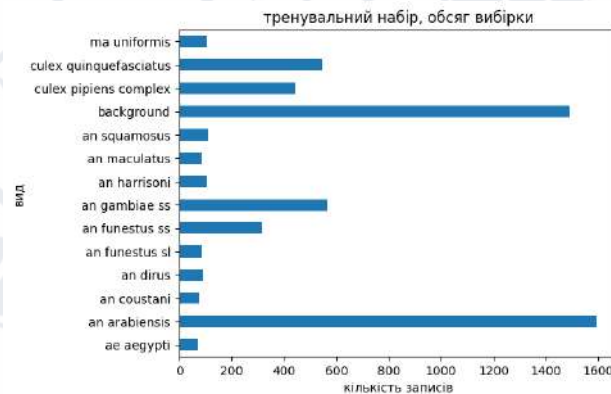


Рисунок 3.25 - Обсяг вибірок для різних класів, для нейромережі SNN

Фінальна точність складала – 15% нерозпізнаних зразків, величина функції втрат  $8.41e-4$ . Як можна бачити з рис. 3.24 та рис. 3.25 найбільша кількість нерозпізнаних зразків припадає на комарів *culex*, кількість нерозпізнаних зразків, що припадає на даний вид не корелює з розміром вибірки.

Ми випробували дві нейромережі CNN. В обох випадках на вхід подавались кольорові зображення спектрограм розміром  $256 \times 256$  пікселів. Перша нейромережа (CNN1) складалась з 3х згорткових шарів ( $32@254 \times 254$ ,  $32@125 \times 125$ ,  $32@60 \times 60$ ), що чергувались з шарами субдискретизації (MaxPooling). Для зменшення ефекту “перенавчання” також використовувався L2-регуляризатор. За ними йшли шар сплюснення (Flatten), прихований повнозв’язаний шар, та щільний вихідний шар, що мав 14 нейронів які мали



функцію активації 'softmax'. Функція втрат categorical\_crossentropy, оптимізатор 'adam'. Результати симуляції наведені на рис. 3.26-3.27.

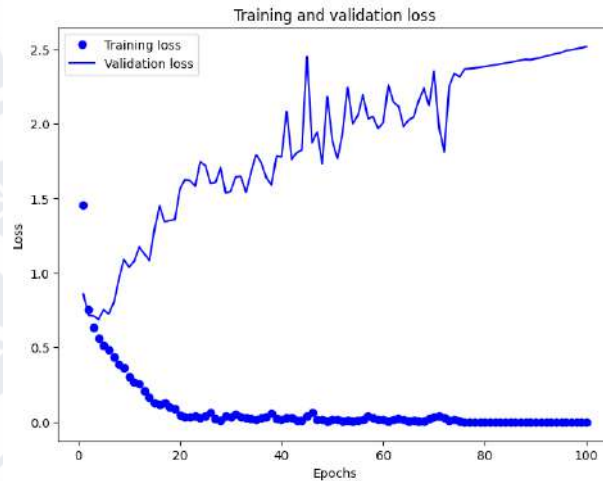


Рисунок 3.26 - Втрати тренувальної і перевіркої вибірки




Рисунок 3.27 - Точність тренувальної і перевіркої вибірки

Фінальна точність склала – 24% нерозпізнаних зразків, величина функції втрат  $2.15e-$

Друга неймережа (CNN2) складалась з 4х згорткових шарів (32@222x222, 128@109x109, 128@52x52, 128@24x24 ), що чергувались з шарами субдискретизації (MaxPooling). Для зменшення ефекту “перенавчання” також використовувався L2-регуляризатор. За ними йшли шар сплющення (Flatten), прихований повнозв’язаний шар, та щільний вихідний

шар, що мав 14 нейронів які мали функцію активації 'softmax'. Функція втрат categorical\_crossentropy, оптимізатор 'adam'. Результати симуляції наведені на рис. 3.28 – 3.29.

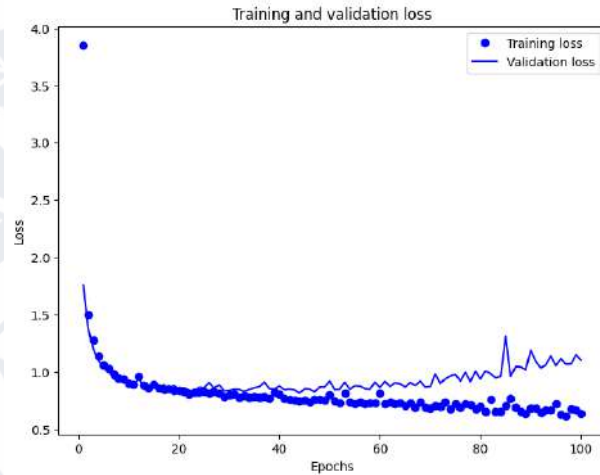


Рисунок 3.28 - Точність тренувальної і перевіркої вибірки

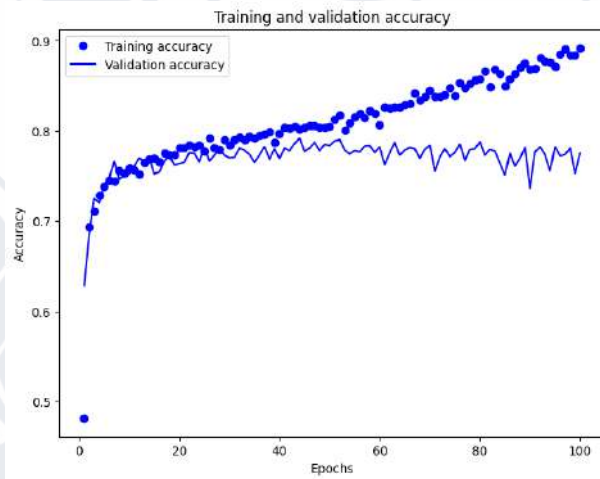


Рисунок 3.29 - Точність тренувальної і перевіркої вибірки

Фінальна точність склала – 21% нерозпізнаних зразків, величина функції втрат  $2.5e^{-}$

Таблиця 3.10 - Вплив методу глибокого навчання на відсоток невірних відповідей розпізнавання зразків тестового набору даних

Техніка глибокого навчання	Відсоток невірних відповідей	Функція величини витрат
Sequential Neural Network	15%	8.41e-4
Convolutional Neural Network 1	24%	2.15-4
Convolutional Neural Network 2	21%	1.10e-4

Згорткові нейромережі CNN1 та CNN2 дали приблизно однакову точність, але в нейромережі CNN2, що має більшу кількість згорткових шарів, що також мають фільтри більшої розмірності, дещо вдалося зменшити ефект перенавчання. Використанням згорткових нейромереж не вдалося покращити точність порівняно з послідовною нейромережею SNN. Хоча згорткові нейромережі і мають перевагу, в тому що вони потребують меншої обробки вхідних даних, однак порівняно з SNN вони також потребують набагато більше машинних ресурсів та часу для свого навчання.

## ВИСНОВКИ

1. Було оброблено 7105 аудіозаписів звуків 14 різних видів комарів з відкритої бази даних NumBugDB. Для кожного запису було отримано: спектрограму, спектр амплітуд, 49 звукових ознак. Крім того, використовуючи алгоритм YIN здійснювалась оцінка фундаментальної частоти. Було виявлено, що фундаментальна частота різних видів лежить в межах діапазону від 350 до 650 Гц, верхня межа для гармонік більш високого порядку приблизно 4000 Гц.
2. Для відбору найбільш релевантних для навчання звукових ознак проводився їх кореляційний аналіз, також ми проводили навчання нейромережі SNN з різними наборами ознак. Кореляційний аналіз показав, що без впливу на якість навчання нейронної мережі, можна виключити деякі мел-частотні кеспральні коефіцієнти. Також дуже сильна кореляція спостерігалась між такими показниками як спектральний центроїд, спектральна ширина, рівномірність спектральної характеристики.
3. Також відбір релевантних ознак здійснювався шляхом навчання SNN з різними наборами ознак, при цьому ми дивились яким це чином впливає на ефективність нейромережі. Було з'ясовано, що найбільш релевантними ознаками для проведення машинного навчання є ознаки обчислені як середнє їх віконних значень а не як стандартне відхилення; □ознаки обчислені для аудіосигналу, а не на основі спектрограми; мел-частотні кеспральні коефіцієнти.
4. Спроби покращити точність навчання нейромережі SNN, шляхом фільтрації аудіосигналів смуговим фільтром перед оцінкою ознак не призвели до підвищення ефективності навчання нейромережі. Найбільш релевантною смугою частот важливою для розпізнавання видів комарів можна вважати смугу частот 300–3000 Гц.
5. Найбільш ефективним є використання архітектури SNN, які мають два або три шари з кількістю нейронів 256, 128 та 64. Подальше збільшення

шарів/кількості нейронів не призводить до покращення якості та підвищення ефективності. Найбільш ефективним є використання для нейронів прихованих шарів функції активації *relu*, алгоритм оптимізації вагових коефіцієнтів *adam*.

6. Ми порівняли точність розпізнавання для різних методів глибокого навчання, порівнювалась послідовні (SNN) та згорткові нейромережі (CNN). Згорткові нейромережі не продемонстрували більшої точності порівняно з послідовною нейромережею SNN. Хоча згорткові нейромережі і мають перевагу, в тому що вони потребують меншої обробки вхідних даних, однак порівняно з SNN вони також потребують набагато більше машинних ресурсів та часу для свого навчання.

**СПИСОК ВИКОРИСТАНИХ ДЖЕРЕЛ**

1. Onen H, Luzala MM, Kigozi S, Sikumbili RM, Muanga CK, Zola EN, Wendji SN, Buya AB, Balciunaitiene A, Viškelis J, Kaddumukasa MA, Memvanga PB. Mosquito-Borne Diseases and Their Control Strategies: An Overview Focused on Green Synthesized Plant-Based Metallic Nanoparticles. *Insects*. 2023 Feb 23;14(3):221. doi: 10.3390/insects14030221. PMID: 36975906; PMCID: PMC10059804.
2. Dahmana H, Mediannikov O. Mosquito-Borne Diseases Emergence/Resurgence and How to Effectively Control It Biologically. *Pathogens*. 2020 Apr 23;9(4):310. doi: 10.3390/pathogens9040310. PMID: 32340230; PMCID: PMC7238209.
3. Pryce J, Richardson M, Lengeler C. Insecticide-treated nets for preventing malaria. *Cochrane Database Syst Rev*. 2018 Nov 6;11(11):CD000363. doi: 10.1002/14651858.CD000363.pub3. PMID: 30398672; PMCID: PMC6418392.
4. Chuma J, Okungu V, Ntwiga J, Molyneux C. Towards achieving Abuja targets: identifying and addressing barriers to access and use of insecticides treated nets among the poorest populations in Kenya. *BMC Public Health*. 2010 Mar 16;10:137. doi: 10.1186/1471-2458-10-137. PMID: 20233413; PMCID: PMC2847543.
5. Alphey L, Benedict M, Bellini R, Clark GG, Dame DA, Service MW, Dobson SL. Sterile-insect methods for control of mosquito-borne diseases: an analysis. *Vector Borne Zoonotic Dis*. 2010 Apr;10(3):295-311. doi: 10.1089/vbz.2009.0014. PMID: 19725763; PMCID: PMC2946175.
6. Bourtzis K, Vreysen MJB. Sterile Insect Technique (SIT) and Its Applications. *Insects*. 2021 Jul 13;12(7):638. doi: 10.3390/insects12070638. PMID: 34357298; PMCID: PMC8304793.

7. Kiskin I, Sinka M, Cobb Adam D, Rafique W, Wang L, Zilli D, Gutteridge B, Dam R, Marinos T, Li Y, Msaky D, Kaindoa E. HumBugDB: A Large-scale Acoustic Mosquito Dataset 2021 Oct
8. Laroche M, Raoult D, Parola P. Insects and the Transmission of Bacterial Agents. *Microbiol Spectr*. 2018 Oct;6(5). doi: 10.1128/microbiolspec.MTBP-0017-2016. PMID: 30306888.
9. Ferreira AG, Fairlie S, Moreira LA. Insect vectors endosymbionts as solutions against diseases. *Curr Opin Insect Sci*. 2020 Aug;40:56-61. doi: 10.1016/j.cois.2020.05.014. Epub 2020 Jun 4. PMID: 32599512.
10. Mohd Adnan K. A review on Respiratory allergy caused by insects. *Bioinformation*. 2018 Dec 22;14(9):540-553. doi: 10.6026/97320630014540. PMID: 31223213; PMCID: PMC6563666.
11. Fang Y, Zhang W, Xue JB, Zhang Y. Monitoring Mosquito-Borne Arbovirus in Various Insect Regions in China in 2018. *Front Cell Infect Microbiol*. 2021 Mar 11;11:640993. doi: 10.3389/fcimb.2021.640993. PMID: 33791242; PMCID: PMC8006455.
12. Epelboin Y, Talaga S, Epelboin L, Dusfour I. Zika virus: An updated review of competent or naturally infected mosquitoes. *PLoS Negl Trop Dis*. 2017 Nov 16;11(11):e0005933. doi: 10.1371/journal.pntd.0005933. PMID: 29145400; PMCID: PMC5690600.
13. Plourde AR, Bloch EM. A Literature Review of Zika Virus. *Emerg Infect Dis*. 2016 Jul;22(7):1185-92. doi: 10.3201/eid2207.151990. Epub 2016 Jul 15. PMID: 27070380; PMCID: PMC4918175.
14. Pielnaa P, Al-Saadawe M, Saro A, Dama MF, Zhou M, Huang Y, Huang J, Xia Z. Zika virus-spread, epidemiology, genome, transmission cycle, clinical manifestation, associated challenges, vaccine and antiviral drug development. *Virology*. 2020 Apr;543:34-42. doi: 10.1016/j.virol.2020.01.015. Epub 2020 Feb 2. PMID: 32056845.

15. Tian J, Yu B, Shi X, Liang H, Wang D, Ge M. Sequencing and analysis of the complete mitochondrial genome of *Mansonia uniformis* (Dipera: Culicidae). *Mitochondrial DNA B Resour.* 2020 Jan 10;5(1):498-499. doi: 10.1080/23802359.2019.1704638. PMID: 33366619; PMCID: PMC7748744.
16. Ridha MR, Rahayu N, Hairani B, Perwitasari D, Kusumaningtyas H. Biodiversity of mosquitoes and *Mansonia uniformis* as a potential vector of *Wuchereria bancrofti* in Hulu Sungai Utara District, South Kalimantan, Indonesia. *Vet World.* 2020 Dec;13(12):2815-2821. doi: 10.14202/vetworld.2020.2815-2821. Epub 2020 Dec 30. PMID: 33488003; PMCID: PMC7811548.
17. Flores GAM, Lopez RP, Cerrudo CS, Perotti MA, Consolo VF, Berón CM. *Wolbachia* dominance influences the *Culex quinquefasciatus* microbiota. *Sci Rep.* 2023 Nov 3;13(1):18980. doi: 10.1038/s41598-023-46067-2. PMID: 37923779; PMCID: PMC10624681.
18. Shemshadian A, Vatandoost H, Oshaghi MA, Abai MR, Djadid ND, Karimian F. Relationship between *Wolbachia* infection in *Culex quinquefasciatus* and its resistance to insecticide. *Heliyon.* 2021 Apr 13;7(4):e06749. doi: 10.1016/j.heliyon.2021.e06749. PMID: 33912718; PMCID: PMC8065290.
19. Rios FGF, Menezes CA, Silva LR, Feitoza LHM, Meireles ACA, Julião GR. *Culex quinquefasciatus* predominance during integrated mosquito surveillance in an urban area of the Brazilian Amazon. *Braz J Biol.* 2022 Nov 14;82:e266219. doi: 10.1590/1519-6984.266219. PMID: 36383798.
20. Sumruayphol S, Chaiphongpachara T, Samung Y, Ruangsittichai J, Cui L, Zhong D, Sattabongkot J, Sriwichai P. Seasonal dynamics and molecular differentiation of three natural *Anopheles* species (Diptera: Culicidae) of the *Maculatus* group (*Neocellia* series) in malaria hotspot villages of Thailand.



- Parasit Vectors. 2020 Nov 11;13(1):574. doi: 10.1186/s13071-020-04452-0. PMID: 33176862; PMCID: PMC7659066.
21. Sukkanon C, Masangkay FR, Mala W, Kotepui KU, Wilairatana P, Chareonviriyaphap T, Kotepui M. Prevalence of Plasmodium spp. in Anopheles mosquitoes in Thailand: a systematic review and meta-analysis. Parasit Vectors. 2022 Aug 6;15(1):285. doi: 10.1186/s13071-022-05397-2. PMID: 35933389; PMCID: PMC9357324.
22. Yan C, Hii J, Ngoen-Klan R, Saeung M, Chareonviriyaphap T. Semi-field evaluation of human landing catches *versus* human double net trap for estimating human biting rate of *Anopheles minimus* and *Anopheles harrisoni* in Thailand. PeerJ. 2022 Sep 8;10:e13865. doi: 10.7717/peerj.13865. PMID: 36101880; PMCID: PMC9464434.
23. Mukundarajan H, Hol FJH, Castillo EA, Newby C, Prakash M. Using mobile phones as acoustic sensors for high-throughput mosquito surveillance. Elife. 2017 Oct 31;6:e27854. doi: 10.7554/eLife.27854. PMID: 29087296; PMCID: PMC5663474.
24. Garcia GA, Lord AR, Santos LMB, Kariyawasam TN, David MR, Couto-Lima D, Tátilla-Ferreira A, Pavan MG, Sikulu-Lord MT, Maciel-de-Freitas R. Rapid and Non-Invasive Detection of *Aedes aegypti* Co-Infected with Zika and Dengue Viruses Using Near Infrared Spectroscopy. Viruses. 2022 Dec 20;15(1):11. doi: 10.3390/v15010011. PMID: 36680052; PMCID: PMC9863061.
25. Huang AW, Haslberger M, Coulibaly N, Galárraga O, Oganisian A, Belbasis L, Panagiotou OA. Multivariable prediction models for health care spending using machine learning: a protocol of a systematic review. Diagn Progn Res. 2022 Mar 24;6(1):4. doi: 10.1186/s41512-022-00119-9. PMID: 35321760; PMCID: PMC8943988.
26. Rush B, Celi LA, Stone DJ. Applying machine learning to continuously monitored physiological data. J Clin Monit Comput. 2019 Oct;33(5):887-893.

- doi: 10.1007/s10877-018-0219-z. Epub 2018 Nov 11. PMID: 30417258; PMCID: PMC6511324.
27. Mofatteh M. Neurosurgery and artificial intelligence. *AIMS Neurosci.* 2021 Aug 6;8(4):477-495. doi: 10.3934/Neuroscience.2021025. PMID: 34877400; PMCID: PMC8611194.
28. Stewart M. Simple Introduction to Convolutional Neural Networks [Электронный ресурс] / Matthew Stewart // Towards Data Science. – 2019. – Режим доступа до ресурсу: <https://towardsdatascience.com/simple-introduction-to-convolutional-neural-networks-cdf8d3077bac>.
29. M. Simões, R. A. Ingham, G. Gibson, and I. J. Russell. A role for acoustic distortion in novel rapid frequency modulation behaviour in free-flying male mosquitoes. *Journal of Experimental Biology*, 219(13):2039–2047, 2016.
30. Fanioudakis, M. Geismar, and I. Potamitis. Mosquito wingbeat analysis and classification using deep learning. In *2018 26th European Signal Processing Conference (EUSIPCO)*, pages 2410–2414, 2018.
31. Li, D. Zilli, H. Chan, I. Kiskin, M. Sinka, S. Roberts, and K. Willis. Mosquito detection with low-cost smartphones: data acquisition for malaria research. *NeurIPS Workshop on Machine Learning for the Developing World*, 2017b
32. Kiskin, A. D. Cobb, M. Sinka, and S. J. Roberts. Automatic acoustic mosquito tagging with Bayesian neural networks. *The European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases*, 2021.
33. HumBugDB Ivan Kiskin, Lawrence Wang, Marianne Sinka, Adam D. Cobb, Benjamin Gutteridge, Davide Zilli, Waqas Rafique, Rinita Dam, Theodoros Marinos, Yunpeng Li, Gerard Killeen, Dickson Msaky, Emmanuel Kaindoa, Kathy Willis, & Steve J. Roberts. (2021).
34. PostgreSQL Global Development Group. PostgreSQL, 2021. URL <https://www.postgresql.org/docs/9.3/app-psql.html>. Accessed: 2021-06-05.

- 35.Sahoo. Voice activity detection for low-resource settings. *Department of Electrical Engineering, Stanford University*, 2020.
- 36.Karrer. Google WebRTC Voice Activity Detection module, 2020. URL <https://github.com/rafaelkarrer/mex-webrtcvad/releases/tag/v0.1>. Accessed: 2021-06-05.
- 37.Li, I. Kiskin, M. Sinka, D. Zilli, H. Chan, E. Herreros-Moya, T. Chareonviriyaphap, R. Tisgratog, K. Willis, and S. Roberts. Fast mosquito acoustic detection with field cup recordings: an initial investigation. *Detection and Classification of Acoustic Scenes and Events*, 2018.
- 38.World Health Organization. World malaria report 2020: 20 years of global progress and challenges. 2020. URL <https://www.who.int/publications/i/item/9789240015791>. Accessed: 2021-09-21.
- 39.De Cheveigné, Alain, and Hideki Kawahara. “YIN, a fundamental frequency estimator for speech and music.” *The Journal of the Acoustical Society of America* 111.4 (2002): 1917-1930.