



CHALMERS



Smarta bikupor

Automatisering av biodlingsprocessen genom maskininlärning på sensordata från bikupor

Kandidatarbete vid institutionen för fysik

**Adina Hellström, Elliot Källander, Hampus de Flon,
Marcus Möller, Mohammed Rauf, Omar Sulaiman**

INSTITUTIONEN FÖR FYSIK
CHALMERS TEKNISKA HÖGSKOLA

Göteborg, Sverige 2023
www.chalmers.se

Smarta bikupor

Automatisering av biodlingsprocessen genom maskininlärning på sensordata från bikupor

© Adina Hellström, Elliot Källander, Hampus de Flon, Marcus Möller, Mohammed Rauf, Omar Sulaiman, 2023.

Handledare: Björn Wickman, Institutionen för fysik

Industrihandledare: Lars-Erik Lindberg, Ericsson

Examinator: Jan Swenson

Kandidatuppsats 2023 TIFX11-23-28

Institutionen för fysik

Chalmers tekniska högskola

Göteborg

Omslag: *Hives in an apiary with bees flying to the landing boards* tagen av Kosolovskyy. Hämtad från:
https://stock.adobe.com/se/images/hives-in-an-apiary-with-bees-flying-to-the-landing-boards-apiculture/158322617?asset_id=126989830

Typsatt i L^AT_EX

Göteborg, Sverige 2023

BACHELOR'S THESIS 2023

Smart Beehives

Automation of the beekeeping process using machine learning on sensor data from beehives

Adina Hellström, Elliot Källander, Hampus de Flon,
Marcus Möller, Mohammed Rauf, Omar Sulaiman

Abstract

Honey bees play a crucial role as pollinators, contributing to food production and ecological diversity globally. As a beekeeper, the work is often manual and time-consuming. The aim of this project is to automate the beekeeping process using smart beehives and create a web-based application utilizing sensor data, data analysis and artificial intelligence. The application incorporates models for sound anomaly and sound classification, image anomaly, ant detection, pollen detection, swarm risk, and calculation of the beehive's health status. All models except the pollen detection model were created during the project, using previously collected data from sensors and then implemented in real-time.

The machine learning algorithms K Nearest Neighbors and Isolation Forest are used for sound classification and anomaly models, respectively. An object detection model is used for pollen and ant detection and two different expert systems with defined conditions for weight, temperature, and weather are used for swarm risk and calculation of the beehive's state. During testing, sound classification showed an F1 score of 0.91–1 for three out of four classes, and ant detection showed a precision of 97%. The swarm risk model can be used to indicate and detect if bees will leave their beehive to form a new colony somewhere else, which is an undesirable phenomenon for beekeepers. When the model was tested using past data, it identified correctly that swarm did not happen for 357 out of 359 cases. The expert system for the health status worked correctly when tested on current health status. The results of the anomaly models could only be analyzed, not tested. However, several anomalies were identified in both models, which proves their valuability. The implementation of the pollen detection model to run in real-time was successful, and the application worked as expected during runtime. The integration of the models in the web-based application completed the development process and the purpose of the project is considered achieved.

Further development and additional evaluation of the models will be possible when more varied data can be collected. The application has been adapted to suit beekeepers with both few and many beehives and is considered to be able to facilitate the beekeeping process. The project has increased the knowledge of the use of smart beehives and can therefore contribute to future innovations in technology for sustainable development.



CHALMERS

Department of Physics

Chalmers University of Technology

Gothenburg, Sweden 2023

Sammandrag

Honungsbin spelar en avgörande roll som pollinatörer och bidrar till livsmedelsproduktion och ekologisk mångfald globalt. Som biodlare utförs manuellt arbete som ofta är tidskrävande. Syftet med detta projekt är att automatisera biodlingsprocessen med hjälp av smarta bikupor och skapa en web-baserad applikation som använder sensordata, dataanalys och artificiell intelligens. Applikationen innehåller modeller för ljudavvikelse och ljudklassificering, objektavvikelse, myrdetektion, pollendetektion, svärningsrisk och beräkning av bikupans hälsotillstånd. Alla modeller utom den för pollendetektion skapades under projektets gång, genom att använda tidigare insamlad data från sensorer och sedan implementeras i realtid.

Maskininlärningsalgoritmerna *K-nearest neighbors* och *Isolation Forest* används för ljudklassificering och avvikelsemodeller, respektive. En objektdektionsmodell används för pollen- och myrdetektion, och två olika expertsystem med definierade villkor för vikt, temperatur och väder används för svärningsrisk och beräkning av bikupans tillstånd. Under testning visade ljudklassificeringen ett F1-värde på 0,91-1 för tre av fyra klasser och myrdetektionen visade en precision på 97 %. Svärningsriskmodellen kan användas för att indikera om en del av bina är på väg att lämna sin bikupa för att bilda ett nytt samhälle någon annanstans, vilket är en oönskad företeelse för biodlare. När modellen testades med historisk data identifierade den korrekt att svärmning inte skedde för 357 av 359 fall. Expertsystemet för hälsotillstånd fungerade korrekt när det testades på nuvarande hälsotillstånd. Resultaten av avvikelsemodellerna kunde bara analyseras, inte testas. Men flera avvikelser identifierades i båda modellerna, vilket visar deras värde. Implementeringen av pollen dektionsmodellen för realtidskörning var lyckad och applikationen fungerade som förväntat vid körning. Integreringen av modellerna i den webbaserade applikationen avslutade utvecklingsprocessen och projektets syfte anses uppnått.

Vidareutveckling och ytterligare utvärdering av modellerna kommer att vara möjlig när mer varierad data kan samlas in. Applikationen har anpassats för att passa biodlare med både få och många bikupor och anses kunna användas för att underlätta biodlingsprocessen. Projektet har breddat kunskapen om användning av smarta bikupor och kan därför bidra till framtida innovationer inom teknik för hållbar utveckling.

Förord

Kandidatarbetet Smarta bikupor har bedrivits på Chalmers i samarbete med med Ericsson. Vi har fortsatt på ett pågående arbete *Connected Beehives* som är en del av Ericsson Garage på Lindholmen, deras inkubator för innovativa projekt med fokus på hållbarhet. Vi är mycket tacksamma för möjligheten att få ta del av detta projektet vilket inte skulle vara möjligt utan Ericssons varma välkomnande.

Vi vill framföra ett stort tack till våra handledare Björn Wickman, på Chalmers, och Lars-Erik Lindberg på Ericsson, för deras vägledning under projektet. Tack till Johan Nicander för teknisk hjälp och för alla kloka tankar när vi har bollat idéer tillsammans. Vi vill även tacka Björn Franzon för ovärderlig hjälp med OWL miljön. Därutöver vill vi tacka Tuss Anzelius, Måns Josefsson, Lisa Samuelsson, Kevin Svensson, Filip Rydin, Lovisa Åkesson som tidigare har arbetat med detta projektet och varit till stor inspiration under vidareutvecklingen. Till sist vill vi tacka Christopher Persson, Enayatullah Norozi, Andrei Borg, Nadia Papa, Samuel Kyletoft, Fredrik Jansson och Per Samuelsson som utvecklade modellen för pollendetektion.

Adina, H. Elliot, K. Hampus, d F. Marcus, M. Mohammed, R. Omar, S.

Innehåll

1	Inledning	1
1.1	Bakgrund	1
1.2	Syfte	1
1.3	Avgränsningar	2
2	Teori om bin och bisamhället	2
2.1	Bidrottningen och drönare	3
2.2	Arbetsbin och insamling av pollen	4
2.3	Svärmning	4
2.4	Skadedjur	5
2.5	Att ta hand om ett bisamhälle	5
3	Teori om systemet	6
3.1	Metoder och modeller för dataanalys	6
3.2	Mjukvara och hårdvara	13
4	Utveckling av systemet	13
4.1	Systemets utformning	13
4.2	Detektion av ljudavvikelser och klassificering av ljud	15
4.3	Pollendetektion	16
4.4	Detektering av avvikelser i bilddata	17
4.5	Myrdetektion	17
4.6	Svärmningsdetektion	18
4.7	Beräkning av bikupans hälsotillstånd	19
4.8	Presentation av systemfunktionerna	19
5	Resultat	19
5.1	Modeller för identifiering av avvikelser och klassificering av ljud	20
5.2	Pollendetektion	22
5.3	Modell för bildavvikelse	22
5.4	Modell för myrdetektion	22
5.5	Svärmningsdetektion	23
5.6	Bikupans hälsotillstånd	23
5.7	Användargränssnitt i OWL	23
6	Diskussion	25
6.1	Utvärdering av systemfunktioner	25
6.2	Samhälleliga och etiska aspekter	29
6.3	Utvecklingsmöjligheter	29
7	Slutsats	32
A	Intervju med yrkesbiodlaren Andrea Wallroth	I
B	Hårdvara	II
C	Beräkning av Mel-Frequency Cepstral Coefficients	IV

1 Inledning

Världens livsmedelsproduktion, jordbruk och bevarandet av den biologiska mångfalden är beroende av pollinering som sker med hjälp av insekter [1]. En av de viktigaste och mest effektiva pollinatörerna är bin, som idag hör till hotade arter på grund av bland annat klimatförändringar och urbanisering. Ett minskat antal bin hotar även oss människor genom sämre skördar och osäkerhet i livsmedelsförsörjningen [1]. Biodlare gör därför ett viktigt arbete genom att föda upp och ta hand om bisamhällen. Arbetet kan dock vara tidskrävande och innebära flera problem och utmaningar, men med modern teknik är det möjligt att förenkla arbetet för biodlarna. Genom att underlätta biodlingsprocessen och få bättre insyn i hur bisamhällen fungerar med hjälp av smarta bikupor, kan förutsättningarna för en bra livsmiljö i bikupan förbättras.

1.1 Bakgrund

Honungsbiet är en semi-domesticerad biart vars pollineringsjänster har ett stort värde för jordbruk, ekosystemtjänster och honungsproduktion [2]. Honungsbin klarar sig typiskt inte själva utan är beroende av biodlare, vars viktigaste uppgifter är att skörda honung och se över välmåendet i bisamhället [3]. Det finns ungefär 15 000 biodlare i Sverige idag som tar hand om cirka 120 000 bisamhällen [4]. En biodlare behöver bland annat se till att bisamhället inte lider av sjukdomar, att bikupan inte är för trång och vill i de flesta fall undvika en svärmning. En av de största utmaningarna är att övervaka bisamhällena tillräckligt ofta och noggrant, men samtidigt kunna göra detta på ett tidseffektivt sätt.

Arbetet vid övervakning sker oftast manuellt och vid kontroll behöver bikupan öppnas. Det innebär ett störningsmoment för bina, då till exempel kupans temperatur påverkas vilket i sin tur påverkar binas pågående processer i kupan. Genom att använda sensorteknik och insamling av data som kan analyseras, kan biodlarens arbete underlättas och störningsmomenten minska.

1.2 Syfte

Syftet med projektet är att använda bikupor utrustade med sensorer och automatisera biodlingsprocessen genom att med hjälp av artificiell intelligens (AI) analysera insamlad data. Den analyserade datan ska sedan presenteras med ett grafiskt användargränssnitt där biodlaren snabbt kan se tillståndet på sina bisamhällen och varnas om eventuella hot och avvikelser som upptäckts. Genom att kunna upptäcka och åtgärda hot i ett tidigt skede kan risken för att bisamhällen försvagas eller dör sänkas. [5]. Biodlingsprocessen blir också enklare då biodlaren kan undvika vissa delar av det manuella arbetet. En överblick över bisamhällets hälsa i realtid kan därför bidra både till att sänka tröskeln till att bli biodlare och till en bättre livsmiljö för bisamhällena.

Arbetet utförs i samarbete med Ericsson som tidigare utrustat bikupor med sensorer och genomfört analys av insamlad data. Projektet syftar till att vidareutveckla det arbete som tidigare gjorts med nya metoder och analyser, men även genom att implementera redan existerande modeller. Under projektet genomfördes avvikelседetektion i ljud- och bilddata, identifiering av pollen och myror samt analys av bikupans temperatur och vikt. Analysen presenteras sedan i ett grafiskt användargränssnitt som kan användas av biodlare.


1.3 Avgränsningar

De avgränsningar som gjorts gäller främst sensorerna, tillgänglig data och det grafiska användargränssnittet *Orchestration Widget Leader* (OWL). Projektet är avgränsat till de sensorer som finns i och på bikuporna. Alla sensorer har funnits sedan projektets start och inga nya sensorer har tillkommit. Inga experiment genomfördes, trots att det kan vara ett bra sätt för att ta fram data som är givande för skapandet av modeller. Detta på grund av bisamhällenas låga aktivitet under projektets gång och avrådan från personer med erfarenhet av biodling. I ett användarvänligt användargränssnitt för biodlare kan många olika värden, beräkningar och modeller vara värdefulla att ha med, men projektet har avgränsats till sex modeller samt implementation i OWL. Exempel på användbara funktioner som inte skapats eller implementerats är varroakvalsterdetektion och beräkning av antalet bin i kupan. När utvecklingsarbetet avslutas kan systemet inte köras oberoende utvecklarnas datorer och är alltså inte helt implementerat hos Ericsson. De tekniska avgränsningar har gjorts på grund av den begränsade tidsplanen, det utmanande utvecklingsarbetet samt den begränsade tillgången på användbar data.

2 Teori om bin och bisamhället

Det finns över 20 000 olika arter av bin, både domesticerade och vilda, där honungsbiet (*Apis mellifera*) är den art som föredras av biodlare för pollinering av grödor och honungsproduktion [6]. Honungsbiet är ett socialt djur som lever i organiserade samhällen där olika typer av bin fyller olika funktioner.

I ett bisamhälle finns det tre olika typer av bin, bidrottning, drönare och arbetarbin. Differentieringen sker vid befruktning och under biets utveckling, där drönare föds ur ett obefruktat ägg och drottningar och arbetarbin ur befruktade ägg. I figur 1 syns biets fyra utvecklingsfaser, ägg, larv, puppa och slutligen färdig insekt, en process som kallas fullständig metamorfos [8]. Ägget läggs i en hexagonalt formad vax-cell där det utvecklas till en larv som matas av arbetarbina. Till en början matas alla larver med en speciell näringslösning kallad drottninggelé och matas en hon-larv uteslutande med denna gelé utvecklas larven till en ny drottning. Efter att ha mångdubblat sin vikt som larv spinner den en puppa ur sitt sekret från munnen. I denna puppan utvecklas sedan alla kroppsdelar av biet. Efter 12–13 dagar är biet färdigutvecklat och kläcks ur sin puppa.



Figur 1: Illustrationen beskriver binas fyra utvecklingsstadium: ägg - larv - puppa - färdigt bi. Bilden är baserad på [7].

Jämfört med andra insekter har bin komplexa och utvecklade metoder för att kommunicera, både kemiskt med feromoner och fysiskt med danser. Nobelpriset i fysiologi eller medicin gick år 1973 till upptäckten av att bin använder sig av danser för att kommunicera riktning, storlek och kvalitet på en matkälla [9]. Bins avancerade koordination kan även observeras i hur de reglerar miljön i kupan där de styr både temperatur och luftfuktighet.

Bin både konstruerar kupan för optimal temperatur, som att täcka för hål som släpper ut för mycket värme samt genom aktiv reglering [10]. Om temperaturen utanför bikupan är tillräckligt låg samlas bisamhället i ett klot för att hålla värmen och bina roterar mellan mitten och kanten av klotet [11]. Om det istället är för varmt kyler de bikupan på liknande sätt som luftkonditionering kyler ett rum. Vissa bin ställer sig vid ingången och fläktar in kall luft med vingarna medan andra bin hämtar vatten som de fäster på insidan av bikupans väggar. Då vattnet avdunstar sjunker temperaturen, varvid den

varma fuktiga luften fläktas ut. På liknande sätt kontrollerar de luftfuktigheten, genom att fläktas in torr luft eller hämta in vatten i kupan.


En bra miljö inne i kupan är essentiell för ett hälsosamt bisamhälle. Temperaturen är speciellt viktig under bins utvecklingsstadier och behöver då ligga på en temperatur på 32–36°C. Är det för kallt eller varmt i kupans yngelkammare riskerar bina bli missbildade och dö. Luftfuktigheten i kupan behöver också regleras noggrant. Är luftfuktigheten för låg i kupan kan äggen torka ut och är det för fuktigt kan det växa mögel och bakterier [12]. Luftfuktigheten är också viktig för produktionen av honung då vatten drivs ur nektarn bina hämtar.

2.1 Bidrottningen och drönare

Drottningen är den enda fertila honan i ett bisamhälle och hon passas upp och skyddas av arbetsbina. En bidrottning har en genomsnittlig produktiv livslängd på två till tre år, men förväntas bli mellan tre till fem år gammal [13]. Drottningen parar sig en gång i sitt liv med flera drönare och sparar sedan säden i ett särskilt organ (*receptaculum seminis*), för att senare kunna befrukta de ägg hon lägger [14]. Hon kan lägga upp till 3000 ägg per dag under försommaren [13].

Om drottningen är gammal, sjuk eller oproduktiv leder detta till ett svagt samhälle, alltså ett samhälle som inte kan producera tillräckligt mycket honung för att biodlaren ska kunna skörda utan att riskera att svälta bisamhället. Om drottningen dör väljer arbetsbina ut ett befintligt befruktat ägg till att bli en ny drottning. Misslyckas arbetsbina med detta så kommer samhället att successivt minska i storlek då inga fertila bin finns för att kunna lägga ägg [14, 15]. En stor del av biodlarens uppmärksamhet är därför riktat åt bidrottningen, för att upprätthålla ett stabilt bisamhälle.


Bisamhällets hanbin kallas för drönare. Deras utseende skiljer sig från drottningens och arbetsbinas, de har till exempel stora ögon och stora vingar [16], vilket syns i figur 2. Deras huvuduppgift är att befrukta bidrottningar utanför bikupan för att sprida drottningens gener vidare. Drottningen börjar först lägga flera drönarägg när hon känner att samhället har tillräckligt med mat för att mata drönarna [17]. En stor andel drönare betyder därför att samhället är starkt och kan indikera en risk för svärmning.



Figur 2: De tre olika typerna av bin, arbetsbi, bidrottning och drönare. Bilden är baserad på [18].

2.2 Arbetsbin och insamling av pollen

De flesta bin i bisamhället är infertila honor och kallas arbetsbin [17]. De står för allt arbete både innanför och utanför kupan och dessa arbetsområden varierar beroende på deras ålder och årstid. En syssla som arbetsbina utför är insamling av nektar och pollen från blommor på olika växter. Bin lever av nektar och pollen, vilket gör detta till en viktig uppgift. Nektarns höga sockerinnehåll bidrar med energi till bina för att kunna flyga och utföra sina uppdrag, medan pollen är proteinrikt och samlas in som föda till larverna. Pollenkorn samlas in från blommor och förs ihop till pollenklumpar som sedan fästs i pälsen på magen och på bakbenen [20]. Detta visas i figur 3, där pollenklumpen på biets bakben är färgad orange.



Figur 3: Bi med orangefärgad pollenklump på bakbenet. Bilden är baserad på [19].

Pollen varierar i färg beroende på vilken blomsort bina besöker. Genom att undersöka färgen på det pollen som bina tar in och se till vilka blommor som blommar i det geografiska området, går det att få en god uppfattning om vilka växter de besöker. Det finns olika typer av honung vilka kan delas upp i kategorierna blandhonung och sorthonung. Sorthonung innebär att honungen är gjord till största del på en och samma blomsort och om man som biodlare vill åt denna typen av honung är det därför viktigt att skörda innan bina byter blomsort.

2.3 Svärmning

Svärmning är ett fenomen som uppstår hos bisamhällen som innebär att den befintliga drottningen flyger iväg med ungefär hälften av bina för att hitta en ny plats att bo på [21]. Ett bisamhälle fungerar som en individ och genom svärmning delas samhället till två. Detta är alltså binas naturliga sätt att sprida och föröka sig på. Det finns olika anledningar till att svärmning sker, till exempel att kupan är för trång, att samhället är väldigt starkt eller att drottningen börjar bli gammal [22].

Innan bisamhället är redo för svärmning och därmed byte av drottning, behöver bina ta fram en efterträdare. Den utlösande faktorn för svärmning är när drottningcellerna förpuppas, vilket sker cirka nio dagar efter uppfödningen [17]. Ytterligare en viktig faktor till svärmning är om det blir för trångt i bikupan och det inte får plats med mer nektar. Under tiden som bina väntar på att en ny drottning kläcks, och kupan samtidigt är trång, leder det till minskad insamling av nektar vilket i sin tur leder till att vikten stannar av eller minskar [23].

Svärmning är en oönskad företeelse eftersom biodlaren förlorar cirka hälften av sina bin om de inte fångas in igen. Det finns en stor risk att de bin som lämnar slår sig ner på oönskade eller svårtillgängliga platser och eftersom honungsbin normalt sätt inte överlever länge i naturen är risken stor att samhället dör. Därför är det av intresse att kunna identifiera risk för svärmning och när svärmning faktiskt sker för att om möjligt kunna förhindra den. Det är störst risk att bin svärmar på sommaren, under andra halvan av juni fram till augusti [22, 24]. Svärmning sker endast vid soligt väder vid en utomhustemperatur över 15 °C eftersom bin ogillar att flyga i temperaturer lägre än så [25]. Risken ökar om bina suttit inne i kupan under en lång tid på grund av kyla och regn.

Det finns olika sätt att förhindra eller minska risken för svärmning, det går till exempel att vingklippa drottningen och leta efter drottningceller, även kallade svärmceller. Genom manuell inspektion går det även att se till så att bina har tillräckligt med utrymme. Det bivanligaste alternativet är att undvika

vingklippning, men de manuella kontrollerna som behöver ske ungefär en gång i veckan är tidskrävande. Därför kan biodlare gynnas av att i förväg kunna få en varning om risken är extra stor för svärmning.

Genom att kombinera analysen av de faktorer som påverkar svärmning går det att ge en indikation i realtid över risken för svärmning. Om temperaturen legat runt 34 °C kan detta innebära att äggläggning sker i kupan. Ligger även vikten på ett relativt konstant värde under några dagar och det är klart väder kan detta innebära att bina väntar på att drottningcellerna förpuppas. Dessa är alla riskfaktorer och analys av vikt-, temperatur- och väderdata kan alltså tillsammans avgöra risken för svärmning.

2.4 Skadedjur

Under de olika säsongerna på året kan biodlare stöta på utmaningar med olika djur och insekter som stör bisamhället eller rentav kan vara orsaken till att bisamhället dör ut [26]. De geografiska förhållandena har inverkan på vilka skadedjur och insekter biodlare kan stöta på, som till exempel björnar, getingar, fåglar, möss och olika arter av myror. Det finns ingen universallösning på problemet och de specifika lösningarna varierar från fall till fall. Detektering av avvikelser vid ett tidigt skede är således en förutsättning för att rätt bekämpningsmetod ska kunna appliceras innan skadan är skedd.

Angrepp från stackmyror är vanligt förekommande i Sverige. I en intervju med yrkesbiodlaren Andrea Wallroth (se appendix A), framkom det att stackmyror är mycket farliga och kan döda ett bisamhälle inom ett par dygn. Andrea förklarade i intervjun att hennes bisamhällen råkar ut för minst en myrinvasion per säsong och att dessa incidenter måste upptäckas inom första 24–48 timmarna, för att rädda bisamhället. Ett fåtal myror nära bikupan är vanligt och indikerar inte ett myrangrepp, när myrorna angriper en bikupa gör de det istället i ett stort antal. För att enklare skydda bisamhällen kan både hobby- och yrkesbiodlare dra nytta av att implementera AI-driven bildanalys för att övervaka bikupor. AI-teknologin kan i ett tidigt stadie upptäcka infektioner, rovdjursattacker och myrinvasioner i realtid, för att sedan snabbt meddela biodlaren.

2.5 Att ta hand om ett bisamhälle

Att vara biodlare innebär att man tar hand om ett eller flera bisamhällen. Under vinterhalvåret håller bina sig inne i kupan där de sitter tätt ihop likt en boll för att hålla värmen, vilket innebär mindre arbete för biodlaren. När bina börjar bli aktiva igen under våren behöver biodlaren se till att bina mår bra genom att undersöka kupan. Under en sådan undersökning säkerställer biodlaren att det finns en äggläggande drottning och undersöker om det finns några sjukdomar som behöver behandlas. Om mängden mat visar sig vara mycket låg, kan bina behöva stödfoder i form av sockerlösning för att klara sig de första veckorna. Under sommarmånaderna kontrolleras sedan bikupan ungefär varje vecka av biodlaren för att se till att bisamhället håller sig starkt, och samtidigt förebygga risk för svärmning. När sommaren sedan leder mot sitt slut ska biodlaren invintra bisamhället, vilket innebär att förbereda samhället för vintern genom att skörda honungen för sista gången och ge bina sockerlösning som foder [27]. Detta gör biodlaren för att ge samhället så bra förutsättningar som möjligt att överleva den kalla vintern.

Bin behöver någonstans att bo där biodlaren enkelt kan kontrollera deras välmående, och därför används idag färdigbyggda bikupor som enkelt kan öppnas för inspektion. De byggda bikuporna kan variera kraftigt i utseende och stil men består alla av samma huvudkomponenter som uppfyller samma funktion [17]. Den vanligaste kupan och den som använts i projektet är uppstaplingskupan, som oftast består av en eller två så kallade yngellådor staplade på varandra. I dessa lådor finns det ramar med

sexkantigt cellmönster för att förenkla vaxbyggandet för bina. Vaxkakorna som bina bygger i yngellådorna finns till för att förvara honungen och för drottningen att lägga ägg i. I den understa lådan sitter flustret, vilket är en öppning med ett landningsbräde där bina kan flyga in och ut ur kupan. För att få honung ur sin biodling läggs en så kallad skattlåda på de andra två lådorna oftast med ett galler emellan som förhindrar drottningen från att ta sig dit. Därmed kan det inte läggas ägg i ramarna som finns i skattlådan och de kommer bara fyllas med honung. Denna låda sätts på bikupan först när bisamhället börja växa sig starkt på våren för att sedan skördas och tas bort när bina ska invintra.

En viktig del av biodlarens arbete är honungsproduktionen. Målet är ofta att få ut så mycket honung som möjligt och processen blir olika avancerad beroende på om biodlaren vill producera sorthonung eller blandhonung. För att veta vilken sorts nektar bina tar in i kupan under olika perioder kan därför identifiering av pollenfärg vara mycket hjälpsamt. Det är intressant för en biodlare att veta, både vid tillverkning av sorthonung och för att kunna jämföra flödet mellan olika kupor eller förändring av flödet över tid.

3 Teori om systemet

I detta avsnitt presenteras teori om systemet där metoder och modeller som kan användas för att genomföra automatisering och dataanalys på sensordata samt hårdvara och mjukvara beskrivs.

3.1 Metoder och modeller för dataanalys

3.1.1 Behandling av ljuddata

För att analysera ljudfiler digitalt behöver de konverteras till ett passande format och anpassas till den analys som ska göras. En ljudsignal är en kontinuerlig vågform som representerar lufttrycksvariationerna över tid orsakade av ljudvågor [28]. För att digitalisera denna signal måste den samplas med en viss hastighet, samplingshastigheten. Den representerar antalet samplingar (d.v.s. numeriska värden) som tas per sekund för att representera ljudsignalen. Ljuddata lagras vanligtvis i ljudfilen som en serie binära nummer som representerar amplituden för ljudsignalen vid en viss tidpunkt [29].

Ljud kan analyseras på många olika sätt men kan delas upp i två övergripande metodiker. Antingen görs realtidsanalys då den samplade amplituden analyseras över tid. Alternativt kan de frekvenser som utgör ljudsignalen analyseras. Då ljud är en vågform är frekvensanalysen ofta mer informativ om ljudsignalens karaktäristik än realtidsanalys. För att erhålla frekvenserna fouriertransformeras ljudsignalen enligt

$$Amp(\omega) = \frac{1}{\sqrt{2\pi}} \int_0^\infty Amp(t)e^{-it\omega} dt \quad [30].$$


För att anpassa analysen för maskininlärning behövs vissa bakomliggande egenskaper av maskininlärning tas i åtanke. Maskininlärning bygger på statistiska modeller som ger prediktioner baserat på diskret numerisk data [31]. Det är därför önskvärt att göra en analys som är numerisk och beskriver ljudfilens karaktäristik på ett urskiljbart sätt.

En vanlig analysmetodik för ljudigenkänning är *Mel-frequency cepstral coefficients* (MFCC) som tillsammans utgör ett *Mel-frequency cepstral* (MFC) [32]. Detta verktyg används i stor utsträckning inom igenkänning av mänskligt tal, men kan också appliceras på många djurarter [33]. Matematiskt förenklat

fås ett MFCC av att först fourier transformera ljudsignalen, sedan skala om signalen till mel-skalan, vilken är en representation av hur hörfrekvent en människa upplever ett ljud, därefter logaritmeras signalen och diskret-fouriertransformeras som ger MFC-koefficienterna. Slutsignalen blir alltså diskreta MFC-koefficienterna som beskriver ett "spektrum av spektrumet" anpassat till hur människor upplever ljud. Dessa koefficienter kan sedan användas som ingående variabler till maskininlärningsmodeller. För en mer ingående teori om beräkningen av MFCC, se appendix C.

3.1.2 Behandling av bilddata

Bildanalys utförs genom att analysera varje enskild pixel för sig. För att digitalisera en bild konverteras dess pixlar till numeriska värden i en matris, där varje rad representerar ett pixelvärde och varje kolumn representerar en färg ur färgmodellen RGB (röd, grön och blå). Detta illustreras i figur 4.



Figur 4: Illustration av fyra pixlar med lika värden för röd och grön, men variation i blå för RGB färgmodellen och dess motsvarande matris.

Varje värde i RGB-modellen representeras med ett 8-bitars nummer som varierar mellan 0 och 2^8 , som ger ett maxvärde 255, således representeras varje pixel av 24-bitar (3-byte). Konverteringen av pixelvärden till numeriska värden möjliggör matematiska operationer som normalisering, vilket resulterar i AI-modeller med högre prestanda. Normaliseringen sker genom att dela pixelvärdet på maxvärdet 255, vilket ger ett värde mellan 0–1. Detta resulterar i utveckling av stabilare AI-modeller [34, 35].

Om nödvändig bilddata för modellering saknas finns möjligheten att skapa ett anpassat dataset för träning och validering för AI-modeller. Datan kan skapas på två olika sätt, första metoden bygger på att förse ett program med exempelbilder, som det sedan använder för att autogenerera modifikationer. Den andra metoden kräver användning av ett fotoredigeringsprogram, för att redigera varje bild med olika typer av modifikationer såsom brus, ljuseffekter och rotation, för att skapa ett brett och varierande dataset.

3.1.3 Väglett och icke-väglett lärande inom maskininläring

Ett snabbt växande område inom dataanalys är modeller som använder sig av AI. Sådana modeller förknippas med mänskliga kognitiva funktioner, som att tolka tal och identifiera mönster [36]. En gren inom AI är maskininläring, där algoritmer använder statistiska tekniker för att tränas till att kunna dra slutsatser om data.


Inom maskininläring kan modeller delas upp i två huvudområden, väglett lärande (eng. *supervised learning*) och icke-väglett lärande (eng. *unsupervised learning*) [37]. Inom väglett lärande har all indata tillhörande annoterad utdata, som fungerar som ett facit. Syftet är att förutspå utdata genom att använda indata som modellen inte tränats på och utvärdera hur väl den lyckas. Annoterad data innebär att datan är märkt med en klass eller information som kan användas till dataanalys. Inom icke-väglett

lärande är däremot ingen utdata annoterad och modellen behöver därför lära sig underliggande mönster endast via indatan.

Ett tredje område är semi-väglett lärande (eng. *semi-supervised learning*) där en ofta liten del av den tillgängliga datan är annoterad och som innebär att metoderna ovan kombineras. Målet är att kunna annotera med hjälp av modellen, och därmed minimera annoterings-arbetet, vilket ger möjligheter att få bättre användning för stora dataset där endast en liten del är annoterad. Inom väglett lärande är ett vanligt tillvägagångssätt att dela upp datasetet i tränings-, validerings- och testdata för att först kunna träna modellen och sedan validera och testa hur väl modellen fungerar genom att använda data som inte setts av modellen tidigare. Inom icke-väglett lärande får modellen istället dra slutsatser på osedd data.

3.1.4 K-nearest neighbors

K-nearest neighbors (KNN) är en maskininlärningsalgoritm som kan användas för att klassificera data [38]. Modellen går ut på att i ett vektorrum jämföra en datapunkt med dess K närmsta grannar, under förutsättning att K är ett heltal som väljs när man skapar modellen. En datapunkts attribut beskrivs av en numerisk vektor och har en tillhörande klass. Modellen tränas sedan genom att ha ett annoterat dataset som referenssystem. En geometrisk tolkning av systemet är att en datapunkt med okänd klass placeras i vektorrummet med referenssystemet, som kan ses i figur 5. Datapunkten jämförs med de K närmsta punkterna i rummet. Datapunkten erhåller sedan den klass som flest av de K punkterna har. Då modellen bygger på avstånden mellan punkter i det flerdimensionella rummet kan det erhållas ett bättre resultat med att normera referensdatan utifrån dess vektoraxlar. En dimension med låg spridning skulle annars premieras över en dimension med högre spridning eftersom punkter med låg spridning generellt sett hamnar närmare varandra. Normeringen förhindrar därmed denna typ av bias vid klassificering.




Figur 5: Illustration över hur algoritmen *K-Nearest Neighbors* med $K = 5$ klassar en okänd 2-dimensionell datapunkt som dess fem närmsta grannar. Då de flesta av de 5 grannarna är av klassen A, så erhåller den okända punkten samma klass.

3.1.5 Isolation Forest

Detektion av avvikelse (eng. *Anomaly detection*), är ett område inom icke-väglett lärande där målet är att utifrån mönster som identifierats i data hitta avvikelser från dessa mönster [39]. Algoritmen *Isolation Forest* är en populär maskininlärningsalgoritm som använder sig av beslutsträd [40].

Algoritmen fungerar på så sätt att när en datauppsättning ges, väljs ett slumpmässigt urval av datan ut och tilldelas ett binärt träd [40]. Förgrening av trädet börjar med att först välja ett slumpmässigt attribut av flera. Sedan fortsätter en rekursiv process där trädet förgrenas vid ett slumpmässigt tröskelvärde, vilket värde som helst inom intervallet för det minsta och maximala värdena för det valda attributet. Om värdet på en datapunkt är mindre än det valda tröskelvärdet fortsätter sökningen till vänster gren, och om större till höger. Därmed är en nod uppdelad i grenar till vänster och höger. Denna process fortsätter tills varje datapunkt är helt isolerad eller tills maximalt djup nås. Dessa steg upprepas för att skapa flera träd, vilket ger en ensemble av träd (eng. *isolation forest*) och då är träningen av modellen klar. För att därefter avgöra om en datapunkt är avvikande går den igenom alla träd i ensemblen och får ett värde för hur avvikande datapunkten är, baserat på djupet på trädet som krävs för att komma fram till den punkten. Denna poäng är en sammanställning av djupet som erhålls från vart och ett av träden, och baserat på en gräns för hur hög poäng som krävs för datapunkten att bli en avvikelse, bestäms avvikelserna och tilldelas värdet -1. En illustration över hur algoritmen *Isolation Forest* syns i figur 6.




Figur 6: Illustration över hur algoritmen *Isolation Forest* använder flera träd för att skapa en skog. Bilden är baserad på [41].

Två parametrar som används i modellen är särskilt viktiga. De är $n_estimators$ som anger antal beslutsträd som används till träd-ensemblen och *contamination*, som anger hur hög procentandel av datasetet som det är önskvärt att avvikelserna utgör. Dessa parametrar kan justeras för att göra algoritmen mer eller mindre känslig. För att få ett färre antal avvikelser i förhållande till antal datapunkter kan till exempel värdena på dessa parametrar sänkas [42].

3.1.6 Convolutional neural network

Convolutional neural network (CNN) är en typ av neuralt nätverk som analyserar bilddata genom att bearbeta det i ett rutnät [43]. Data passerar genom flera lager, som var och ett bearbetar pixeldata med hjälp av filter. Nätverket använder filter som mallar för att upptäcka former och mönster i bilden. Dessa filter körs sedan över en liten del av rutnätet åt gången och jämförs med pixlarna i det området. De flyttas sedan till nästa del av rutnätet, där processen upprepas tills den har analyserat samtliga pixlar. Varje lager i CNN-algoritmen blir gradvis mer komplex i sin analys, vilket gör att det kan upptäcka allt mer abstrakta mönster och objekt, se figur 7.

CNN-algoritmen används i huvudsak på två olika sätt beroende på ändamålet. Första metoden är *singel-shot* algoritmen som används i modeller med prioritering på snabbhet och den andra modellen är *two-shot* algoritmen som används i modeller med fokus på precision. *Singel-shot* innebär att modellen detekterar ett objekt med endast en passering genom dess neurala nätverk, medan det passerar två gånger i en *two-shot*-algoritm. Första passeringen framställer ett antal förslag på möjliga placeringar av objekten och den andra passeringen förbättrar förslagen samt ger slutgiltiga prediktioner. Modellen ger dessa prediktioner som innehåller koordinater, klass, namn och sannolikhetsvärde som anger vilken sannolikhet det är att objektet finns på den platsen. Valet mellan algoritmerna beror på modellens ändamål, en *singel-shot*-algoritm är bäst lämpad för detektering i realtid medan en *two-shot*-algoritm passar bättre för modeller som kräver högre precision.




Figur 7: En översiktlig illustration av CNN processen. Pixelvärden av den inmatade bilden passerar konvolutionella lager, sedan en ReLU-funktion och slutligen ett pooling lager som skickas in i ett helt sammankopplat lager. Bilden är baserad på [43].

3.1.7 You Only Look Once

Analys av bilder med maskininlärningsmodeller är ett stort område inom AI [44]. Förmågan att detektera objekt, finna mönster och analysera bilder används idag inom ett flertal applikationer. *You Only Look Once* (YOLO) är en objekt-detekterings-modell. Den använder väglett lärande och *singel-shot* algoritmen, vilket ger snabba prediktioner i realtid. Genom att använda ett neuralt nätverk som använder sig av *end-to-end*, vilket innebär att modellen tar emot rådata och ger en direkt prediktion, ger modellen både prediktioner och klass sannolikhet samtidigt. Till skillnad från andra algoritmer utför YOLO dess uppgifter med ett helt sammankopplat lager, alltså under en iteration. Andra alternativ som *Faster R-CNN*-algoritmen använder först *Region Proposal Network*, som är en neural nätverksmodul som föreslår möjliga placeringar av objekt på bilden, för att sedan utföra igenkänning på varje

område. Således kräver modellerna som använder *Region Proposal Network* ett flertal iterationer på varje bild, medan YOLO endast behöver en iteration.

YOLO-modellen använder ett CNN-nätverk med 24 konvolutionella lager [45], se figur 8. De första 20 lagren är tränade i förväg på ImageNet som är ett stort annoterat dataset skapat i syfte att användas vid forskning. Denna träningen lär YOLO grundläggande egenskaper, såsom färger, kanter och textur. Resterande fyra konvolutionella lager tränas på avsedd annoterad data, där sista lagret ger det detekterade objektets koordinater samt klassens sannolikhet.



Figur 8: I figuren visualiseras YOLO-arkitekturen, med dess konvolutionella lager och dess upplösningens dimensioner. Bilden är baserad på [45].

YOLO-modellen måste förses med data som innehåller objektet som ska detekteras, varje bild i datasetet måste vara väl annoterat och ha inritade boxar som rutar in de avsedda objekten i varje bild [44]. Modellen tränas exempelvis på ungefär 75 % av datasetet, sedan valideras den efter varje epok av träning på 12,5 % och slutligen testas slutresultatet efter träningen på resterande 12,5 % data. Den framställda modellen kan sedan användas självständigt på ny data.

3.1.8 Utvärdering av maskininlärningsmodeller

Två vanliga sätt att värdera vägledda maskininlärningsmodellers prestation är genom att använda F1-värde och *confusion matrix* [46]. F1-värdet är ett harmoniskt medelvärde av en modells F1-känslighet (eng. *recall*) och F1-precision (eng. *precision*). För modeller med två klasser benämns en som positiv och den andra som negativ. Sedan beräknas F1-känslighet och F1-precision genom att se till hur många sanna negativa, falska negativa, sanna positiva och falska positiva klasser som finns. Dessa förkortas TN, FN, TP och FP respektive, vilket kommer från de motsvarande engelska uttrycken *true*, *false*, *positive*, *negative*. Sanna innebär att en positiv klass klassats som positiv eller negativ som negativ. Falsk innebär felklassificering, det vill säga att en positiv klass klassats som negativ eller tvärtom. F1-känslighet beräknar hur stor del av de positivt klassade datapunkterna som modellen faktiskt klassat som positiva enligt ekvation 1. F1-precision beräknar hur stor del av de positivt klassade datapunkterna som faktiskt är positiva enligt ekvation 2.

$$\text{F1-känslighet} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (1)$$

$$\text{F1-precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (2)$$

F1-värdet beräknas sedan med hjälp av dessa två enligt

$$\text{F1-värde} = \frac{\text{F1-precision} \cdot \text{F1-känslighet}}{\text{F1-precision} + \text{F1-känslighet}}$$

Vid användning av flera klasser beräknas inte ett totalt F1-värde, utan istället beräknas F1-värdet per klass med hjälp av F1-precision och F1-känslighet per klass [47] enligt

$$\begin{aligned}\text{F1-precision (klass = x)} &= \frac{\text{TP(klass = x)}}{\text{TP(klass = x)} + \text{FP(klass = x)}} \\ \text{F1-känslighet (klass = x)} &= \frac{\text{TP(klass = x)}}{\text{TP(klass = x)} + \text{FN(klass = x)}} \\ \Rightarrow \text{F1-värde (klass = x)} &= \frac{\text{F1-precision(klass = x)} \cdot \text{F1-känslighet(klass = x)}}{\text{F1-precision(klass = x)} + \text{F1-känslighet(klass = x)}}\end{aligned}$$

där x representerar varje klass. F1-värdet ligger mellan 0 och 1 och målet är att värdet skall ligga så nära ett som möjligt, vilket indikerar att modellen presterar väl.

En *confusion matrix* visar hur noggrant en modell har klassat, i form av en matris där varje klassificering som modellen gjort jämförs den faktiska klassen. Kolumnerna i matrisen motsvarar de faktiska klasserna medan raderna motsvarar hur modellen har klassat datapunkter från en viss klass. I tabell 1 syns ett exempel med totalt 42 datapunkter som klassats till klasserna a, b eller c och hur en *confusion matrix* kan se ut om rätt klassificering har gjorts 10, 7 och 14 gånger för respektive klass och fel-klassificering gjorts totalt 4, 6 och 0 gånger för respektive klass. Om all data har klassats korrekt kommer endast rutorna i diagonalen ha ett värde skilt från 0.

Tabell 1: Exempel över hur en *confusion matrix* kan se ut för tre klasser.

		Klassificerad som		
		Klass 1	Klass 2	Klass 3
Faktisk klass	Klass 1	10	3	1
	Klass 2	2	7	4
	Klass 3	0	0	14

3.1.9 Expertsystem

Ett expertsystem inom AI är en modell som använder en samling av villkor för att lösa problem inom ett specifikt område [48]. Dessa regler är baserade på kunskap och erfarenhet från experter inom området. För att använda systemet matar användaren in relevanta data och systemet söker sedan i kunskapsbasen efter regler som matchar dessa data. Om en matchning hittas, tillämpas regeln och genererar en slutsats eller rekommendation. Förenklat kan ett expertsystem appliceras på problem där ett antal frågor kan besvaras, och utifrån svaren kan systemet gå vidare till nya frågor och till slut ge ett resultat. Fördelen med expertsystem är att de är enklare att förstå än många andra modeller inom AI.

3.2 Mjukvara och hårdvara

3.2.1 Webbapplikationen OWL

OWL är en webbapplikation där grafiska användargränssnitt kan skapas. Utvecklingsmiljön i OWL tillåter utvecklaren att ha en instrumentpanel med ett valfritt antal komponenter där information kan visualiseras. Dessa komponenter skapas utifrån färdiggjorda mallar, exempelvis olika slags grafer eller tabeller. Utöver de färdiggjorda mallarna finns det även möjligheten att skapa en komponent med enbart programspråken HTML och Javascript för att kunna utforma komponenten och dess innehåll fritt ifrån grunden. Komponenterna kan sedan läsa in och presentera data från en databas eller skriva data till databasen, genom att kopplas till ett automatiserat system som agerar som back-end. Systemet styrs av kod som är skriven i Javascript och bestämmer vilken data som sedan ska visas i komponenterna.

3.2.2 Hårdvara

Systemet använder ett flertal sensorer som är monterade i och på bikupan. Dessa är kamera, lastcell (våg), mikrofon, termometer och lufttrycksmätare och var monterade innan projektet började. Mer detaljerad teori om sensorerna hittas i appendix B, och hur de är monterade och används i projektet hittas i avsnitt 4.1.


4 Utveckling av systemet

Följande avsnitt beskriver hur systemet av sensorer, dataflöde, analysprogram och presentation är utformat. Vidare beskrivs även hur de olika modellerna skapades och hur de fungerar. Modellerna, som tillsammans utgör översikten över bikupan, beskrivs var för sig samt hur de tillsammans presenteras i en webbaserad applikation.

4.1 Systemets utformning

Bikuporna i projektet är utrustade för att samla data från bild, ljud, temperatur, luftfuktighet, lufttryck och vikt. En ritning över kuporna och var sensorerna är placerade illustreras i figur 9. Den inkommande datan hanteras först av en mikrodator på kupan, där data som tar mycket bredband att skicka, såsom bild och ljud, sparas lokalt medan resterande data skickas i realtid till en av Ericssons servrar, där det lagras i molnet.

Bilddatan från bikuporna samlas med en digitalkamera placerad utanför kupan riktad mot dess ingång [49]. Under projekts gång användes två olika sorters mikrofoner, som spelar in 10 sekunder långa ljudfiler. Initalt användes enklare monomikrofoner och under projektets gång byttes vissa ut till stereomikrofoner med bättre ljudupptagning. Stereomikrofonerna består av två mikrofoner placerade med visst mellanrum. Detta gör så att ljudupptagningen blir mer redundant och tillåter teoretiskt att filtrera bort brus samt beräkna riktningen av ljudet.




Figur 9: Schematisk bild över uppställningen av bikupan och de monterade sensorerna.

Varje bikupa har åtta stycken digitala termometrar, sex i kupan och två utanför. Termometrarna är placerade i de två understa lådorna, tre per våning från höger till vänster. Detta för att kunna få en uppfattning av temperaturfördelningen i kupan. Luftfuktigheten mäts i kuporna av luftfuktighets-sensorer med en sensor som referens placerad utanför vardera kupa. Även lufttrycket mäts med sensor i kuporna. Bikupans vikt mäts av fyra stycken sammankopplade lastceller placerade under kupan. Lastcellerna är först kopplade till en ADC-krets som gör en analog signal digital, därefter till en mikrodator (Raspberry Pi). Alla sensorer bygger på konceptet att i elektroniska komponenter använda material vars egenskaper är beroende av en eller flera yttre faktorer. Data, som till exempel temperatur, kan sedan härledas ur hur komponenten påverkar spänningen i dess krets. För mer djupgående teori om fysiken bakom sensorerna, se appendix B.

Mikrodatorn som styr hela datainsamlingen kör ett operativsystem byggt på linux [50]. En mikrodator har alla komponenter som förväntas på en vanlig dator och kan utföra samma processer. Skillnaden är att de är mycket mindre till storleken och har mindre beräkningskraft och minne. För mindre beräkningskrävande program, som att samla in data eller enklare analys klarar en mikrodator det väl.

Dataflödet som summerar systemets utformning visas i figur 10. Sensorerna är kopplade till ett modem som hanterar inflödet av data, och modemmet är i sig kopplat till mikrodatorn som både styr när sensorerna ska samla in data och själva lagringen. På mikrodatorn initieras och kalibreras även sensorerna för att sedan läsa in sensordatan var tionde minut. För att koppla upp sig till Ericssons server använder sig datorn av ett API som skickar data över internet. Datan i databasen används sedan för att beräkna riskindikatorn för svärmning, samt bikupans tillstånd och slutligen visas resultatet i instrumentpanelen på OWL.



Figur 10: Schematisk bild över systemets utformning och dataflöde. Sensordatan skickas till mikrodatorn och bearbetas innan den skickas vidare till databasen i OWL. Modellen för bildavvikelse, myrddetektion samt pollendetektion körs på en lokal dator och resultatet skickas sedan till databasen i OWL. Slutligen visas datan på komponenterna i instrumentpanelen.


4.2 Detektion av ljudavvikelser och klassificering av ljud

Ljudanalysmodellerna skapades med maskininlärning baserat på historisk data från Ericssons kupor. Ljudfilerna erhöles av Ericsson via minneskort och konverterades till numeriska amplitudvektorer genom att samplas. Vidare extraherades ljudfilernas attribut genom att beräkna 20 MFC-koefficienter.

Syftet med att kunna detektera avvikelser i ljuddata är att snabbt kunna informera biodlaren om ovanliga händelser i kupan som kan detekteras via ljud. Exempel på sådana är svärmning, ökad aktivitet under vintertid, angrepp från stora djur eller att delar av kupan till exempel blåser bort. För att skapa en modell som kan detektera ljudavvikelser i bikupan användes en *Isolation Forest*-modell från inbyggda funktioner i Python-biblioteket *scikit-learn*. Eftersom modellen bygger på icke-väglett lärande tränades den på nytt för varje set av ljudfiler för att hitta eventuella avvikelser bland dem. Parametrarna som modellen använder sig av justerades för att få ett lagom antal avvikelser.

Flera tester gjordes genom att skicka in olika set av filer från bikuporna till modellen, för att undersöka hur många och vilka filer modellen detekterar som avvikande i olika uppsättningar av filer. Utvärdering av hur väl modellen fungerade gjordes genom att lyssna på några av de filer som modellen detekterats som avvikelser och jämföra dem med normala filer. Under genomlysning gjordes en subjektiv bedömning på vad som ansågs vara normalt surrande ljud från bin samt avvikande ljud. På grund av tidskrävande arbete genomfördes inte kontroll av alla filer. Speciellt gjordes tester med dataset innehållande fyra ljudfiler som var känt avvikande, för att se hur väl modellen klarade av att hitta dem. En av dessa filer var från ett experiment som genomfördes sommaren 2022 där bidrottningen plockades bort en kortare stund för att få ljudinspelningar som fångar hur ett uppjagat bisamhälle låter. De andra innehåller vind, regn och ett sprakande ljud som alla är tydligt avvikande mot binas surrande ljud som vanligen förekommer i filerna. Noteringar för dessa filerna gjordes för att kunna urskilja dem i resultatet.

Klassificeringens syfte är främst för att få ett effektivare datahanteringssystem för framtida analys. Vid annotering av historisk ljuddata identifierades de distinkta klasserna “bin”, “vind”, “fåglar” och “övrigt” som inkluderade ljud som avvek från de andra klasserna. Den annoterade datan delades upp i tre dataset för träning, validering och testning. För att bygga KNN-modellen användes Python-klassen *KNeighborsClassifier* som är en del av biblioteket *scikit-learn*. Modellen tränades på träningssetet och den ingående parametern K optimerades genom att testa vilken modell som gav bäst klassificering av valideringssetet. För att visualisera KNN-datan användes metoder i biblioteket *scikit-learn* för dimensionsreduktion och principalkomponentanalys. Metoderna reducerar den 20-dimensionella datan till två dimensioner och kombinerar de dimensioner som maximerar variansen i datan. Precisionen av modellen utvärderades sedan mot testsetet för att få fram modellens *confusion matrix* samt F1-känslighet, F1-precision och F1-värde.



Figur 11: Illustration över hur modellerna för ljudanalys är implementerade på en Raspberry Pi. Mikrodatortorn sparar det inspelade ljudet från mikrofonen i en ljudfil. Ljudavvikelsemodellen avgör sedan om ljudfilen avviker eller inte. Skulle ljudfilen klassificeras som avvikande skickas filnamnet och klassen på avvikelser till användargränssnittet. Avslutningsvis placerar klassificeringsmodellen ljudfilen i den korresponderande mappen.

Både KNN-modellen och avvikelse-modellen implementerades sedan i ett gemensamt program på mikrodatortorn, se schematisk bild i figur 11. Programmet hämtar initialt den inspelade filen och jämför den med de 50 senaste inspelade ljudfilerna, och ger ett värde om filen är en avvikelse eller inte. Oavsett om filen blir en avvikelse eller inte läggs den sedan till de 50 senaste filerna, och den äldsta filen kastas. Detta görs för att modellen ska anpassa sig efter förändringar i ljud som kan ske på grund av årstidsskiftning och väder. Sedan klassificerar programmet samma fil med KNN-modellen och ger den en tillhörande klass. Ifall filen har detekterats som en avvikelse skickas denna informationen till databasen i OWL-miljön och filen sparas ned i en egen mapp. Om filen inte identifieras som en avvikelse sparas den ned i en mapp för dess tillhörande klass, för att kunna användas för framtida ljudanalyser.

4.3 Pollendetektion

Modellen som används för pollendetektion är en implementation av en redan existerande bildigenkänningsmodell, tillgänglig via Ericsson. Syftet med att implementera modellen är att integrera den för att den ska kunna köras i realtid och göras tillgänglig i det grafiska användargränssnittet. Vilken typ av pollen som tas in i bikupan påverkar hur honungen blir, vilket är speciellt av intresse för en biodlare som vill producera sorthonung. Implementeringen syftar också till att experimentera med en existerande modell för att undersöka hur den kan vara hjälpsam i detta projekt.

I modellen används YOLO för att först detektera arbetsbin som bär på pollen, därefter vilken typ av pollen bina bär. Modellen tränades på ett annoterat dataset som består av 714 bilder från Ericssons bikupor och den kan identifiera tre pollenfärger; röd, orange och gul. Modellen tränades på runt 90 % av datasetet och testades med hjälp av resterande 10 %. Modellen var skapad sedan tidigare men träningen och testningen gjordes om under projektet.

För att kunna implementera modellen och integrera den med användargränssnittet i OWL etablerades kommunikation mellan OWL och modellen. När modellen körs laddas alla bilder som finns lagrade lokalt. Därefter kontrolleras bilderna för att undvika att ladda upp duplicerade resultat. När bilderna

har analyserats laddas resultaten upp i OWL. Slutligen finslipas resultaten och visualiseras med grafer för att presenteras på ett tydligt sätt.

4.4 Detektering av avvikelser i bilddata

För att öka förståelsen och användbarheten för arbetet med att automatisera biodlingsprocessen genomfördes en intervju med en yrkesbiodlare, Andrea Wallroth. I intervjun förklarade hon att svenska biodlare stöter på många olika problem, som bland annat fåglar som äter bina, möss som gömmer sig i bikupan under vintern och stackmyror som attackerar bisamhället för att nå honungen. Hon förklarade att biodlarna ständigt måste kontrollera bikuporna för att inte riskera att de dör, se appendix A. Från intervjun kom idén till att lösa en del av dessa svårigheter med övervakningsprogram. Problemen kan identifieras tidigt med ett bildigenkänningsprogram, som ger biodlarna möjligheten att upptäcka potentiella faror i god tid. Genom att analysera den insamlade bilddatan i realtid kan avvikelser i binas miljö upptäckas snabbt.

För att skapa ett AI-program för detta ändamål, skapades en modell som utför bildanalys och objektidentifiering för att identifiera eventuella avvikelser från mönster som observerats i föregående bilder. Modellen tränades på en uppsättning bilder för att lära sig mönster, och testades sedan med en bild som jämfördes mot dessa mönster. Antalet bilder som modellen tränas mot är en parameter som kan ändras, men sattes under utvecklingen till 50 bilder. Utmatningen från modellen gav sedan andelen avvikelse utifrån resultatet av modellens träning. Detta tillvägagångssätt gör det möjligt för biodlare att upptäcka potentiella faror i tid och vidta nödvändiga åtgärder för att skydda sina bin.

Modellen är baserad på *Isolation Forest*-algoritmen. För att utföra en effektiv och snabb analys delades modellträningen och datakontrollen upp, och två filer skapades. För att implementera algoritmerna användes Python-biblioteken *scikit-learn* och *joblib*.

I den första filen hämtas de senaste 50 bilderna från Ericssons databas och konverteras till vektorer med hjälp av *NumPy*-paketet. Därefter tränas en *Isolation Forest*-modell, skapad från *scikit-learn*, på vektorerna och sparas sedan med *joblib* för senare användning. I den andra filen laddas den tränade modellen med *joblib*. Den senaste bilden laddas ner från OWL, konverteras till numeriska värden och testas med modellen. Utmatningen av programmet blir sedan den procentuella avvikelsen för bilden. Om avvikelsen överstiger ett förutbestämt gränsvärde skickas ett meddelande till biodlaren via OWL om den upptäckta avvikelsen, tillsammans med motsvarande bild. Detekteras inte någon avvikelse meddelas det via OWL och bilden sparas i träningsmappen.

Eftersom avvikande incidenter inte är insamlade, utvärderades modellen genom att tränas på en period då bina var i vila och inte vistades ute, sedan testades den på en bild då bina var aktiva utanför bikupan. Modellen kunde sedan utvärderas genom att kontrollera om bina detekteras som avvikelser.

4.5 Myrdetektion

För att förhindra potentiella myrinvasioner i bikupor utvecklades ett AI-program för att varna biodlare om risken för angrepp. Stackmyror finns ofta runt bikupor, men deras närvaro tyder inte alltid på en invasion. Vid en attack krävs snabba åtgärder för att skydda bisamhället.

För att detektera antalet myror vid kupans ingång utvecklades en objekt-detekteringsmodell baserad på YOLO. Modellen utformades så att biodlaren varnas om risken för myrinvasion, om antalet stackmyror på bild överstiger ett förutbestämt värde. För att träna YOLO-modellen genererades ett brett

dataset. Bilder av bikupans ingång, som togs med kameran riktad rakt uppifrån valdes ut från Ericssons insamlade data, och användes sedan som bakgrund för genereringen av data med stackmyror. Därefter beskärdes bilder av stackmyror som hämtades från nätet och placerades på de utvalda bilderna. Ett varierat och robust dataset framställdes genom att redigera bilderna, inklusive ändringar i antalet myror, deras placering, rotation, färg, ljus, skugga, skärpa och brus. Denna metod resulterade i en större variation i datauppsättning, vilket bidrog till att modellen bättre kunde lära sig och anpassa sig inför ny, otränad data. Sedan annoterades varje bild genom att markera varje myra med en box och tilldela dem en motsvarande etikett. Modellen skapades genom att tränas på den annoterade datan med ett YOLO-kommando i Python. För att utvärdera modellens prestanda användes tre testbilder, med varierande antal myror, för att bedöma dess noggrannhet i att upptäcka och klassificera myror vid kupans ingång.

Vidare implementerades modellen i OWL genom att hämta senaste bilden från vald bikupa och sedan testa den bilden med modellen. Resultatet av testet skickas till OWL och presenteras som en bedömning av risken för myrinvasion. Bilden som testats presenteras även för användaren för att den direkt ska kunna se detektionen av myror.

4.6 Svärmningsdetektion

Eftersom svärmingar kan vara förödande för en biodlares lönsamhet beslutades det att implementera en metod för att identifiera risken för att en svärming ska kunna ske. Först gjordes en analys om det var möjligt att med avancerade maskininlärningsalgoritmer detektera svärming. Eftersom det saknas tillgänglig historisk data på svärmingar på de kupor som finns tillgängliga för analys gjordes bedömningen att det var för svårt. Projektgruppen beslöt därför att använda ett expertsystem. Med hjälp av ett expertsystem kan data analyseras och ge en förbestämd respons med hjälp av teori beroende på vilka data som samlas in. På grund av implementeringssvårigheter togs även beslutet att detektera risken för en svärming istället för att detektera när en faktiskt svärming sker. Ytterligare anledningar inkluderar att utvecklingen av ljudanalysen ska kunna detektera svärming eftersom ljudet kan ge en tydlig indikation om en svärming äger rum.

Expertsystemet tar hänsyn till fem olika parametrar; utomhustemperatur, klart väder, månad, vikt och temperatur i kupan. Månadsintervallet sattes från maj till augusti för att ta hänsyn till hela perioden då risk finns. För att detektera om vikten är konstant jämförs de tre senaste dagarna med varandra och om vikten inte ökat under dessa dagar, detekteras det och visas i applikationen. För att göra en bedömning om svärming sker nu presenteras även viktskillnaden mellan senast mätning och medianvikten för dagen innan. Om svärming sker kommer en stor viktskillnad kunna avläsas och biodlaren kan larmas.

Till sist detekteras det om det är tillräckligt varmt i kupan för att det ska ske äggläggning. För att en larv ska utvecklas måste det vara 34 °C i kupan och detta gäller även för drottningen när den ska utvecklas. Vid all äggläggning hålls temperaturen i kupan konstant runt 34–35 °C med hjälp av binas temperaturreglering [17]. För att undersöka temperaturen samlas de fem senaste dagarnas mediantemperatur och om 80 % är i intervallet 31–35 °C så ges ett positivt besked att det kan bedrivas äggläggning i kupan. Intervallet 31–35 °C bestämdes eftersom positionen av sensorn inte är exakt där äggläggning sker och inte når upp fullt till 34 °C och att temperaturen kan fluktuerar kring 34 °C.

Koden för modellen implementerades direkt i OWL där realtidsdata hämtas för att sedan gå igenom expertsystemet. Resultatet presenterades sedan i instrumentpanelen som visas i figur 16. För att testa

modellen kördes expertsystemet på gammal data på samma bikupor från 2022, dock fanns ingen tillgänglig data på faktiska svärmningar. Testerna som kördes visade därmed hur många falska varningar som modellen ger. Tre stycken test kördes, ett för modellen utan parametrarna klart väder och plötslig viktninskning, ett utan plötslig viktninskning och ett med alla parametrar. Testet med alla parametrar innehöll 359 datapunkter.

4.7 Beräkning av bikupans hälsotillstånd

Utifrån insamlad information om vilka faktorer som påverkar tillståndet hos ett bisamhälle och deras bikupa bestämdes de tre parametrarna vikt och temperatur på bikupan, samt bidrottningens ålder. För att avgöra hälsotillståndet i bikupan skapades ett enkelt expertsystem där regler för dessa parametrar sattes upp, i form av intervall och villkor. För ett godkänt hälsotillstånd sattes vikten till över tio kilo för att säkerställa att bina har tillräckligt med näring och för att ta hänsyn till olika uppsättningar av utrustning. Villkoret för temperaturen sattes till mellan 5–35 °C baserat på vilken temperatur bisamhället klarar av och villkoret för åldern på bidrottningen till yngre än fem år, vilket är den maximala livslängden. Med hjälp av expertsystemet användes sedan realtidsdata från vikt- och temperatursensorerna, samt ett manuellt inmatat värde på drottningens ålder för att avgöra hälsotillståndet för en vald kupa. Efter att sensordata lästs in från databasen säkerställer expertsystemet att varje värde är inom sitt intervall och markerar då värdet med grön färg, annars med röd färg. Hela modellen skapades i OWL och implementerades i de korresponderande komponenterna i instrumentpanelen. Resultatet av beräkningen av hälsotillståndet utvärderades genom att implementera modellen i realtid i OWL och jämföra med nuvarande status, då historisk data över kupans hälsotillstånd inte fanns tillgänglig.

4.8 Presentation av systemfunktionerna

Presentation av de funktioner som tillsammans används för att beskriva bikupans status skapades som ett grafiskt användargränssnitt i OWL. Eftersom dataanalysen genomfördes delvis i OWL har programmet arbetats med kontinuerligt under projektets gång. När datan och modellerna gjorts tillgängliga genom att koppla dem till OWL och använda databasen, skapades automationer och komponenter som sedan skulle visas på instrumentpanelen. För att visualisera och förmedla informationen på ett bra sätt behövde en design för hur komponenterna skulle se ut implementeras. Designen blev ett pågående projekt då vilka funktioner som skulle hinnas med att implementeras var oklart, och instrumentbrädan anpassades utefter detta.

Informationen som skulle presenteras var de ovan nämnda funktionerna, detektion av ljudavvikelse och ljudklassifiering, pollendetektion, myrdetektion samt detektion av bildavvikelse, svärningsdetektion och beräkning av hälsotillstånd. Designen på instrumentbrädan valdes så att de mest relevanta funktionerna kom först, samtidigt som de komponenter som hör ihop presenterades bredvid varandra.

5 Resultat

Följande avsnitt redovisar resultatet av modellerna som skapats och implementationen i det grafiska användargränssnittet.

5.1 Modeller för identifiering av avvikelser och klassificering av ljud

När modellen för ljudavvikelser kördes på tidigare insamlad data hittades flera ljudavvikelser. Tre olika set användes, där set 1 bestod av filer från mars 2023, set 2 från december 2022 och februari 2023 och set 3 bestod av blandade filer från olika månader. Utmärkande för set 3 var att de innehöll filer med både vanligt surrande ljud från bin och känt avvikande filer. Två olika värden på respektive parameter, $n_estimators$ och $contamination$, valdes. Vid körning blev resultatet att olika antal ljudavvikelser hittades beroende på hur parametrarna var satta, se tabell 2. Resultatet för set 3 med de kända avvikelserna blev att de avvikande filerna hittades, se rad 5 i tabell 2. Filerna som identifierats blev "regn", "digitalt sprakande ljud", "utan drottning" och "vind" samt en fil som inte tidigare identifierats som avvikande. När modellen kördes med ett stort antal filer hittades ett stort antal avvikelser, se rad 2 i tabell 2. Många av de detekterade avvikande filerna som lyssnades igenom kunde inte kopplas till något annat ljud än "normalt" surrande ljud från bin.


Tabell 2: Resultat av modell för ljudavvikelse för olika testset och parametervärden.

Namn på test-set	$n_estimators$	$contamination$	Antal filer	Antal avvikelser
Set 1	100	0.1	128	14
Set 1	75	0.05	128	7
Set 2	100	0.1	565	57
Set 2	75	0.05	565	29
Set 3	100	0.1	46	5
Set 3	75	0.05	46	3

Klassificeringsmodellens prestanda optimerades först på valideringsdatan och utvärderades sedan på testdatan. Modellen tränades på att kunna klassificera inspelat ljud som "bin", "vind", "fåglar" och "övrigt". Modellen gav bäst precision på valideringsdatan när $K = 7$. Utvärderat på testdatan visas modellens prestanda i tabell 3 och dess *confusion matrix* presenteras i figur 12.


Tabell 3: Prestandautvärdering av KNN-klassificeringsmodell av ljud.

Klass	F1-känslighet	F1-precision	F1-värde
Bin	1,00	0,97	0,98
Fåglar	0,91	0,91	0,91
Vind	1,00	1,00	1,00
Övrigt	0	0	0



Figur 12: *Confusion matrix* från KNN-modellens klassificering av test-datan, då siffrorna representerar antalet filer.

Datan som KNN-modellen tränades på visas i figur 13. Originaldatan består av 20 MFC-koefficienter och har reducerats till två dimensioner, en Y och X-axel. I figuren syns de kluster som klasserna "Bin", "Vind" och "Fåglar" utgör, medan kategorin "Övrigt" har mer spridning. När modellen kördes med testdatan kunde den läsa in filerna i en mapp och sedan sortera dem enligt deras tillhörande klass. Detta visade att modellen kunde uppfylla sin funktion som ett verktyg för sortering av data.




Figur 13: Figuren visar datan som användes för att träna KNN-modellen, datans dimension är reducerad till två dimensioner för visualisering.

Vid implementation av det gemensamma programmet för de två modellerna, detektion av ljudavvikelser och ljudklassificering, på mikrodatorn och till OWL, valdes parametrarna $n_estimators = 75$ och


$contamination = 0.05$, samt $K = 7$. När programmet kördes blev resultatet att ljudavvikelse hittades i realtid, och kunde klassificeras. Eftersom implementationen gjordes i slutet av projektet kunde inte de nya resultaten utvärderas, det vill säga valideras enligt mått för precision eller genomlyssnas för att se karaktären på avvikelseerna.

5.2 Pollendetektion

Eftersom pollendetektionsmodellen existerade innan projektets start beskrivs resultatet av hur implementationen av modellen blev. Vid testning uppnådde modellen en precision på 77 %. Modellen presterade olika bra för olika bilder. När bilderna hade små fläckar orsakat av smuts på kameralinsen kunde modellen misstolka dessa för pollen. Resultatet av implementationen av pollendetektionsmodellen blev att den fungerade och kunde integreras som väntat i OWL, och sedan köras i realtid. Figur 14a visar tre bilder på bin med insamlat pollen på sidorna och figur 14b visar resultat för körning av en testbild.



(a) Bin med tre olika pollenfärger. Från vänster syns bin med: orange pollen, vit pollen och gul pollen.



(b) Resultat för körning av pollendetektionsmodellen på en testbild.


Figur 14: Till vänster visas tre bilder av de som pollendetektionsmodellen tränades på och till höger visas resultat från körning på en testbild från Ericssons bikupa.

5.3 Modell för bildavvikelse

Vid testning av bildavvikelsemodellen detekterades samtliga bin som avvikelser. Modellen var tränad på de 50 senaste bilderna på kupan då bina var inaktiva. Då samhället var i vila, och testbilden var från när bina var aktiva utanför kupan så identifierades bina som avvikelser. Detta resultatet erhöles då modellens tröskelvärde för avvikelse var 5 %, $n_estimators = 100$ och $contamination = 0.05$.

5.4 Modell för myrdetektion

Modellen kan identifiera stackmyraangrepp och har en F1-precision på 97 %. Myrdetekteringsmodellen testades på tre olika bilder, och resultaten presenteras nedan. I det första testet, se figur 15a, upptäckte modellen ett högre antal myror än gränsvärdet på 8, vilket resulterade i en varning för myrinvasion. I det andra testet, se figur 15b, var antalet myror i bilden mindre än gränsvärdet och modellen gav utvärdet att myror har detekterats men att risken för invasion är låg. Slutligen, i det tredje testet figur 15c upptäcktes inga myror vid bikupans ingång, vilket resulterade i att modellen skriver ut att inga myror har detekterats.



Figur 15: Illustrationen visar resultatet av myrdektionsmodellen för tre olika fall.

5.5 Svärmsningsdetektion

Resultatet blev att modellen vid realtidskörning gav korrekt utslag enligt de villkor som angetts. Vid testning på historisk data blev resultatet att 46 stycken falskt positiva utslag gavs när endast parametrarna utomhustemperatur, månad och temperatur i kupan analyserades. Efter att även parametrarna klart väder och plötslig viktminskning implementerats sjönk antalet falska positiva till 2 stycken. Alltså gav modellen korrekta utslag att det inte skedde någon svärmning för 357 av 359 fall.

5.6 Bikupans hälsotillstånd

Resultatet av modellen för bikupans hälsotillstånd blev att modellen gav utslag enligt de villkor som angetts. Modellens bedömning stämde även överens med en subjektiv bedömning av bikupans nuvarande hälsostatus.

5.7 Användargränssnitt i OWL

Det grafiska användargränssnittet är en instrumentpanel uppdelad i nio stycken komponenter med olika funktioner. Varje komponent har en titel och beskrivning om vad komponenten visar. Instrumentpanelens första komponent tillåter användaren att välja vilken bikupa som informationen ska visas för, och innan dess visas ingen data. Först efter att en kupa har valts laddas tillhörande data in i samtliga resterande komponenter.

I figur 16 syns de tre första komponenterna i instrumentpanelen. Kolumnerna i den första komponenten visar bikupornas namn, plats, hälsotillstånd och ifall äggläggning sker. För hälsotillståndet och äggläggning har passande symboler i form av gröna bockar, röda kryss och ägg valts.

Mittenkomponenten visar hälsotillståndet för bikupan inklusive svärmsningsrisken. Värdena som analyseras och visualiseras är; vikt och viktökning senaste dagen och veckan, lufttryck, bidrottningens ålder samt genomsnittstemperaturen i varje box. Värdena som visas i samband med riskindikator för svärmning är väder, utomhustemperatur, månad, om det finns ägg i bikupan och om vikten varit konstant. Här ser användaren värden i grönt eller rött baserat på hur värdet klassas, och ifall alla värden är gröna visas en grön bock-symbol under kolumnen *Health* i den första komponenten. Ifall något värde är rött visas en röd kryss-symbol. Risk för svärmning beräknas vara hög när alla värden i nedre delen av komponenten är röda, och som en sammanfattning visar meningen längst ner om något sensorvärde har klassats som okej eller inte. Komponenterna visualiserar expertsystemen som gjorts för att beräkna

hälsotillståndet och ger även en riskindikation för svärmning. Den tredje komponenten visar temperatur över tid för de senaste tre månaderna i den valda bikupan. När temperaturen ligger mellan 31–35 °C blir grafen grön, och överstiger den 35 °C blir grafen röd, för att indikera när äggläggning sker.




Figure 16: Applikationens komponenter som visar val av kupa, bikupans hälsotillstånd och en graf över temperaturen korrelerat till när äggläggning sker implementerat i OWL.

I figur 17 syns de tre följande komponenterna i instrumentpanelen, vilka visualiserar resultatet av pollendetektionsmodellen genom olika grafer. Den första komponenten visar ett tårtdiagram över fördelningen av färger på pollen för den valda bikupan. Mittenkomponenten visar ett linjediagram som visar hur olika färger på pollen samlats in över tid för den valda kupa. Den tredje och sista komponenten visar ett radardiagram som jämför fördelningen av färger på insamlat pollen för alla bikuporna. Detaljerad information om vilka värden som tillhör vilken bikupa fås genom att hålla muspekaren över grafen.





Figure 17: Applikationens komponenter som visualiserar resultatet av pollendetektionsmodellen.

De tre sista komponenterna visar ljudanalys, myrdetektion och bildavvikelser, samt inspektionsinformation, se figur 18. Komponenten för ljudanalys visar filnamnen för de fem senaste avvikelserna som hittats av de ljudfiler som matats in till modellen och vilken klass de har tilldelats. Mittenkomponenten visar datum för senaste kontroll av bildavvikelse, samt grön text om ingen avvikelse hittats och röd text om avvikelse hittats. Komponenterna visar även den senaste bilden som körs i modellen. Nedre delen av komponenten visar datum för senaste kontroll av myrdetektion och huruvida en stor mängd myror identifierades (röd text), en liten mängd (orange text) eller inga myror (grön text).

Den sista komponenten visar ett formulär där användaren kan fylla i information om senaste inspektionen som gjorts. Till vänster i varje rad syns en beskrivning om vad som kan fyllas i eller vilken bikupa som är vald, och till höger kan användaren fylla i text eller datum i fälten. Denna information

sparas sedan tills användaren väljer att fylla i ny information.



Figur 18: Applikationens komponenter som visualiserar ljudanalys, avvikelser i bilddata och myrdetektion samt ett inspektionsformulär.

6 Diskussion

I detta avsnitt utvärderas först varje systemfunktion, därefter diskuteras etiska och samhällseliga aspekter samt utvecklingsmöjligheter.

6.1 Utvärdering av systemfunktioner

6.1.1 Svårt att dra slutsatser om ljudanalys, men finns värdefull information

Tidigt i arbetet konstaterades potentialen med att använda ljudanalys för att ge information om bisamhällets tillstånd. Under informationssökning hittades aktuell forskning om hur olika beteenden i kupan kan kopplas till specifika ljud och frekvenser [51]. Detta tyder på möjligheten att analysera ljudet från en bikupa och ge en detaljerad bild av vilka processer som sker i kupan. Vid förstudien till ljudanalysmodellen gjordes bedömningen att en modell för dessa specifika beteenden skulle kräva en hög kvalitet på ljudinsamling och väl annoterad data ifall maskininlärning ska användas. Dessa förutsättningar fanns inte i dagsläget och kvaliteten på ljuddata var en betydande begränsande faktor. I tidigare projekt har modeller skapats utifrån externt hämtad data, men när de skulle prövas på Ericssons kupor presterade de inte väl på deras data. Med önskemål att bygga ett program som är kompatibelt med Ericssons uppkopplade kupor och föra utvecklingen vidare, beslutades att fokusera på den existerande datan, trots dess begränsningar.

Under projektets gång utvecklades ett program med en avvikelsemodell och en klassificeringsmodell. Modellen för avvikelser är en generell modell som inte har några krav på ljudkvalitet eller annotering vilket gjorde den lämplig beaktande projektets förutsättningar. För att förbättra datainsamlingen av ljud utvecklades klassificeringsmodellen som system för att sälla mellan brus och relevant data. På mycket av den insamlade datan kunde det höras fågelkvitter och blåst som dominerade över det underliggande ljudet från bikuporna. Förhoppningen med det nya systemet är att framtida projekt ska kunna få bättre sorterad data för att kunna fortsätta utveckla fler funktioner med ljudanalys.

Syftet med att skapa en avvikelsemodell för ljudupptagning var främst att kunna informera biodlaren om att en avvikande händelse sker. För att utvärdera modellens algoritm har det tagits fram intressanta situationer som är önskvärda att detektera som avvikelser. Dessa är främst svärmning, oväntad aktivitet

på vintertid och om till exempel ett djur attackerar kupan. Det saknades däremot historisk data från sådana händelser som gjorde en detaljerad utvärdering svår. Modellen lyckades detektera avvikelser och särskilt intressant är att den detekterade de annoterade avvikelserna, så som ett uppjagat bisamhälle. Att få en indikation i realtid om något avviker från det normala, vilken kan användas året runt, är en viktig tillgång för en biodlare.

Vid utvärdering av KNN-modellen visas det tydligt hur modellen korrekt kan identifiera bin, fåglar och vind med ett F1-värde på 0,91 till 1, medan den inte alls lyckas hitta klassen övrigt. Anledningen till detta kan tydligt tolkas ur figur 13 där en stor spridning på övrigt-klassen syns. Detta är då klassen inte definieras efter ett gemensamt attribut annat än att de inte tillhör de andra klasserna. Då KNN-modellen endast kan tränas att klassificera väldefinierade klasser är detta en dålig modell för att klassa avvikande ljud, då förefaller det mer lämpligt med en avvikelse-modell.

De största bristerna hos programmet för de två modellerna för ljudavvikelse och klassificering är användarvänlighet och precision av detektion. Då programmet skickar alla detekterade avvikelser till OWL kan det vara tidskrävande att lyssna igenom dem och vid närmare undersökning var många detektioner inte av intresse. Det innebär att modellen kan vara för känslig eller att algoritmen för hur avvikelserna hittas kanske inte är rätt för denna sortens ljuddata. Programmets KNN-modell är också mer intressant för utvecklare av systemet och svårtolkad av biodlare. Funktionen är däremot givande för en biodlare i kombination med avvikelsemodellen. Då även dess klass skickas till OWL kan det vara en metod för att sortera detekterade avvikelser. Då avvikelsemodellen jämför med de senaste 50 dagarnas data kan till exempel blåst klassas som avvikelse om det inte har varit blåst de senaste dagarna. Då kan KNN-modellen ge en indikation på om det är en intressant avvikelse att studera närmre eller inte.

6.1.2 Sorthonung och indikation om hälsa från pollenidentifiering

Analys av resultatet från pollenidentifieringsmodellen ger både biodlaren information om fördelningen av olika pollensorter och möjligheten att jämföra insamlingen av pollen mellan kuporna. Fördelningen av pollensorter underlättar produktionen av sorthonung, som kan ge en biodlare ett mer varierat utbud. Genom att jämföra insamlingen av pollen mellan kupor kan det även ge en indikation på ett bisamhälles hälsa. Om en kupa samlar in mindre pollen än de andra kan det vara för att kupan är dåligt placerad, eller att bisamhället är svagt och att biodlaren behöver ingripa.

Även om modellen visade sig vara effektiv, gjorde den också misstag. Vissa bilder som användes har små fläckar av smuts, som modellen misstog för pollenklumpar. Detta resulterar i felaktiga resultat och kan därmed generera grafer som inte är användbara. Bakgrundsfärgen spelar stor roll eftersom modellen endast är tränad på bilder från Ericssons kupor med ungefär samma bakgrundsfärger. Detta gör modellen mer specifik och mindre kapabel att hantera andra bakgrundsfärger. Dessutom kan bildkvaliteten ha haft en betydande påverkan på modellens prestation. Om bilderna är suddiga, pixliga eller är för mörka kan det vara svårt för modellen att identifiera objekt korrekt. Utöver dessa faktorer kan även kameravinklarna och ljusförhållandena för varje bikupa ha påverkat bildvariationerna och gjort det svårare för modellen att korrekt identifiera pollen.

6.1.3 Detektering av bildavvikelser kan hjälpa biodlare, men kräver data av hög kvalitet

Resultatet av bildavvikelsemodellen visar på potentialen för ett brett användningsområde. Som ett verktyg kan modellen användas för att effektivisera och optimera biodling för både yrkes- och hobbybiod-

lare. Genom att meddela biodlaren om detekterade avvikelser i realtid, kan biodlare få en detaljerad överblick på ett större antal bikupor och endast utföra kontroller vid behov. För yrkesbiodlare som kan ha tiotals till hundratals bikupor är det inte möjligt att ge varje bikupa mycket tid, nämnde Andrea Wallroth i intervjun. För oerfarna biodlare kan bildavvikelsemodellen innebära en ökad förståelse och därmed enklare identifiera de avvikelser som kräver åtgärder. I teoriavsnittet 2.4 nämns ett flertal olika faror som bisamhällen kan råka utför och trots att det inte finns en optimal universallösning, kan det AI-drivna övervakningssystemet meddela biodlarna i god tid och de kan agera därefter.

Strukturen med två separata filer, där den ena är avsedd för träning av data och den andra för att köra modellen samt testa nya bilder, medför hög hastighet för modellen. För träning av koden kräver modellen inte mycket data för att vara kapabel till detektering av ett flertal olika avvikelser. Det är viktigt att notera att modellen baseras på *Isolation Forest*-algoritmen och inte objekt-detekteringsmodellen, vilket resulterat i en mer flexibel bildavvikelsemodell. Längden på tidsperioden som träningsdatan hämtas från kan enkelt justeras i koden med hänsyn till mål och behov. Modellen etablerar en standard baserad på träningsintervall, vilket möjliggör anpassning för att hantera både dagliga avvikelser och större avvikande händelser över längre tidsperioder. En väsentlig fördel med detta är att det breddar användningsområdet och kan modifieras efter typ av användare. Modellen utmärker sig med dess mindre storlek och enkla struktur och är således lätt att använda samt öppen för utökning.

Den största utmaningen vid utveckling av modellen var att utvärdera dess prestanda. Bristen på verkliga avvikelser har gjort det svårt att bedöma modellens styrkor och svagheter, och det har därför varit utmanande att bedöma hur väl modellen fungerar på data som innehåller vardagliga variationer. Vidare är modellens datakänslighet en begränsning då datan som modellen tränas på måste vara av hög kvalitet och vara homogen utan för mycket fluktuation, annars blir precisionen för avvikelседetektion sämre. En ytterligare begränsning är modellens enkelhet, dess främsta syfte är att detektera avvikelser och utför därmed inga ytterligare analyser. Det är väsentligt att påpeka att då modellen inte är testad på faktiska avvikelser, kommer den att detektera många avvikelser som inte alla är betydande. Således, om avvikelserna annoteras kan man sakta utveckla en robust modell.

6.1.4 Myrdektionsmodell tränad på genererade bilder

Ett av de främsta problemen för svenska biodlare berör stackmyror som är fridlysta och måste hanteras med stor försiktighet, enligt Andrea Wallroth. Stackmyror befinner sig ofta nära bikupan, men det tyder inte alltid på att de är en fara för bisamhället, det är farligt endast när en myrinvasion sker. De få myrorna vid bikupan kan skapa stor oro hos oerfarna biodlare. Myrdektionsmodellen kan således ge nya biodlare en tydlig signal om när de behöver agera, och för yrkesbiodlare kan modellen innebära effektivisering.

Modellen är en objekt-detekteringsmodell och behöver därmed inte tränas varje gång den används, utan den körs på den förtränade modellen. Denna modell är inte bara lätt att använda utan även mycket effektiv och dess korta detekteringstid är en av dess främsta fördelar, utöver detta har modellen en hög precision på 97 %.

Det är viktigt att påpeka att en av myrdektionmodellens främsta begränsningar är att datan baseras på bilder tagna ur bestämda förhållanden och som inte nödvändigtvis återspeglar variationen i naturliga scenarion. Vidare är en begränsning med modellen att den inte är flexibel, då modellen inte går att ändra och modifiera för ny typ av bilddata. På grund av brist på bilddata med stackmyror, är modellen baserad på manuellt genererad bilddata vilket har haft en signifikant påverkan på slutresultatet. Den

generade datan är även begränsad till bilder tagna rakt uppifrån, det innebär att modellen endast kan testas på de utvalda bikuporna med rätt kameravinkel. På grund av tidsbrist fanns inte möjlighet inom ramen av denna studie att vidare utforska möjligheten för insamling av data på stackmyror. Med verklig bilddata kan en modell utvecklas som är anpassad för alla bikupor, vilket kan resultera i en ökad noggrannhet i analysen, och en mer robust modell kan tränas som är förberedd på olika variationer.

6.1.5 Ett första steg mot svärminnsdetektion

Riskindikatorn för svärmning implementerades och kommer i framtiden kunna ge användbar information till biodlaren om hur stor risken är att samhället ska svärma. Implementationen ses därför som lyckad och även om modellens träffsäkerhet är svår att utvärdera så bedöms modellen som en bra grund och mall för framtida projekt att bygga vidare på. Utmaningar som uppkom under projektet var att sätta gränserna för de olika villkoren i expertsystemet eftersom det inte fanns någon data och beslutsfattandet grundades till stor del på teori och information från tidigare studier. Detta bidrog i sin tur till en hög osäkerhet i de parametrarna som till slut valdes. Främst var det osäkert att bestämma vad som skulle vara konstant vikt och vad som ska ses som en plötslig sänkning i vikt eftersom vikten och viktskillnaden till stor del är beroende av hur stort samhället är. Detta gör att gränserna kan variera mycket från kupa till kupa.

En ytterligare utmaning var presentationen av den samlade informationen. Till en början var idén att resultaten från funktionerna skulle värderas i koden och bara presentera en bedömning i form av låg, medel och hög risk. Eftersom expertsystemet har många parametrar som är osäkra och bristen på faktiskt data av svärmande bikupor valdes detta bort. Istället presenteras informationen var för sig med en positiv eller negativ bedömning. På detta sätt blir modellen lättare att förstå och mer transparent, vilket är viktigt i det tidiga stadiet som modellen befinner sig i.

6.1.6 Hälsotillståndet identifierar generella avvikelser

Modellen för hälsotillståndet baserades på värden som hittats i teori om bin och bisamhället och kan användas för att ge en indikation på hälsotillståndet för kupan. Parametrarna som modellen använder; bikupans vikt, temperatur och bidrottningens ålder, ger en översiktlig bild över hälsostatusen eftersom de är grundläggande faktorer som påverkar binsamhället. Om modellen identifierar avvikande värden kan biodlaren meddelas och åtgärder kan genomföras. En särskilt viktig situation där hälsotillståndet är värdefullt är om vikten på kupan blir för låg på vintern, vilket kan innebära att bisamhället dör om inte biodlaren får en varning och kan agera i tid.

Villkoren för parametrarna valdes utefter vilken data som fanns tillgänglig, men i och med variationer och felkällor kopplat till sensorerna sattes intervallen brett. Det innebär att värden anses bra eller icke avvikande i de flesta fall om inte ett extremt värde visas. En mer noggrann studie kring vilka intervall som är passande hade därför kunnat öka precisionen för att detektera om något inte stämmer. Det är viktigt att biodlaren inte förlitar sig enbart på dataanalysen utan ser beräkningen av hälsotillståndet som ett hjälpmedel och fortsätter inspekterar bikupan manuellt.

6.1.7 Användarvänlig presentation av dataanalys från sensorer

Användargränssnittet ger biodlare möjlighet att både se direkta värden från sensorerna, såsom temperatur, vikt och bilder, och även visualiserad och bearbetad data i form av grafer och analysresultat.

Avvikande värden eller beteenden kan upptäckas med hjälp av användargränssnittet, varpå biodlaren kan agera snabbt och se till att en manuell undersökning genomförs så snart som möjligt för att åtgärda potentiella problem. Applikationen har skapats så att användaren direkt får en översiktlig uppfattning av alla kupors tillstånd och äggläggning, för att sedan kunna välja en kupa och få detaljerad information om den. Denna design gör applikationen användbar även för biodlare med många kupor. Komponenterna har positionerats så att de hör ihop tre och tre horisontellt, vilket gäller framför allt de första två raderna av komponenter. För att göra värden och analyser extra tydliga har grön och röd färg använts konsekvent för att indikera bra respektive dåliga eller avvikande värden.

6.2 Samhälleliga och etiska aspekter

Automation av biodlingsprocessen och teknikutveckling lik den som genomförts under projektet kan bidra till ökad förståelse och förbättringar för biologiska system såsom bisamhällen. Mer insyn i biodlingsprocessen och ökad kunskap om hur ett bisamhälle fungerar bidrar till att förstå hur innovation och tekniska lösningar kan gynna biodlingsprocessen och därmed gynna pollinering och biologisk mångfald. Det är dock viktigt att användarna av användargränssnittet och modellerna som skapats i detta projekt är medvetna om att de inte kan ersätta manuell övervakning, utan ska fungera som ett verktyg som kan underlätta och minska arbetet för biodlare och störningsmomenten för bina.

Inga experiment har genomförts under projektets gång, vilket också innebär att ingen interaktion alls mellan projektgruppen och bikuporna har skett. Data från ett tidigare experiment har använts och experimentet genomfördes efter noga övervägning från personer med kunskap om biodling. Det experimentet bidrog till har varit värdefullt i utvecklandet, men för att experiment ska vara etiskt försvarbara är det viktigt att fördelarna vägs mot de nackdelar som genomförandet kan innebära.

En förenklad process genom ökad automation kan innebära att tröskeln till att bli biodlare sänks och att antalet biodlare och antal honungsbin ökar. Samtidigt är urbanisering, monokulturer i jordbruk och avsaknad av blomsterängar faktorer som minskar födan för pollinerare [1]. Detta påverkar både honungsbin och vildbin, mellan vilka konkurrens kan uppstå [52]. Det går därför att diskutera om biodlare behöver ta hänsyn till andra pollinerare genom att undvika biodling i områden där konkurrensen kan bli hög, men eftersom projektet inte är geografiskt bundet går det att ta hänsyn till detta samtidigt som lösningarna kan användas. Sverige ligger dessutom långt under genomsnittet för antal bisamhällen per kvadratmeter i Europa [52], vilket snarare talar för att fördelarna med utveckling som kan stimulera ökning av biodling och bisamhällen överväger.

6.3 Utvecklingsmöjligheter

6.3.1 Modeller för ljudanalys

Ljudavvikelsemodellen identifierade viktiga avvikelser som kunde uppfattas av det mänskliga örat, men också många avvikelser som var svåra att tyda. För att göra modellen mer användbar kan andra algoritmer eller parametervärden testas. Det skulle även vara givande att göra en ny modell baserad på väglett lärande och annotera datan till "normalt ljud från bin" och "avvikande ljud", där filer med normalt bakgrundsljud, som till exempel fågelkvitter, inte detekteras som en avvikelse. Detta kräver ett varierat dataset med olika sorters avvikelser likt de som tidigare presenterats, eftersom det krävs ett jämnt fördelat dataset för att kunna skapa en bra modell. Att annotera ljuddata är dock mycket tidskrävande och i flera fall utmanande med tanke på förmågan att förstå vad ljuddata faktiskt innehåller.

6.3.2 Pollendetektion

För att göra modellen för pollenidentifiering bättre behövs ett mer varierat bilddataset. Modellen är nu begränsad till att tränas på ett specifikt dataset, vilket gör att modellen gör misstag när den blir testad på ny, osedd data med andra variationer. Genom att träna och testa modellen på ett utökat dataset med andra bakgrunder, annan ljussättning och bildkvalitet, kan modellens precision förbättras.

En funktion som hade utökat pollendetektionens användning skulle vara att koppla ihop analysen med växters säsong för blomning och bikupans närliggande växtlighet. Då hade programmet eventuellt kunnat koppla färg på pollen direkt till blomsort. Att producera sorthonung skulle då bli betydligt enklare för en biodlare.

6.3.3 Bildavvikelse

Det befintliga systemet har lyckats upptäcka avvikelser, men förbättringar behövs för att ge biodlaren ett mer informativt resultat. Med vidare utveckling kan modellen potentiellt identifiera sjukdomar samt plötsliga förändringar i binas miljö. Genom att kombinera den befintliga bildavvikelsemodellen med ett klassificeringssystem kan mer detaljerad information ges av de detekterade avvikelserna.

För att utveckla ett klassificeringssystem behövs manuellt annoterad data över avvikelserna. Genom att låta modellen sortera dessa i olika kategorier, får användaren möjligheten att analysera dem. Klassificeringssystemet kan då tala om för användaren vilken typ av avvikelse som detekterats och om den är betydande eller feldetekterad.

Vidare kan en funktion utvecklas där biodlaren kan interagera med modellen via användargränssnittet. Genom att presentera den detekterade avvikelsefilen i OWL kan användaren sedan bestämma om bilden är en avvikelse eller inte. Bilden kan sedan skickas till avvikelsemappen eller till träningsmappen beroende på biodlarens svar. På så sätt anpassar biodlaren systemet efter vad de anser är noterbart. Icke avvikande bilder skickas till träningsmappen som används till träning av modellen, vilket skulle öka modellens precision över tid.

6.3.4 Myrdetektion

Den nuvarande modellen är begränsad på grund av dess träningsdata. Modellen tränades på manuellt genererade data som brister i verkliga variationer. Genom att samla verklig data på stackmyror och myrinvasioner kan man skapa en modell som kan appliceras på olika bikupor. Under projektets gång föreslogs en metod för en första version av datainsamling, men på grund av tidsbrist utfördes det inte. Förslaget innebar att ställa en utrustad tom bikupa med honung nära en myrstack som skulle locka myror, för att sedan samla data på myrinvasion.

Vidare är data med alla typer av variationer värdefulla. Genom att samla och annotera data med olika typer av myror och insekter kan man bilda ett system som kan detektera och identifiera dessa objekt. Modellen skulle således kunna informera användaren om det är stackmyror, svarta myror eller andra insekter som befinner sig vid ingången av bikupan.

6.3.5 Svärmning

För att utveckla svärmningsmodellen behövs främst data på svärmningar från kupor med liknande sensoruppsättning. Sådan data skulle göra det möjligt att beräkna precision och analysera om modellen stämmer överens med verkligheten, vilket i sin tur gör det möjligt att ändra och förbättra

modellen. Svärmningsdata skulle också göra det möjligt att se hur vikten ändras inför en svärmning och se viktskillnader när svärmningen sker.

Andra utvecklingsmöjligheter som hade varit intressanta att undersöka är att mäta styrkan av ett bisamhälle eftersom svärmning ofta sker när bisamhället är starkt och bina känner att de klarar av att dela sig. En mer avancerad modell hade kunnat bedöma ett samhälles styrka genom att analysera vikten, eftersom styrkan är kraftigt kopplad till storleken på samhället. Genom att veta totalvikten av bina och honungen utan ramarna och bikupan finns det möjlighet att jämföra olika bisamhällen på ett mer precist sätt. Om dessutom vikten för en full ram vore känd hade det varit möjligt att estimerar maxvikten på samhället. För att testa detta förslag behövs data om bisamhällernas styrka och storlek, för att sedan validera den utvecklade funktionen.

En ytterligare utvecklingsmöjlighet är att inkludera ljudanalys i svärmningsdetektionen, eftersom ljudet av en pågående svärmning är en tydlig indikator. Därför bedöms ljudanalysen i framtiden kunna detektera svärmningar och varna biodlaren direkt när det händer.

6.3.6 Beräkning av hälsotillstånd

Modellen för beräkning av hälsotillståndet är mycket enkel och är baserad på villkor i form av värden som utgör övre och undre gränser. Modellen kan fungera som en översiktlig hälsostatus som varnar när något värde avviker kraftigt eller är dåligt. Genom att implementera justerbara gränser som kan variera över året hade modellen blivit mer dynamisk. Även fler parametrar och validering mot data kan öka modellens precision.

6.3.7 Användargränssnitt

Användargränssnittet begränsas till de funktioner som var möjliga att skapa i programvaran. En bättre design för biodlare med många kupor hade kunnat implementeras med annan programvara och hade tillåtit användaren att se mer av informationen för alla kupor samtidigt, utan att behöva välja en kupa specifikt. Applikationen har utvecklats i samarbete med biodlare, men hade kunnat testas av ett flertal för vidare utveckling. Fler valmöjligheter för användaren är ytterligare ett möjligt sätt att förbättra applikationen, där till exempel tidsperiod för pollen- och temperaturgraferna skulle kunna väljas av användaren. För ljudanalysen kan ljudfilen läggas in i OWL, så att användaren direkt kan lyssna på de avvikande filerna, så som det fungerar med bilder som visas. Detta skulle ge biodlaren möjlighet att hålla sig direkt uppdaterad och själv analysera datan genom applikationen.

En förbättring av applikationen skulle även vara att göra det oberoende av extern programvara. I dagsläget körs flera av analysprogrammen externt på datorer och resultatet från dessa laddas upp till OWL. Datan uppdateras därför inte i realtid utan endast när programmen körs manuellt. Detta kan lösas genom att implementera de externa modellerna på mikrodatorn och köra analysen direkt på den. Detta gjordes med ljudanalysmodellen på en kupa, men saknas för pollendetektion, myrdetektion och bildavvikelsedetektion.

7 Slutsats

Projektets mål var att underlätta biodlingsprocessen för biodlare genom att analysera sensordata från bikupor och sedan visualisera resultatet genom en webbapplikation. Resultatet blev en användarvänlig applikation med information om bikupans hälsotillstånd, svärmningsrisk, äggläggning, polleninsamling, avvikelser i ljud- och bilddata samt ljudklassificering, myrdetektion och information om den senaste inspektion.

Expertsystemet för hälsotillståndet testades mot nuvarande hälsotillstånd och gav korrekt utfall, medan expertsystemet för svärmningsrisk testades mot historisk data och resulterade då i två falska positiva utfall av 359 testade datapunkter. Den tidigare utvecklade pollendetektionsmodellen kunde implementeras i OWL och användes för att visualisera fördelning och färg på pollen. Ljudavvikelsemodellen gav flera användbara avvikelser som kan ge indikation på hot eller annorlunda beteende, samtidigt som resultatet för en sådan modell kan vara svårt att tolka. Ljudklassificeringsmodellen fick ett F1-värde mellan 0,91–1,00 för klasserna bin, fåglar och vind, och 0 för klassen övrigt. Modellerna implementerades tillsammans på en kupa och förbättrade insamlingen av ljuddata. En myrdetektionsmodell utvecklades genom att träna den på egengenererad data. Modellen uppnådde en precision på 97 % på testdatan, men den testades däremot inte på verklig data. Bildavvikelsemodellen kunde detektera samtliga testade avvikelser.

Under projektets gång var möjligheten att samla in ny data begränsad eftersom bisamhället hade låg aktivitet. Det var därför stundvis svårt att validera funktionerna med data och de utvecklades istället baserade på den data som fanns tillgänglig, samt på teori. Resultatet av analyserna och maskininlärningsmodellerna presenterades i användargränssnittet i OWL, och kan användas som ett underlättande verktyg för biodlare. Avslutningsvis bedöms syftet med projektet uppfyllt, samtidigt som ett flertal framtida utvecklingsmöjligheter identifierats.

Referenser

- [1] Förenta nationerna, "En värld utan bin är en värld utan mat", 2021. [Online]. Tillgänglig: <http://unric.org/sv/en-varld-utan-bin-ar-en-varld-utan-mat/>, Hämtad: 2023-02-02.
- [2] R. Bommarco et al., "Massdöd av bin – samhällsekonomska konsekvenser och möjliga åtgärder", Jordbruksverket, 2009. [Online]. Tillgänglig: https://www.jordbruksverket.se/webdav/files/SJV/trycksaker/Pdf_rapporter/ra09_24.pdf, Hämtad: 2023-04-20.
- [3] Allt om biodling, "Bli Biodlare", [Online]. Tillgänglig: <https://alltombiodling.se/bli-biodlare/>, Hämtad: 2023-02-02.
- [4] Biodlarna, "Bisamhället", [Online]. Tillgänglig: <https://www.biodlarna.se/bin-och-biodling/fakta-om-biodling/bisamhallet/>, Hämtad: 2023-01-30.
- [5] Jordbruksverket, "Bekämpa varroa", 2019. [Online]. Tillgänglig: <https://www.jordbruksverket.se/download/18.1a096df816ec43b73b5ddb74/1575454420734/ovr383v2.pdf>, Hämtad: 2023-01-27.
- [6] Allt om biodling, "Honungsbi", 2021. [Online]. Tillgänglig: <https://alltombiodling.se/honungsbi/>, Hämtad: 2023-03-20.
- [7] Emmet Royal Honey, "Honey Bee Life Cycle", 2022. [Elektronisk bild]. Tillgänglig: <https://emmetroyalhoney.com/bee-education/honey-bee-life-cycle/>, Hämtad: 2023-04-25.
- [8] E. Lee-Mäder, M. Spivak och E. Evans, "Managing alternative pollinators: A handbook for beekeepers, growers, and conservationists". Sustainable Agriculture Research och Education, 2010.
- [9] Nobelstiftelsen, "Karl von Frisch", 2021. [Online]. Tillgänglig: <https://www.nobelprize.org/prizes/medicine/1973/frisch/facts/>, Hämtad: 2023-04-26.
- [10] A. Stabentheiner, H. Kovac och R. Brodschneider, "Honeybee colony thermoregulation – regulatory mechanisms and contribution of individuals in dependence on age, location and thermal stress," *PLoS ONE*, årg. 5, nr 1, 2010. DOI: [10.1371/journal.pone.0008967](https://doi.org/10.1371/journal.pone.0008967).
- [11] F. Poelsma, "Thermoregulation in the bee colony", 2019-10-18, Tillgänglig: <https://www.vatorex.com/blog/beekeeping-blog-2/thermoregulation-in-the-bee-colony-31>, Hämtad: 2023-04-18.
- [12] M. Simmonds, "Honeybee Colony Thermoregulation", 2022. [Online]. Tillgänglig: <https://beekeepclub.com/how-honeybees-maintain-temperature-and-humidity-in-a-beehive/>, Hämtad: 2023-04-26.
- [13] Biodlarna, "Bisamhället", [Online]. Tillgänglig: <https://www.biodlarna.se/bin-och-biodling/fakta-om-biodling/bisamhallet/>, Hämtad: 2023-03-18.
- [14] Biodlarna, "Binas biologi", [Online]. Tillgänglig: <https://www.biodlarna.se/bin-och-biodling/fakta-om-biodling/bisamhallet/>, Hämtad: 2023-03-18.
- [15] PerfectBee, "The Role of the Queen Bee", 2022. [Online]. Tillgänglig: <https://www.perfectbee.com/learn-about-bees/the-life-of-bees/role-queen-bee>, Hämtad: 2023-03-18.
- [16] PerfectBee, "The Role of the Drone Bee", 2022. [Online]. Tillgänglig: <https://www.perfectbee.com/learn-about-bees/the-life-of-bees/role-of-the-drone-bee>, Hämtad: 2023-03-18.
- [17] N. Persson, "Boken om Biodling", 3 uppl., Skänninge, Sverige: Biodlarna, Sveriges biodlares riksförbund, 2011.
- [18] Britannica, The Editors of Encyclopaedia, "Honeybee", 2020. [Elektronisk bild]. Tillgänglig: <https://www.britannica.com/animal/honeybee>, Hämtad: 2023-04-25.
- [19] C. Hobbs, "The Mechanics of Pellet-Carrying Honey Bees", 2021. [Elektronisk bild]. Tillgänglig: <https://coe.gatech.edu/news/2021/08/mechanics-pellet-carrying-honey-bees>, Hämtad: 2023-04-25.
- [20] Sveriges Biodlares Riksförbund, "Pollen", [Online]. Tillgänglig: <https://www.biodlarna.se/bin-och-biodling/biodlingens-produkter/pollen/>, Hämtad: 2023-04-28.
- [21] Svenska Bin, "Varför svärmar bin?" [Online]. Tillgänglig: <https://svenskabin.se/varfor-svarmar-bin/>, Hämtad: 2022-03-23.
- [22] C. O. Mattson, J. Lang, "Bin till nytta och nöje", 5 uppl., Stockholm, Sverige: Art & copy produktion, 2013.
- [23] Arnia remote hive monitoring, "The Behaviour of Honey Bees Preparing to Swarm", 2021. [Online]. Tillgänglig: <https://www.arnia.co/post/the-behaviour-of-honey-bees-preparing-to-swarm>, Hämtad: 2023-04-30.

- [24] P. Sellman, "Expansionsperioden och den svärmförebyggande avläggaren", 2019. [Online]. Tillgänglig: <https://xn--smbruk-jua.se/publication/view/biaret-del-2-artikel-i-ater/>, Hämtad: 2023-04-30.
- [25] Bee Urban, "Biodling i Norra Djurgårdsstaden", 2023. [Online]. Tillgänglig: <https://vaxer.stockholm/omraden/norra-djurgardsstaden/biodling-i-norra-djurgardsstaden/>, Hämtad: 2023-04-30.
- [26] M. Sarwar, "Predations on honey bees (Arthropoda) by vertebrate pests (Chordata) and control of nuisance," *International Journal of Zoology Studies*, s. 12–17, 2016.
- [27] Allt om biodling, "Invintring", [Online]. Tillgänglig: <https://alltombiodling.se/invintring/>, Hämtad: 2023-03-27.
- [28] KDE Documentation, "Digitalisering", [Online]. Tillgänglig: <https://docs-staging.kde.org/trunk5/sv/kwave/kwave/digitalization.html>, Hämtad: 2023-04-14.
- [29] BBC, "Representing text, images and sound", 2022. [Online]. Tillgänglig: <https://www.bbc.co.uk/bitesize/guides/zpfdwmn/revision/3>, Hämtad: 2023-04-27.
- [30] S. Duraisamy, "The discrete Fourier transform," *The Discrete Fourier Transform*, s. 31–60, 2001. DOI: [10.1142/9789812810298_0003](https://doi.org/10.1142/9789812810298_0003).
- [31] R. Mahmood, J. Lucas, Jose Alvarez, S. M. Fidler, M. T. Law, "Optimizing Data Collection for Machine Learning", Working Paper.
- [32] S. Ali, S. Tanweer, S. Khalid och N. Rao, "Mel Frequency Cepstral coefficient: A Review," *Proceedings of the 2nd International Conference on ICT for Digital, Smart, and Sustainable Development, ICIDSSD 2020, 27-28 February 2020, Jamia Hamdard, New Delhi, India*, 2021. DOI: [10.4108/eai.27-2-2020.2303173](https://doi.org/10.4108/eai.27-2-2020.2303173).
- [33] J. N. Oswald, C. Erbe and W. L. Gannon, S. Madhusudhana and J. A. Thomas, "Detection and classification methods for animal sounds," *Exploring Animal Behavior Through Sound: Volume 1*, s. 269–317, 2022. DOI: [10.1007/978-3-030-97540-1_8](https://doi.org/10.1007/978-3-030-97540-1_8).
- [34] Chunduri, "Normalization in Machine Learning and Deep Learning", 2018. [Online]. Tillgänglig: <https://medium.com/transparent-deep-learning/normalization-in-machine-learning-and-deep-learning-56eb33eb0165>, Hämtad: 2023-04-27.
- [35] Google, "Normalization", 2022. [Online]. Tillgänglig: <https://developers.google.com/machine-learning/data-prep/transform/normalization>, Hämtad: 2023-04-27.
- [36] A. Schroer, "Artificial Intelligence. What Is Artificial Intelligence (AI)? How Does AI Work?", 2023. [Online]. Tillgänglig: <https://builtin.com/artificial-intelligence>, Hämtad: 2023-04-14.
- [37] R. Raj, Enjoy Algorithms, "Different types of machine learning algorithms". [Online]. Tillgänglig: <https://www.enjoyalgorithms.com/blog/classification-of-machine-learning-models>, Hämtad: 2023-04-14.
- [38] IBM, "What is the k-nearest neighbors algorithm?" 2021. [Online]. Tillgänglig: <https://www.ibm.com/topics/knn>, Hämtad: 2023-04-27.
- [39] M. Goldstein and S. Uchida, "A comparative evaluation of unsupervised anomaly detection algorithms for multivariate data," *PLOS ONE*, årg. 11, nr 4, 2016. DOI: [10.1371/journal.pone.0152173](https://doi.org/10.1371/journal.pone.0152173).
- [40] Analytics Vidhya, "Anomaly detection using Isolation Forest – A Complete Guide", 2021. [Online]. Tillgänglig: <https://www.analyticsvidhya.com/blog/2021/07/anomaly-detection-using-isolation-forest-a-complete-guide/>, Hämtad: 2023-04-14.
- [41] P. Pandey, "Outlier Detection using Isolation Forests", 2020. [Elektronisk bild]. Tillgänglig: <https://machinelearninggeek.com/outlier-detection-using-isolation-forests/>, Hämtad: 2023-04-14.
- [42] E. Lewinson, "Outlier Detection with Isolation Forest", 2018. [Online]. Tillgänglig: <https://towardsdatascience.com/outlier-detection-with-isolation-forest-3d190448d45e>, Hämtad: 2023-04-20.
- [43] A. Biswal, "Convolutional Neural Network Tutorial", 2023. [Elektronisk bild]. Tillgänglig: <https://www.simplilearn.com/tutorials/deep-learning-tutorial/convolutional-neural-network>, sept. 2022.
- [44] R. Kundu, "YOLO: Real-Time Object Detection Explained", 2023. [Online]. Tillgänglig: <https://www.v7labs.com/blog/yolo-object-detection>, Hämtad: 2023-04-26.

- [45] J. Redmon, S. Divvala, R. Girshick and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," i *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016, s. 779–788. DOI: [10.1109/CVPR.2016.91](https://doi.org/10.1109/CVPR.2016.91).
- [46] S. E. Harikrishnan, "Confusion Matrix, Accuracy, Precision, Recall, F1 Score", 2019. [Online]. Tillgänglig: <https://medium.com/analytics-vidhya/confusion-matrix-accuracy-precision-recall-f1-score-ade299cf63cd>, Hämtad: 2023-04-14.
- [47] Baeldung, "F-1 Score for Multi-Class Classification", 2022. [Online]. Tillgänglig: <https://www.baeldung.com/cs/multi-class-f1-score#multi-class-f-1-score-calculation>, Hämtad: 2023-04-28.
- [48] S. Liao, "Expert system methodologies and applications—a decade review from 1995 to 2004," *Expert Systems with Applications*, årg. 28, nr 1, s. 93–103, 2005. DOI: [10.1016/j.eswa.2004.08.003](https://doi.org/10.1016/j.eswa.2004.08.003).
- [49] Tuss Anzelius et al., "Automatisering av biodlingsprocess", 2022. [Online]. Tillgänglig: <https://odr.chalmers.se/server/api/core/bitstreams/2282e688-4e1c-420f-b579-954a47de8792/content>, Hämtad: 2023-01-27.
- [50] Raspberry Pi Foundation, "Raspberry PI", 2021. [Online]. Tillgänglig: <https://www.raspberrypi.com/products/raspberry-pi-4-model-b/>, Hämtad: 2023-04-26.
- [51] A. Terenzi, S. Cecchi och S. Spinsante, "On the importance of the sound emitted by Honey Bee hives," *Veterinary Sciences*, årg. 7, nr 4, s. 168, 2020. DOI: [10.3390/vetsci7040168](https://doi.org/10.3390/vetsci7040168).
- [52] B. Gustavsson T. Rahbek Pedersen, "Hur ska honungsbin kunna samsas om födan?" *JO23:2. Jordbruksverket*, 2023. [Online]. https://www2.jordbruksverket.se/download/18.35daf3941861129502336677/1675415066694/jo23_2.pdf, Hämtad: 2023-04-28.
- [53] Conventor, *An Explanation of New MEMS Microphone Technology and Design*, 2022, Tillgänglig: <https://www.coventor.com/blog/explanation-new-mems-microphone-technology-design/>, Hämtad: 2023-04-26.
- [54] TEL NanoTec Museum, *What is a CMOS sensor*, 2021, Tillgänglig: <https://www.tel.com/museum/exhibition/principle/cmos.html>, Hämtad: 2023-04-25.
- [55] Practical Cryptography, *Mel Frequency Cepstral Coefficient (MFCC) tutorial*, 2021, Tillgänglig: <http://practicalcryptography.com/miscellaneous/machine-learning/guide-mel-frequency-cepstral-coefficients-mfccs/>, Hämtad: 2023-04-19.

A Intervju med yrkesbiodlaren Andrea Wallroth

Intervjun med Andrea Wallroth började med en kort genomgång om biodling och bisamhällen. Andrea, som är en yrkesbiodlare med 60 bikupor, diskuterade flera viktiga aspekter av biodlingen, som bland annat vikten av att mäta bipopulationens storlek, då det är en indikation på bisamhällets hälsotillstånd. Ur hennes erfarenhet stöter biodlare på många olika utmaningar, som bland annat kvalster, möss och stackmyror. Mössen stör bina i deras bikupa på vintern och äter deras honung. Stackmyror beskrev hon som mycket dödliga då en myrinvasion innebär att bisamhället dör inom 24–48 timmar om man inte agerar. Hon förklarade att hon stötte på stackmyror minst en gång per år och behövde då flytta på bikuporna i närheten. Svärmning är en annan viktig aspekt av biodling som diskuterades av Andrea, eftersom det kan ändra hela bisamhället då stor del av den lämnar bikupan, är det viktigt att kontrollera. Falsk svärmning kan förekomma och om drottningen inte lyckas para sig kan vid väldigt ovanliga fall arbetsbina lägga ägg, som endast resulterar i drönare. Vid sådana incidenter måste hela kupan bytas ut. Hon förklarade att som en yrkesbiodlare jobbar hon mer än 40 timmar per vecka under sommarhalvåret, medan under vinterhalvåret jobbar hon med att sköta om kuporna några timmar om veckan.

Sammanfattningsvis gav Andrea värdefulla insikter om biodling och betonade vikten av noggrann övervakning samt hantering för att säkerställa hälsosamma bisamhällen. Hon var väldigt intresserad av idén av smarta bikupor som kan underlätta samt effektivisera biodlingen för både hobby och yrkesbiodlare.

B Hårdvara

För presentation av bikipornas hälsa och skapandet av analyser behövdes data samlas från Ericssons kupor. Detta gjordes med hårdvara i form av sensorer, kameror och mikrodatorer som samlade in information som temperatur, vikt och ljud. Följande avsnitt beskriver den bakomliggande fysiken och tekniken som sensorerna bygger på.

Töjningsmätande lastcell

En töjningsmätande lastcell används vid mätning av vikt och omvandlar en pålagd kraft till en elektrisk signal. Sensorn består vanligtvis av en bit metall med fyra stycken trådtöjningsgivare monterade i en krets som kallas *wheatstone*-brygga. En trådtöjningsgivare är en elektrisk komponent som består av en tunn tråd eller folie. När komponenten sträcks ut blir tråden tunnare och längre, vilket ökar dess resistans. Denna ändringen i resistans mäts i wheatstone-bryggan och är proportionell till den pålagda kraften, som ger vikten på objektet. Vikten beräknas enligt:

$$m = \frac{F}{g} = \frac{\Delta R E A}{g G_F R_G} \quad (3)$$

Då E är lastcellens elasticitetsmodul, A är arean på lastcellen, G_F är töjningsfaktorn, R_G är trådtöjningsgivarens resistans och g tyngdaccelerationen.

Digital termometer med kiseldioder

De vanligaste digitala termometrarna bygger på en krets med två kiseldioder och en analog-till-digital omvandlare (ADC). Dioderna är kopplade i en Brokaw-bandgaps-referenskrets där framspänningen på dioderna är temperaturberoende. Temperaturen beräknas då genom att mäta spänningsskillanden mellan dioderna enligt:

$$T = \frac{\Delta V * q}{k_B \ln(\frac{I_1}{I_2})} \quad (4)$$

Då ΔV är spänningsskillanden över dioderna, q är elementarladdning, k_B är Boltzmanns konstant, I_1 och I_2 är strömmarna genom varje diod.

Luftfuktighetssensor

En digital hygrometer, eller luftfuktighetsmätare bygger på att vissa materials ledningsförmåga är beroende av temperatur och luftfuktighet. Sensorn mäter luftfuktigheten med en tunn platta av ett dielektriskt material, där permittiviteten är beroende av temperatur och luftfuktighet. Plattan är placerad mellan två elektroder och får en varierande kapacitans. För att lösa ut luftfuktigheten från den varierande kapacitansen har sensorn även en termistor, som är en temperaturberoende resistans, som mäter temperaturen.

MEMS-mikrofon

En MEMS-mikrofon (mikroelektromekanisk system-mikrofon) omvandlar en ljudsignal till en analog elektrisk signal [53]. Ett litet membran utgör en av plattorna i en kondensator, så när det sätts i rörelse

av ljudvågor blir detta till en motsvarande ändring av spänningen i kretsen. Denna spänning filtreras och förstärks sedan analogt.

Digitalkamera

En digital kamera samlar in bilddata genom att omvandla ljus-intensitet och dess våglängd till elektriska signaler [54]. CMOS-sensorn är en av de vanligaste sensorerna som används i digitalkameror. Sensor består miljontals pixlar som format ett rutnät, då varje pixel är en fotodetektor. Varje fotodetektor består av tre fotodioder, som omvandlar en rött grönt eller blått ljus till en spänningsskillnad. Dessa signalerna förstärks sedan med en MOSFET-förstärkare och omvandlas till ett digitalt RGB-värde. Sensorn mäter endast ljusets röda, gröna och blåa ljusintensitet då de i additiv färgblandning kan skapa de andra färgerna.

C Beräkning av Mel-Frequency Cepstral Coefficients

MFCC som analys verktyg har inte en klar definition, utan kan beräknas på olika sätt [55]. Metoden har många ingående parametrar som samplingshastighet, fönsterstorlek och filterfunktioner, som alla påverkar koefficienterna. Beräkningen av MFCC görs däremot ofta på liknande sätt och kan sammanfattas med de följande fem steg.

- Ljudsignalen fourier-transformeras först enligt ekvation 3.1.1.
- Signalens effektspektrum tas sedan fram genom att kvadrera frekvens-funktionen

$$P(f) = |\hat{F}(f)|^2 \quad (5)$$

- Effektspektrumet skalas sedan om till Melfrekvens, som är en representation av hur människan uppfattar ljud [32]. Detta görs med följande funktion:

$$m(f) = 2595 \log(1 + f/100) \quad (6)$$

- Effektspektrumet multipliceras med en summa av filter funktioner ϕ som ofta består av jämt fördelade triangulära fönster.

$$F(m) = \sum_{n=1}^N P(m) \phi_n(m) \quad (7)$$

- Signalen logaritmeras sedan och det appliceras en diskret cosinus transform. Då l går över alla samplade amplituder.

$$MFCC[d] = \sum_{l=1}^L \ln(F(l)) \cos\left(\frac{\pi}{L} d(l - \frac{1}{2})\right) \quad (8)$$