



CHALMERS



Automatisering av biodlingsprocessen

Realtidsanalys med maskininlärning på sensordata från bikupor

Kandidatarbete vid Institutionen för fysik

Tuss Anzelius, Måns Josefsson, Lisa Samuelsson
Kevin Svensson, Filip Rydin, Lovisa Åkesson

Institutionen för fysik

CHALMERS TEKNISKA HÖGSKOLA
Göteborg, Sverige 2022
www.chalmers.se

BACHELOR'S THESIS 2022

Automation of the Beekeeping Process

Real-time analysis of sensor data from beehives using machine learning

Tuss Anzelius, Måns Josefsson, Lisa Samuelsson,
Kevin Svensson, Filip Rydin, Lovisa Åkesson

Abstract

As pollinators, bees are important contributors to the global food production and to the preservation of biodiversity. The aim of this project is to create a web application for beekeepers with which they can monitor their beehives. Such an application would reduce the workload of beekeepers and benefit the health of the bee colony. The final application presents data about the environment in the beehive (including weight, temperature and humidity) as well as indications of the presence of a queen bee, how many varroa mites are detected and if a swarm is occurring or is about to occur. The application uses sensors which were assembled on the beehive prior to the project. The sensors allow for continuous collection of data, which can be analyzed on a micro computer.

The project mainly focused on the development of three models. The machine learning model, ResNet50, used for mite detection was trained for different numbers of epochs, and its highest precision was calculated to be approximately 80%. Calculations of the model's F1-precision and F1-recall resulted in a maximal F1-value. The queen detection model uses two k-nearest neighbors models for analysis of sound. The models' precisions were determined to be 86,4% and 99,6% on test data, and when the whole program was tested on previously recorded data from the sensors, as well as in real time, only correct answers were given. For swarm detection an analytical model was developed based on set conditions for weight, temperature and weather. The model gave the correct result when tested with previously collected data from the beehive and with unit tests.

Further tests on real beehives will show how reliable the models are. The project has resulted in a functioning web application, where the models' classifications give an indication on the well-being of the beehive. The application can be used as a tool by beekeepers, and the aim of the project is therefore considered to be reached.



CHALMERS

Department of Physics
Hive Five

CHALMERS UNIVERSITY OF TECHNOLOGY
Gothenburg, Sweden 2022

Automatisering av biodlingsprocessen
Realtidsanalys med maskininläring på sensordata från bikupor

© Tuss Anzelius, Måns Josefsson, Lisa Samuelsson, Kevin Svensson, Filip Rydin, Lovisa Åkesson,
2022.

Handledare: Björn Wickman, Institutionen för fysik
Industrihandledare: Lars-Erik Lindberg, Ericsson
Examinator: Jan Swenson

Kandidatuppsats 2022 TIFX04-22-03
Institutionen för fysik
Chalmers tekniska högskola
Göteborg

Omslag: Bin på en vaxcellsvägg tagen av Meggyn Pomerleau. Hämtad från: <https://unsplash.com/>

Typsatt i L^AT_EX
Göteborg, Sverige 2022

Sammandrag

Som pollinatörer har bin en viktig roll då de säkerställer den globala livsmedelsproduktionen och bevarar den biologiska mångfalden. För att gynna bins välmående och minska biodlares arbetsbelastning är syftet med detta projekt att skapa en webbapplikation som biodlare kan använda för att övervaka sina bikupor. Den slutgiltiga applikationen innehåller information om miljön i den aktuella bikupan (inklusive vikt, temperatur och luftfuktighet) samt indikatorer på om en bidrottning finns i kupan, hur mycket varroakvalster som har detekterats samt om svärmning sker eller håller på att ske. Applikationen använder en sensoruppsättning som fanns innan projektets början. Denna uppsättning bygger på att data från sensorer samlas in och analyseras med en mikrodator.

Projektet har huvudsakligen fokuserat på utvecklingen av tre modeller. Maskininlärningsmodellen, ResNet50, för varroakvalsterdetektion analyserades vid olika antal tränade epoker, och dess högsta precision beräknades vara cirka 80 %. Uträkning av modellens F1-precision samt F1-känslighet resulterade i att F1-värdet blev maximalt. Bidrottningdetektion använder två k-nearest neighbors modeller för analys av ljud. Modellerna hade precisionen 86,4 % respektive 99,6 % på testdata och när hela programmet kördes på tidigare data från sensorerna samt i realtid indikerades korrekt svar i samtliga fall. För svärmdetektion utvecklades en analytisk modell baserad på bestämda villkor för vikt, temperatur och väder. Modellen testades med enhetstester och redan insamlad svärmdetektionsdata, och gav då korrekta utslag.

Fortsatt arbete med fler tester på verkliga bikupor kommer att visa hur pålitliga modellerna är. Projektet har resulterat i en fungerande webbapplikation där modellernas klassificeringar ger en indikation på bisamhällets välmående. Denna applikation kan användas som ett underlättande verktyg för biodlare, och projektets syfte anses därmed vara uppnått.

Förord

Vi vill rikta ett stort tack till våra handledare Björn Wickman och Lars-Erik Lindberg för deras kontinuerliga stöd och vägledning genom hela projektet. Vi vill även ge ett stort tack till Johan Nicander för alla kloka idéer och den tekniska supporten. Vidare vill vi tacka Björn Franzon för all hjälp med Ericsson OWL samt Marcus Petterson, Felicia Ekener och Felicia Ekenstam som tidigare arbetat med projektet. Slutligen vill vi tacka Jonas Wilhelmsson, Johan Bengtsson, Ingrid Evaldsson och alla andra som visat intresse för projektet.

Tuss, A. Måns, J. Lisa, S. Kevin, S. Filip, R. Lovisa, Å.

Innehåll

1	Inledning	1
1.1	Bakgrund	1
1.2	Syfte	1
1.3	Avgränsningar	2
2	Teori om bin och bisamhällen	3
2.1	Bin och bikupor	3
2.2	Året i bikupan	4
2.3	Miljön i bikupan	5
2.4	Varroakvalster	5
2.5	Bidrottningen	6
2.6	Svärmning	7
3	Teoretisk systembeskrivning	8
3.1	Hårdvara	8
3.2	Metoder och modeller för dataanalys	9
4	Systemets utformning och utveckling	15
4.1	Sensoruppsättning och dataflöde	15
4.2	Program för presentation av miljön i bikupan	16
4.3	Varroakvalsterdetektion med bildigenkänning	16
4.4	Bidrottningdetektion med KNN-klassificerare	18
4.5	Svärmningsdetektion med expertsystemsmodell	19
4.6	Utveckling av grafiskt gränssnitt för webbapplikation	20
5	Resultat	21
5.1	Presentation av miljön i bikupan	21
5.2	Resultat av varroakvalsterdetektion	21
5.3	Resultat av bidrottningdetektion	23
5.4	Resultat av svärmningsdetektion	24
5.5	Grafiskt gränssnitt för webbapplikation	24
6	Diskussion	26
6.1	Utvärdering av systemet	26
6.2	Samhälleliga och etiska aspekter	30
6.3	Utvecklingsmöjligheter för systemet	30
7	Slutsats	33
A	Viktmätning med lastceller och Wheatstonebrygga	I
B	Temperaturmätning med kiseldioder	II
C	Teoretisk fördjupning i metoder för dataanalys	III

1 Inledning

I takt med en växande världsbefolkning ökar ständigt behovet av livsmedel. Bin har en viktig men ofta bortglömd roll för livsmedelsproduktionen och den biologiska mångfalden. Av världens livsmedelsgrödor är 75 % beroende av olika pollinatörer, såsom bin [1]. Trots att pollineringen från bin har en sådan viktig roll riskerar 97 av Sveriges cirka 270 vilda biarter att dö ut [2]. På grund av detta blir det allt viktigare att värna om både vilda och tama bin.

År 2019 beräknades antalet biodlare i Sveriges Biodlares riksförbund vara drygt 14 000 [3]. Dessa biodlare stöter årligen på problem som kan leda till att deras bisamhällen dör. Med dagens teknik finns det en möjlighet att underlätta biodlares arbete och samtidigt rädda bisamhällena från att dö ut.

1.1 Bakgrund

En biodlares arbetsuppgifter utförs till största delen manuellt och många besök till bikupan krävs för att hålla uppsikt över bisamhällets hälsa. Dessa besök till bikupan är tidskrävande, vilket särskilt drabbar biodlare med många kupor. Med hjälp av sensorer på och i bikuporna skulle biodlare kunna få nödvändig information utan att behöva besöka dem.

Planeringen av en biodlares arbete kan underlättas genom tillgång till relevant information från sensorer. Det gör att antalet besök till kupan kan minska, vilket har flera fördelar för både biodlaren och bisamhället. Biodlaren sparar tid och pengar, och kan upptäcka samt åtgärda hälsoproblem i kupan tidigare. Färre besök i kupan leder också till att bisamhället inte behöver bli stört lika ofta, vilket kan ge ett starkare och mer resilient bisamhälle. Starkare bisamhällen kan i sin tur ge en ökad produktion av varor från bikupan såsom honung, bivax och bipollen. Större och hälsosammare bisamhällen är gynnsamt även ur ett samhällsperspektiv, då det leder till ökad pollinering, vilket har en positiv inverkan både på den biologiska mångfalden och på livsmedelsproduktionen [4].

Det här projektet utförs i samarbete med Ericsson, som sedan tidigare har initierat ett arbete med sensorer på och i bikupor. Två bikupor finns tillgängliga, båda utrustade med sensorer som mäter temperatur, luftfuktighet, vikt samt mikrofon och kamera för kontinuerlig datainsamling. Den ena bikupan är placerad på Ericssons kontor på Lindholmen och den andra i Bua Södra, HARRYDA. Redan insamlad data och dokumenterade händelser över två år tillbaka finns tillgängliga för analys.

1.2 Syfte

Syftet med projektet är att skapa en webbapplikation som, med hjälp av sensorer kopplade till en bikupa, presenterar information om kupan i realtid. Webbapplikationens grafiska gränssnitt ska vara lätt att förstå och använda. Ny teknik såsom sensorer och artificiell intelligens gör det möjligt att ta in information och utföra analyser som tidigare behövts göras manuellt.

Risker för bin såsom sjukdomar och parasiter kan upptäckas tidigare vid användning av tekniska lösningar, till exempel kan varroakvalster på bin upptäckas genom bildigenkänning. Sådant som innebär risker för biodlare och problem för bina, som exempelvis svärmning och avsaknad av drottning, kan upptäckas tidigare. Dessa två risker kan upptäckas genom analys av ljud, temperatur och vikt i kupan. Bikupans vikt ger även en indikation på honungsproduktionen, vilket kan användas för att veta när honungen går att skörda under sommaren och för att försäkra att

bisamhället har tillräckligt med foder på vintern. En kombination av bikupans vikt, temperatur och luftfuktighet kan ge en överblick över bisamhällets välmående. Genom att uppnå syftet med projektet underlättas därmed biodlares arbete. Istället för att undersöka bikupans tillstånd på plats kan biodlare få en klar bild av bikupans mående direkt från en webbapplikation i sin mobil eller dator.

1.3 Avgränsningar

Utöver de sensorer som fanns på och i bikuporna innan projektets start har inga ytterligare installerats eller använts. Data samlad från sensorerna har enbart använts för detektion av bidrottningen, varroakvalster och svärmning, samt för att ge en presentation av bikupans miljö. Av de detekterbara hälsostörningar som kan påverka bisamhällen är slutprodukten endast inriktad mot varroakvalster. Information om bidrottningens tillstånd är begränsat till drottningens nuvarande närvaro i bikupan. Besluten kring avgränsningarna grundades på beräknad arbetsbelastning samt tillgänglig träningsdata för maskininlärning. För att presentera miljön i bikupan används data som anses vara relevant för en biodlare utifrån de tillgängliga sensorerna. Detta gäller bikupans vikt, temperatur och luftfuktighet.


2 Teori om bin och bisamhällen

Detta avsnitt inleds med allmän information om bin och bikupor samt hur tiden på året påverkar bisamhället. Därefter presenteras teori kring de områden som webbapplikationen främst är riktad mot, vilket är miljön i bikupan, varroakvalster, bidrottningen och svärmning.

2.1 Bin och bikupor

I Sverige finns ca 270 olika biarter, och den art som används för biodling är honungsbiet (*Apis mellifera*) [2]. Ett bisamhälle består av ca 20 000–80 000 bin beroende på årstid och samhällets välmående [5]. I Figur 1 visas de tre typerna av bin som finns i ett bisamhälle: arbetsbi, drottning och drönare.


Vanligtvis finns endast en bidrottning i varje bisamhälle, vars främsta uppgift är att lägga ägg. Arbetsbina är honor och har uppgifter både i och utanför bikupan [5]. Exempel på arbetsuppgifter i kupan är matning av bilarver, renhållning och omvandling av nektar till honung. Utanför kupan samlar arbetsbina bland annat in nektar, pollen och vatten. Drönarna är hanbin, vars huvudsakliga uppgift är att para sig med en bidrottning från ett annat bisamhälle.



Figur 1: De tre typerna av bin i ett bisamhälle från vänster till höger: arbetsbi, drottning och drönare. Bilden är baserad på [6].


Honungsbin samlar in nektar och pollen för sitt energibehov, och nektarn är det som omvandlas till honung [5]. Honungen lagras i sexkantiga celler i de vaxkakor som bina bygger i bikupan. Arbetsbina producerar vax i vaxkörtlar som finns på undersidan av bakkroppen [7]. I cellerna läggs även binas ägg.

Bin tillhör de insekter som genomgår fullständig metamorfos, även kallat holometabol, vilket innebär att insekten genomgår fyra utvecklingsstadier [7]. De fyra stadierna visas i Figur 2 och är ägg, larv, puppa och slutligen färdig insekt. Metamorfosen, biets utveckling från ägg till insekt, sker i vaxcellerna i bikupan och tar cirka tre veckor [8]. Biägg som blir arbetare och drönare placeras i vaxceller som är mindre än de där drottningägg placeras. En larv kläcks ur ägget efter cirka tre dygn och ökar snabbt i vikt. Efter larvstadiet förpuppas larven och under denna period utvecklas biets kroppsdelar. Även efter äggen kläckts fortsätter bina att utvecklas i ytterligare några dagar.



Figur 2: De fyra stadierna i binas metamorfos är ägg, larv, puppa och insekt. Bilden är baserad på [9].

Det finns flera sorters bikupor som används av biodlare. En av de vanligaste sorterna är uppstaplingskupan, även kallad vandringskupa [7]. En fördel med uppstaplingskupan är att den kan byggas ut när bisamhället växer eftersom den består av flera lådor staplade på varandra. Ett exempel på hur en uppstaplingskupa kan vara uppbyggd ses i Figur 3. I lådorna finns så kallade ramar, vilka används för att göra vaxkorna som bina bygger stabila och lätthanterliga [10]. Kupans lådor har olika användningsområden [7]. I de så kallade skattlådorna lagras bina honungen, och det är från ramarna i dessa lådor som biodlaren skördar honungen, vilket kallas skattning. I yngellådan lägger bidrottningen sina ägg, och denna låda skiljs vanligtvis från skattlådorna som ligger ovanför med ett spärrgaller. Detta galler förhindrar drottningen att lägga ägg i ramarna som avses för honungen.




Figur 3: Exempel på hur en uppstaplingskupa kan se ut.

2.2 Året i bikupan

Aktiviteten i bikupan beror i hög grad på årets säsonger och en naturlig startpunkt för biåret är perioden september till december, då bina förbereder sig inför vintern. Att överleva vintern är en stor utmaning för bisamhället och det gör denna perioden avgörande för hur välmående kupan kommer vara under det nästkommande kalenderåret [11]. Ett sätt att följa biårets stora förändringar i biantal är genom kupvägning som exemplifieras i Figur 4. En strategi som bina använder för att överleva vintern är att minska produktionen av biyngel, vilket förlänger varaktigheten av kupans matförråd [12]. En annan överlevnadsstrategi är att producera vinterbin som tack vare skillnader i beteende och fysiologi kan överleva hela vintern [13]. Genom populationsminskning och ökad resiliens hos de återstående bina möjliggörs skapandet av ett vinterklot i kupan. Ett vinterklot består av tätt packade bin som arbetar tillsammans för att värma upp sig själva. Klotbeteendet brukar ske när temperaturen underskrider 10°C och pågår tills temperaturen ökar igen under våren [12]. Tidpunkten när bina lämnar kupan efter vintersäsongen beror på klimatet utanför kupan.

Vårens ankomst markerar starten av bisamhällets återuppbyggnad efter vinterns förluster. Återbyggnaden avspeglas i Figur 4 där vikten, som till stor del utgörs av vikt från bin och den producerade honungen, stiger kraftigt. Då fokuserar bina på att hämta pollen och nektar som kan mätta bisamhällets växande population. Framåt juni och juli når kupan sin maximala populationsnivå. Denna minskar sedan under augusti och september månad.



Figur 4: Illustration av den genomsnittliga vikten hos bikupor i ett stickprov av danska bikupor från år 2010 till 2013. Vikten ger ett mått på aktiviteten i kupan eftersom den bland annat består av binas och honungens vikt. Grafen är baserad på Figur 4 från [14].

2.3 Miljön i bikupan

För att kunna överleva biåret reglerar bina noggrant miljön i bikupan. Två av de kända kuppparametrarna som bina reglerar är temperaturen och luftfuktigheten [15]. När någon av parametrarna avviker från optimala omständigheter samarbetar bina i ett decentraliserat system för att åtgärda situationen. Kommunikationen mellan dem sker då med hjälp av danser och feromoner (doftämnen).

När bikupan är för varm koordinerar bina en nedkylning av kupan. Små avvikelser möts av fläktning av luft från bivingar medan större temperaturförändringar leder till att bina simulerar processen hos en förågningskylare. Då skapas luft som är sval och fuktig i kupan genom att en grupp bin fläktar varm luft genom vattendroppar som en annan grupp bin släpper ned från kupans tak. En förebyggande åtgärd mot uppvärmning av kupan är att bina placerar sig utanför kupan och agerar värmesköld vilket gör att värmen istället absorberas i deras kroppar.

Givet att bikupan istället är för kall använder sig bina av vinterklotsbeteende. Vid tillräckligt låg temperatur samlas bina i ett klot, vilket underlättar uppvärmning genom minskad volym. Om uppvärmningen inte är nog genererar bina även värme från rörelseenergin av binas rysningar [15].

Luftfuktigheten kontrolleras också med hjälp av koordination av en mängd bin. Processen börjar med att bina fläktar in kall och torr luft mot kupans mitt som värms upp och blir fuktig. Efter det fläktas luften ned mot den kalla luften vid kupans botten och fuktas den. Slutligen värms den fuktiga luften vid botten av kupan till torr luft som fläktas in i kupans mitt. Genom att balansera luftfuktighetsnivån kan biägg utvecklas och nektar kan konverteras till honung utan skadliga konsekvenser såsom mögel [15], [16].

2.4 Varroakvalster

Varroakvalstret (*Varroa destructor*) är en parasit som sedan slutet av 1980-talet har spridit sig bland svenska bin [17]. Parasiten utgör ett stort hot för bina och kan i värsta fall leda till en total kollaps av bisamhället. I en drabbad kupa försvagas vuxna bin genom att varroakvalstret

suger binas hemolymfa som distribuerar näring i bikroppen [18]. De öppna sårn som lämnas på biet och dess allmänt nedsatta kroppstillstånd är bidragande faktorer till att biet löper större risk att smittas av sjukdomar [18]. Sjukdomarna kan komma från omgivningen eller från varroakvalstrets smittbärande saliv.

Spridning av varroakvalster kan ske både inom och mellan bisamhällen. Smittan mellan bin påbörjas genom att parasiten lägger ägg i en cell med ett biyngel inuti [19]. När varroaäggen så småningom kläcks och börjar utvecklas till vuxna livnär de sig på ynglet. Varroakvalstren fortsätter att föröka sig tills det färdigutvecklade biet överger sin cell. Då följer varroahonorna med biet på dess kropp och lämnar kvar resterande varroakvalster i cellen. Varroahonornas överlevnad möjliggör vidare spridning genom att de antingen flyttar mellan bin vid direkt kontakt eller att de påbörjar en ny förökningsprocess i en av samhällets celler. Förmågan att förflytta sig mellan bin är en orsak till varroaspridning mellan bisamhällen. Oförsiktig flytt och försäljning av sjuka bin är en annan orsak [18].

Det finns olika sätt att diagnostisera hur allvarligt drabbad en bikupa är av varroakvalster. Två metoder som kan användas är nedfallsundersökning och skakning med alkohol [20]. I en nedfallsundersökning placeras ett varroainlägg underst i kupan som visar hur många varroakvalster som har dött och sedan fallit ned. Antalet döda varroakvalster per dag ger ett mått på spridningen i bikupan. Vid skakning med alkohol placeras ett stickprov med bin i en burk innehållande alkohol. Genom att skaka burken faller varroakvalstren av bina och antalet varroakvalster i burken används för att uppskatta angreppsgraden. Det är viktigt att diagnostisera kuporna regelbundet, speciellt under yngelsäsongen [21]. Anledningen till detta är att ett okontrollerat angrepp av varroakvalster i extrema fall kan öka explosionsartat givet att det finns många celler för parasiterna att föröka sig i.

Ett alternativt sätt att diagnostisera en bikupas angreppsgrad är genom upprepade observationer. Detta möjliggörs av att varroahonorna är stora nog att se med ögat. Det som talar för metoden är att regelbundna tester kan genomföras som dessutom är skonsamma mot bina i jämförelse med till exempel skakning med alkohol. Ett problem är dock att få biodlare har tid att studera alla sina bin och kupor så ofta som krävs. Ett ytterligare problem är att biodlaren måste öppna kupan för att kunna genomföra observationen. När kupan är öppen störs bina och beroende på klimat och tid på året kan de även bli nedkylda. För att undvika den negativa inverkan på bina och för att minska tiden som hade behövt läggas på övervakning hade observationerna istället kunnat genomföras automatiskt med hjälp av kameror.

2.5 Bidrottningen

Eftersom drottningen är det enda biet i bisamhället som kan lägga befruktade ägg, det vill säga ägg som kan utvecklas till arbetsbin eller drottningar, är drottningen nödvändig för bisamhällets överlevnad och expansion [7]. Drottningen flyger ut en gång i livet kort efter sin födsel för att para sig och stannar därefter, undantaget svärmning, i kupan. Där kan den leva i cirka tre till fem år.

I varje bisamhälle finns vanligtvis en drottning, som ersätts när dess ägglägningsförmåga försämras [22]. Om drottningen plötsligt skulle försvinna eller dö, exempelvis som en följd av sjukdom, inkräktare i kupan eller biodlarens felhantering, kommer arbetsbina påbörja uppfödandet av en ny drottning. Ibland kan emellertid kupan misslyckas med att föda upp en ny drottning. Mängden produktiva bin i kupan kommer då minska tills dess att bisamhället dör ut. Även samhällets motståndskraft mot sjukdomar minskar när det inte finns en äggläggande

drottning närvarande.

För att detektera bidrottningen letar en biodlare vanligtvis efter ägg och larver, vilka indirekt tyder på att en fertil drottning finns i kupan [7]. Det finns också en tydlig visuell skillnad mellan drottningen och arbetsbin (se Figur 1), vilket gör att en biodlare manuellt kan leta efter drottningen i kupan. En vanlig metod för att lättare kunna urskilja drottningen är att färgmärka den. Genom att göra detta kan biodlaren också avgöra om det är samma drottning de ser eller om en ny har ersatt den gamla sedan förra gången kupan besöktes. För att automatisera detektionen av bidrottningen kan ljud från bikupan användas. När en drottning finns i kupan avger den feromoner och vid avsaknad av dessa surrar bina på ett annat sätt än om drottningen är närvarande [23], [24]. Detta surrande karakteriseras av ett annorlunda frekvensinnehåll, och kan beskrivas som mer stressat än det vanliga surrandet.

2.6 Svärmning

Svärmning är ett fenomen som uppstår i bisamhällen och innebär att en andel av ett samhälle flyttar från sin befintliga kupa och bosätter sig på ett nytt ställe [8]. Detta är binas naturliga sätt att föröka och utbreda sig på. Anledningar till att en svärmning sker kan vara att den befintliga kupan börjar bli för trång eller att den befintliga drottningen börjar bli gammal.

När ett bisamhälle förbereder sig inför svärmning föder bina upp nya drottningar i så kallade svärmceller eller drottningceller [8]. När nya bidrottningar (eller andra typer av bin) föds upp reglerar bina temperaturen i bikupan och håller den konstant omkring 34–35 °C. Bisamhället är sedan sysslolöst tills att drottningcellerna täcks, med andra ord förpuppas som i Figur 2, vilket sker efter cirka nio dygn. Täckningen av drottningcellerna utlöser svärmen. Innan bina flyger ut behöver de värma upp sina flygmuskler, vilket leder till att temperaturen kan stiga till 39 °C i kupan [25]. Vid klart väder flyger sedan ungefär hälften av bisamhället ut och sätter sig i en klunga i närheten [8]. Spejarbin flyger därefter ut och letar efter ett passande ställe att bygga upp ett nytt samhälle på. När de återvänder tar de med sig resten av svärmen till den nya platsen och redan efter någon timme har bina byggt upp vaxceller i det nya bisamhället.

Svärmning är problematiskt för biodlare eftersom det innebär att en stor andel av ett bisamhälle kan flytta bort och gå förlorat [8]. Biodlare är därför intresserade av att upptäcka och förhindra svärmar i förtid genom att bygga ut bikupan eller dela upp samhället kontrollerat. Att upptäcka en svärm i förtid är mycket tidskrävande eftersom biodlaren manuellt behöver se över sin kupa ungefär en gång i veckan under svärmsäsongen, från början av maj fram till midsommar, och se om det finns svärmceller. Om en svärmning redan pågår har biodlaren ont om tid att fånga in bina igen och placera dem i en kupa innan de flyger bort. Det kan annars vara väldigt svårt att lokalisera svärmen när de hittat ett nytt ställe och börjat bygga upp ett nytt samhälle.

En svärmning kan detekteras i förtid genom att övervaka temperaturen för att upptäcka en temperaturreglering, och därefter se om det är svärmceller som temperaturregleringen sker för. Den skulle även kunna upptäckas genom analys av vikten eftersom bisamhället sitter sysslolöst en tid innan svärmning, vilket gör att vikten bör vara relativt konstant. En pågående svärmning skulle kunna identifieras av förändringar i vikt, ljud och temperatur. Vikten minskar drastiskt då halva bisamhället lämnar kupan medan ljudvolymen och temperaturen ökar.

3 Teoretisk systembeskrivning

I följande avsnitt beskrivs den hårdvara som använts i projektet, samt teorin bakom de modeller och metoder som använts för att möjliggöra analys av data från denna hårdvara.

3.1 Hårdvara

För att kunna detektera och analysera de fenomen som beskrivits i tidigare avsnitt används hårdvara i form av sensorer, kameror och mikrodatorer. Hårdvaran samlar in information om olika parametrar såsom temperatur, vikt och ljud, som sedan analyseras. Följande avsnitt beskriver hur hårdvaran fungerar ur ett fysikaliskt och tekniskt perspektiv.

3.1.1 Töjningsmätande lastcell

En töjningsmätande lastcell används för viktmätning och består vanligtvis av en metallkropp med fyra trådtöjningsgivare monterade i en elektrisk krets kallad Wheatstonebrygga [26]. En trådtöjningsgivare är en elektriskt ledande komponent med resistans som ändras när den deformeras [27]. Lastcellen mäter vikt utifrån trådtöjningsgivarnas resistansförändring ΔR , vilken kan beräknas från Wheatstonebryggan, då de påverkas av en kraft. Utifrån resistansförändringen kan den pålagda kraften F på lastcellen beräknas. Från denna kan den pålagda vikten m slutligen beräknas enligt

$$m = \frac{F}{g} = \frac{\Delta R E A}{g G_F R_G} [\text{kg}], \quad (1)$$

där E är lastcellens elasticitetsmodul, A är lastcellens area, G_F är töjningsfaktorn, R_G är trådtöjningsgivarnas egna resistans och g är tyngdaccelerationen. För härledning av Ekvation (1), se Bilaga A.

3.1.2 Digital termometer med kiseldioder

En av de vanligaste digitala termometrarna består av en integrerad krets med två kiseldioder och inbyggd analog-till-digital-omvandlare (ADC). Den mäter temperatur genom att utnyttja att framspänningen hos två kiseldioder kopplade i en Brokaw-bandgaps-referenskrets är temperaturberoende [28]. Temperaturen kan då beräknas genom att mäta en spänningsskillnad ΔV_{BE} mellan de två dioderna i kretsen enligt

$$T = \frac{\Delta V_{BE} \cdot q}{k_B \cdot \ln\left(\frac{I_{C1}}{I_{C2}}\right)} [\text{K}], \quad (2)$$

där q är elementarladdningen, k_B är Boltzmanns konstant och I_{C1} samt I_{C2} är strömmarna som går genom vardera diod. För härledning av Ekvation (2), se Bilaga B.

3.1.3 Kapacitiv fuktighetssensor och termistor

En kapacitiv fuktighetssensor kan med hjälp av en termistor användas för att mäta luftfuktighet. En termistor är en typ av halvledare vars elektriska motstånd förändras med temperaturen [29]. Den kapacitiva fuktighetssensorn mäter luftfuktigheten med hjälp av en tunn platta, bestående av ett hygroskopiskt dielektriskt material, placerad mellan två elektroder [30]. Materialets kapacitiva förmåga är beroende av både temperaturen och luftfuktigheten, och påverkar spänningen mellan elektroderna. Genom att mäta temperaturen med termistorn samt strömmen som passerar materialet är det möjligt att ta fram värdet för den omgivande luftfuktigheten.

3.1.4 MEMS-mikrofon

En MEMS-mikrofon (mikroelektromekaniskt system-mikrofon) fungerar genom att ett mikrometerstort membran som utgör ena plattan i en kondensator sätts i rörelse av ljudvågor [31]. När avståndet mellan kondensatorplattorna ökar eller minskar ändras kapacitansen, vilken ger upphov till spänningsändringar i kretsen. Denna elektriska signal förstärks därefter och filtreras analogt.

3.1.5 Mikrodata

En mikrodata har en mikroprocessor, där all logik och alla operationer utförs på en eller ett fåtal integrerade kretsar [32]. Mikrodatarens minne består av halvledarchip där varje binär bit lagras via en eller flera transistorer på en så kallad minnescell. De få integrerade kretsarna gör en mikrodata liten till storleken, med sidlängder ofta kortare än en decimeter. Trots en mikrodatarens storlek, har den processorkraft att utföra avancerade datauppgifter. För att jämföra datarens databehandlingskapacitet kan GFLOPS användas, vilket är antal miljarder flytopperationer dataren utför per sekund [33]. För jämförelse utför mikrodataren av modell Raspberry Pi v4 B från år 2019 13,5 GFLOPS medan mobiltelefonen av modell Iphone 11 Pro från samma år utför 736 GFLOPS [34], [35].

3.1.6 Digitalkamera med CMOS-sensor

En digitalkamera använder bildsensorer för att omvandla ljusintensitet till elektriska signaler. En vanlig typ av bildsensor är en kompletterande metalloxid-halvledarsensor (CMOS). En CMOS-sensor är uppbyggd av miljontals pixelsensorer som har varsin fotodetektor [36]. När en bild tas öppnas kamerans bländare och ljus passerar genom kameralinsen. Ljuset riktar mot CMOS-sensorn vilket får fotodetektorerna att bygga upp en elektrisk spänning baserad på ljusets egenskaper såsom intensitet och våglängd. Laddningen vid varje pixelsensor kan därefter omvandlas till enskilda nummer. Datan som representerar varje fotografi kan sedan överföras via kabel direkt till en mikrodata [37].

3.2 Metoder och modeller för dataanalys

För att analysera datan som samlas in av sensorerna som beskrivits i föregående avsnitt används ett antal olika metoder. Följande avsnitt presenterar teorin bakom de metoder och modeller som används för dataanalys.

3.2.1 Savitzky-Golay filtrering

Savitzky-Golay filtrering är en vanlig metod för brusreducering av diskreta signaler [38]. Fördelarna med metoden är att den tenderar att bevara höjd och bredd hos toppar samtidigt som den minskar högfrekvent brus. Filtringen bygger på att det nya värdet i varje datapunkt ges av ett polynom av grad k , som anpassas till den aktuella datapunkten samt de $2m$ närmaste datapunkterna genom minstakvadratmetoden. Det går att visa att denna beräkning i praktiken motsvarar en viktad medelvärdesbildning. Se Bilaga C för ytterligare teori kring Savitzky-Golay filtrering.

3.2.2 Kromagram och mel frequency cepstrum

Kromagram och mel frequency cepstrum (MFC) är två verktyg som kan användas vid analys av signaler i allmänhet och ljudsignaler i synnerhet. Båda verktygen bygger på användning av Fourieranalys för att beräkna karakteristiska egenskaper hos en signal. Dessa egenskaper kan

sedan fungera som grund för klassificering med olika maskininlärningsalgoritmer.

Kromagram används ofta vid analys av musik för att exempelvis klassificera vilken genre musiken tillhör. Verktøget bygger på indelning av frekvensskalan i områden baserat på ton. Vanligtvis används de tolv tonerna C, C#, D, D#, E, F, F#, G, G#, A, A# och B [39]. Under ett lämpligt tidsfönster beräknas andelen av ljudets energi som ligger i respektive frekvensområde, vilket ger ljudets toninnehåll. Om toninnehållet därefter plottas över tid erhålls ett kromagram. För en fullständig genomgång av hur kromagrammet för en signal kan beräknas, se Bilaga C.

MFC, som representeras av mel frequency cepstra coefficients (MFCC:s), är ett verktyg som ofta används vid automatisk taligenkänning. Cepstrumet för en signal utnyttjas för att förstå periodiska strukturer i spektrumet, exempelvis ekon och övertoner, och kan beräknas genom att Fouriertransformera signalens logaritmerade spektrum [40]. Idén bakom MFC är att först omvandla spektrumet till mel-skalan och därefter bilda cepstrumet [41]. Mel-skalan är en empiriskt härledd frekvensskala i vilken den av människan upplevda frekvensskillnaden mellan två toner är proportionell mot den faktiska frekvensskillnaden. För en fullständig genomgång av hur MFCC:s för en signal kan beräknas, se Bilaga C.

3.2.3 Väglett lärande inom maskininläring

Artificiell intelligens är ett område inom datateknik där maskiners förmåga att visa mänskliga drag tränas upp [42]. Ett område inom artificiell intelligens är maskininläring, vilket använder algoritmer för att lära ett datorprogram att känna igen mönster och dra slutsatser om data. Genom att träna en maskininlärningsmodell på ett dataset kan modellen lära sig klassificera datan att tillhöra olika klasser. Maskininläring kan delas upp i olika kategorier baserat på hur modellen lär sig. En sådan kategori är väglett lärande (supervised learning), där klasserna som modellen ska identifiera är anmarkerade i den data som används för att träna modellen.

Datan som används vid väglett lärande kan delas in i tre set: träning, validering och test [43]. Träningssetet används för att träna modellen att känna igen de givna parametrarna som definierar vilken klass datan tillhör. Efter träningssetet används valideringssetet för att evaluera modellens precision under träningen. Detta görs för att kunna korrigera eventuella inställningar i modellen. Till sist används testsetet för att göra en slutgiltig evaluering av modellens precision. Validerings- och testsetet innehåller därmed data som modellen inte sett under träning och därför inte lärt sig något från. Denna uppdelning av dataseten görs för att evaluera modellens förmåga att känna igen generella mönster.

För att värdera en modells prestation är det inom maskininläring vanligt att utgå från ett F1-värde [44]. Detta värde är ett harmoniskt medelvärde av en modells F1-känslighet (recall) och F1-precision (precision). För att beräkna detta benämns datasetets klasser som antingen ”positiva” eller ”negativa”. När en modell klassificerar en positiv klass som positiv kallas detta sant positivt (true positive). I kontrast sker en falsk positiv (false positive) klassificering när modellen felklassificerat en negativ klass som positiv. Analogt finns sanna negativa (true negative) samt falska negativa (false negative) klassificeringar.

F1-känsligheten beskriver hur stor del av det positivt klassade datasetet som modellen faktiskt klassificerar som positivt. Detta beräknas genom att ta hänsyn till antalet gånger modellen klassificerar sant positivt (TP) och falskt negativt (FN) enligt

$$\text{F1-känslighet} = \frac{\text{TP}}{\text{TP} + \text{FN}}.$$

F1-precisionen beskriver hur stor del av alla positiva klassificeringar modellen gör som faktiskt är positiva. Detta beräknas enligt

$$\text{F1-precision} = \frac{\text{TP}}{\text{TP} + \text{FP}},$$

där antalet gånger modellen klassificerar sant positivt (TP) och falskt positivt (FP) används. Genom att kombinera F1-precisionen och F1-känsligheten beräknas ett F1-värde enligt

$$\text{F1-värde} = 2 \cdot \frac{\text{F1-precision} \cdot \text{F1-känslighet}}{\text{F1-precision} + \text{F1-känslighet}}.$$

Ett F1-värde ligger mellan 0 och 1, där ett högt värde indikerar att modellen presterar väl.


En sammanblandningsmatris (confusion matrix) innehåller värden som visar på klassificeringsnoggrannheten av en maskininlärningsmodell [45]. Varje kolumn i matrisen motsvarar en faktisk klass medan raderna motsvarar modellens klassificeringar. Varje rad i matrisen visar fördelningen av hur modellen har klassificerat all data av en viss klass. En sammanblandningsmatris för en modell utan felklassificeringar har nollor överallt förutom matrisens huvuddiagonal. Tabell 1 visar mallen för en binär sammanblandningsmatris där motsvarande modell har en positiv och en negativ klass.

Tabell 1: Mall för en binär sammanblandningsmatris där klasserna är positiv respektive negativ.

		Faktisk klass	
		Positiv	Negativ
Modellens klassificering	Positiv	TP	FP
	Negativ	FN	TN

3.2.4 Artificiella neurala nätverk för bildigenkänning

En gren inom maskininläring är artificiella neurala nätverk [42]. Namnet och strukturen av ett sådant nätverk är inspirerat av den mänskliga hjärnan, där neuroner signalerar information mellan varandra. Ett vanligt användningsområde för ett neuralt nätverk är bildigenkänning, där modellen som skapas från nätverket kan lära sig att klassificera bilder. Egenskapen att extrahera information från bilder tränas genom att bearbeta data i olika lager. Ett nätverk med fler än tre lager kallas för ett djupt neuralt nätverk och sådana nätverk kan i sin tur delas upp i olika kategorier baserat på deras arkitektur. En sådan kategori är ett convolutional neural network (CNN), vilket är en djupinlärningsmodell som lär sig genom väglett lärande. En översiktlig bild av ett CNNs arkitektur illustreras i Figur 5.



Figur 5: En generell illustration över arkitekturen av ett CNN. Indatan är pixelvärden i bilden som analyseras. Datan passerar ett convolutional lager, en ReLU-funktion samt ett pooling lager. Till sist görs datan om till en vektor som skickas in i ett fully connected lager. Bilden är baserad på [46].

Som Figur 5 visar är indatan till nätverket en matris vars element representerar pixelvärden i bilden som analyseras [46]. Det första steget i nätverket, efter den vänstra gröna pilen i figuren, är ett convolutional lager, vilket används som filter för att extrahera olika egenskaper från bilden. Filtret är en matris som opererar på indatan genom att utföra en skalärprodukt över varje enskilt element i indatamatrisen. Resultaten av skalärprodukten blir en ny matris som passerar en aktiveringsfunktion, vilket används för att introducera icke-linjäritet i modellen. Detta är nödvändigt i en modell vars utdata inte varierar linjärt med indatan. En vanlig aktiveringsfunktion är rectified linear unit (ReLU), vilken opererar genom att sätta negativa värden till noll enligt $\text{ReLU}(x) = \max(0, x)$. Funktionen är illustrerad i en graf ovanför den vänstra orangea pilen i figuren.

Nästa lager i nätverket, efter den mittersta gröna pilen i Figur 5, är ett så kallat pooling lager. Lagret används för att minska risken för överanpassning, vilket sker när modellen tar hänsyn till för många detaljer i datan. Detta kan resultera i att modellen lär sig känna igen parametrar som är unika för datan den tränas på. En överanpassad modell kan därmed få högre precision vid träning än vid validering och testning. Pooling utförs med hjälp av nedsampling, vilket görs genom att minska dimensionen av den inkommande datan. Då dimensionen minskas förstärks kontrasterna i datan och detaljer försummas.

Efter pooling omvandlas matrisen till en vektor, vilket illustreras ovanför den högra orangea pilen i Figur 5. Vektorn tas in i ett fully connected lager, efter den högra gröna pilen i figuren, som består av flera noder. Varje nod kan ses som en egen linjär regressionsmodell som använder sig av inkommande data, vikter och tröskelvärde. När ett visst värde i regressionsmodellen är uppnått, aktiveras noden och data passerar vidare till nästa lager. Vikterna anger hur stor betydelse de olika egenskaperna i datan har, och tröskelvärdet sätter en gräns för när noder aktiveras. Resultatet från fully connected lagret blir en vektor $\vec{z}$ med n element [47]. Vektorn passerar till sist en softmax funktion enligt

$$P(K|z_i) = \text{softmax}(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^n e^{z_j}},$$


vilket anger indatans sannolikhet att tillhöra en klass K givet en viss utdata z_i . Resultatet

blir en vektor med n element vars summa adderas enligt $\sum_{i=0}^n \text{softmax}(\vec{z})_i = 1$, för att ge en total sannolikhet. Varje analyserad bild tilldelas därmed en klassificering samt en sannolikhet att tillhöra denna klass. Vid träning av modellen används träningssetet och antalet gånger som hela setet passerar nätverket räknas i så kallade epoker.

3.2.5 Residualt CNN

Gradientpropagation (backward propagation of errors) är en algoritm som används i ett artificiellt neuralt nätverk vid väglett lärande [48]. Algoritmen beräknar gradienten av nätverkets felfunktion med avseende på nätverkets vikter. Ett nätverks felfunktion beskriver skillnaden mellan modellens klassificering och datans verkliga klass. Från gradienten kan vikternas värde kontinuerligt justeras under träning av modellen. Målet med detta är att anpassa vikternas värden för att minska felfunktionen och därmed öka modellens precision.

För att öka precisionen av ett CNN kan även fler lager användas [49]. När för många lager läggs till kan det däremot leda till att gradienten blir så liten att justeringen av vikterna blir minimal. Problemet kallas för degradering, och det kan hindra nätverket från att lära sig. Ett sådant nätverk har ett maximalt precisionsvärde, och efter detta värde är uppnått minskar precisionen kontinuerligt. För att undvika degradering kan ett residualt neuralt nätverk (ResNet) användas. Ett ResNet är ett CNN som använder sig av genvägar för att hoppa över vissa lager, vilket illustreras i Figur 6.




Figur 6: Figur av ett residualt CNN. Indatan x hoppar över vissa viktade lager enligt den orangea pilen. Vad modellen lärt sig under lagren, $F(x)$, adderas med indatan efter lagren.

Om x är datan innan lagren och $F(x)$ är funktionen som beskriver vad modellen lärt sig genom lagren, är $H(X) = F(X) + x$ funktionen som innehåller genvägen. Genom att hoppa över lager behöver modellen enbart lära sig vad som blir kvar, residualen, när man subtraherar indatan x från utdatan enligt $F(x) = H(x) - x$. Med hjälp av denna metod förenklas nätverket och risken att information i data försvinner minimeras.

För att anpassa en modell till ett dataset och för att minska fel i varje träningssteg kan modellen optimeras. En vanlig optimeringsmetod inom maskininlärning är stokastisk gradientnedstigning (SGD) [50]. SGD är en iterativ algoritm som används för att hitta ett lokalt minimum av en differentierbar funktion. Algoritmen anpassar sig efter faktorer såsom inlärningstakt och vikter, som väljs när modellen definieras.

3.2.6 K-nearest neighbors

K-nearest neighbors (KNN) är en enkel maskininlärningsalgoritm som kan användas för klassificeringsproblem, och visualiseras i Figur 7 [51]. Algoritmen använder väglett lärande för att kunna klassificera nya datapunkter. Ett euklidiskt avstånd mellan två datapunkter kan beräknas utifrån deras koordinater, vilket ger ett mått på hur lika datapunkterna är. Grannarna till en ny datapunkt motsvarar de datapunkter som är närmast utifrån deras euklidiska avstånd. Den nya datapunkten klassificeras genom att tilldela den samma klass som majoriteten av datapunktens k närmaste grannar. En KNN-modell tränas genom att lägga till fler annoterade datapunkter, vilka agerar som grannar vid klassificering av nya datapunkter.



Figur 7: Illustration av k-nearest neighbors-algoritmen för datapunkter med två parametrar, x och y . Den röda punkten klassificeras utifrån de tre närmaste grannarnas klasser.

Figur 7 visar klassificeringsprocessen av KNN för tvådimensionella datapunkter där deras klasser motsvarar färg. I detta fall klassificeras den nya datapunkten, markerad med röd färg, efter den dominerande klassen av de tre närmaste grannarna, alltså är $k = 3$. Eftersom majoriteten av de tre närmaste grannarna är orangea klassificeras datapunkten till den orangea klassen. Samma process fungerar även för data i fler dimensioner.

3.2.7 Expertsystem

Kunskapsbaserade system är ett samlingsnamn för olika typer av datorprogram som använder en kunskapsbas som grund för beslutsfattande [52]. En typ av kunskapsbaserat system är expertsystem, vilket är en form av artificiell intelligens som med hjälp av fördefinierade regler baserade på fakta kan fatta beslut och dra slutsatser. Ett exempel på ett område där expertsystem används är medicinsk diagnos, där indata i expertsystemet är olika symtom en patient har och utdata är en sjukdomsdiagnos.


För att skapa ett expertsystem krävs insamling och sammanställning av information om området, vilket kan vara en tidskrävande process. Däremot är expertsystem ofta relativt enkla att förstå. När många andra typer av artificiell intelligens används, till exempel neurala nätverk, kan en svårighet vara att förklara varför en slutsats dras och hur modellen kommer fram till denna slutsats. Detta undviks med expertsystem. Eftersom reglerna är fördefinierade är det nämligen enkelt att spåra hur och varför en slutsats fattades. Även personer med begränsad kunskap om programmering och artificiell intelligens har möjlighet att förstå hur ett expertsystem är uppbyggt.

4 Systemets utformning och utveckling

Följande avsnitt inleds med att presentera vilka sensorer som används för datainsamling och hur dataflödet går från sensorerna till webbapplikationen. Vidare presenteras hur programmet för presentation av miljön i bikupan fungerar. Därefter beskrivs projektets största fokusområden, de tre modellerna med tillhörande program som skapades för att detektera de fenomen som beskrivs i avsnitt 2.4–2.6. Slutligen beskrivs hur det grafiska användargränssnittet, som presenterar en överskådlig bild över tillståndet i bikupan, skapades.

4.1 Sensoruppsättning och dataflöde


För insamling av data som senare analyseras i olika modeller har Ericsson två bikupor som är identiskt utrustade med sensorer enligt Figur 8. För att mäta vikten används fyra töjningsmätande lastceller kopplade till en ADC (HX711). För temperaturmätning används sex digitala termometrar (ds18b20) och för luftfuktighetsmätning används en kapacitiv luftfuktighetsmätare (AM2302). En digitalkamera med CMOS-sensor (Raspberry Pi Camera v2.1) är riktad mot ingången till bikupan och under kupan sitter en MEMS-mikrofon (SPH0645LM4H). Alla sensorer är kopplade till en mikrodator (Raspberry Pi).



Figur 8: Schematisk bild över sensorernas placering. Tre termometrar i varje låda är placerade mellan lådornas ramar och en luftfuktighetsmätare sitter under täckskivan. Fyra lastceller är placerade under varje ben på bikupan och en kamera är riktad mot bikupans ingång. En mikrofon är placerad under kupan.

Projektets översiktliga dataflöde visas i Figur 9. Samtliga sensorer initieras och kalibreras med Pythonkod som körs på mikrodatorn. Sensorerna är programmerade att ta nya mätvärden var tionde minut och skicka dessa till mikrodatorn, där datan bearbetas och analyseras. Tidsintervallet anses vara tillräckligt kort för att hinna detektera om något ovanligt pågår i bikupan, samtidigt som överflödiga data undviks och prestanda på mikrodatorn sparas. Nya värden skickas från mikrodatorn via ett modem av typen Telit ME910C1 till externa servrar, där datan lagras. Datan presenteras sedan för användaren på en instrumentpanel som kan nås via webben.

Ericsson OWL är en webbapplikation som används för att lagra data och skapa digitala instrumentpaneler. Amazon SageMaker och Amazon S3 är webbtjänster som tillhör Amazon Web Services (AWS). Amazon SageMaker användes som programmeringsmiljö för att utveckla maskininlärningsmodeller och har tillgång till data lagrat i Amazon S3, vilket är en webbtjänst för datalagring.



Figur 9: Översiktligt dataflöde för projektet. Rådata samlas in av sensorer och analyseras samt bearbetas i mikrodatorn. Därefter skickas datan och lagras i Ericsson OWL och Amazon S3. Användaren kan sedan nå en instrumentpanel där datan visas via webben. Projektets huvudsakliga fokus var att utveckla modeller för svärmsdetektion, drottningdetektion och varroakvalsterdetektion.

4.2 Program för presentation av miljön i bikupan


För att återge en överskådlig bild över miljön i bikupan presenteras den befintliga temperaturen, vikten och luftfuktigheten. Montering, kalibrering och kod för datainhämtning från sensorerna hade gjorts innan projektets start. Det som återstod för att presentera miljön i kupan var att programmera en automation i Ericsson OWL så att värdena presenterades och uppdaterades i realtid.

4.3 Varroakvalsterdetektion med bildigenkänning

Många redan tränade artificiella neurala nätverk finns att hämta från olika ramverk i programmeringsspråket Python. Ett sådant är djupinlärningsramverket PyTorch som har öppen källkod. Från en tidigare jämförelse av de 17 mest vanliga bildigenkänningsmodellerna från PyTorch undersöktes parametrar såsom modellernas precision, storlek och körningstid [53]. Modellen ResNet50, ett residualt CNN med 50 lager, visade sig prestera bäst när hänsyn togs till alla undersökta parametrar. Av denna anledning valdes ResNet50 att användas som modell.


Från en tidigare studie av varroakvalster på bin erhöles ett bildset på 14 000 bilder på bin varav 3 947 bilder var på bin med varroakvalster och resterande på bin utan [54]. Ett exempel på hur ett bi med varroakvalster ser ut går att se i Figur 10a, där två röda varroakvalster sitter på mitten av biets rygg. Vidare visar Figur 10b ett exempel på ett bi utan varroakvalster. Bildsetet laddades upp i Amazon S3 och därifrån in i Amazon SageMaker. Bilderna i bildsetet var sorterade i tränings-, validerings- och testmappar. I varje mapp sorterades bilderna in i ytterligare mappar som specificerade ifall bina hade varroakvalster eller inte. Denna indelning kunde genomföras utifrån bildernas annoteringar.

Kameran på Ericssons bikupa tar bilder på hela ingången av bikupan, vilket innebär att flera bin syns i samma bild. Ett exempel på en bild tagen vid Ericssons bikupa går att se i Figur 11a. För att efterlikna bilderna som tas av kameran genererades nya bilder där ett flertal närbilder på bin med och utan varroakvalster placerades på en bakgrund. Binas positioner på bakgrunden fördelades slumpvis och bakgrundens färg valdes till samma färg som närbildernas bakgrundsfärg. Figur 11b visar ett exempel på en genererad bild. Målet med att generera bilder var att en modell som tränades på dessa bilder först kunde lära sig detektera bin och sedan detektera om biet hade varroakvalster eller inte.



Figur 10: Exempel på närbilder av bin med och utan varroakvalster från datasetet. Den genererade bilden skapades genom att slumpvis placera bin på en bakgrund.

Bildseten lästes in i koden för träning av modellen. Vid inläsning av bilderna för träning användes olika transformationer slumpvis såsom skiftning i färg, kontrast och ljusstyrka. Detta gjordes för att modellera variationer i bilderna som tas av kameran till följd av exempelvis tid på dygnet, väderskiftet och suddiga motiv. Hur färgnyansen av bildsetet påverkade modellen valdes särskilt att analyseras. Därefter laddades den förtränade bildigenkänningsmodellen ResNet50 från PyTorch in i koden. Modellen optimerades med SGD där värden på inlärningstakt och vikter valdes utifrån dokumentation av PyTorch [55].



Figur 11: Exempel på bild tagen av kameran vid Ericssons bikupa samt en genererad bild.

Två modeller skapades, en modell där träningssetet hade variationer i färgnyans och en modell där färgnyansen på bilderna inte ändrades. De båda modellerna tränades i 50 epoker och varje version av modellerna sparades efter varje tränad epok. På grund av tidsbrist valdes modellernas inställningar att inte korrigeras ytterligare under träning. Av denna anledning användes inte bildsetet för validering. För att analysera de två modellernas precision testades de på bilder ur testsetet, vilket innehöll bilder som modellerna inte har sett tidigare. Två tomma vektorer skapades för vardera modell, en för att användas som facit och en för att lagra respektive modells klassificeringar. För varje bild som testades sparades en etta i facitvektorn för varje bi med varroakvalster och en tvåa för varje bi utan varroakvalster. Modellernas klassificeringar sparades på samma sätt.

Från softmax-funktionen erhöles med vilken sannolikhet modellerna gjorde varje klassificering. Enbart klassificeringar med sannolikhet över 85 % valdes som trovärdiga, och därför sparades enbart dessa i vardera modells klassificeringsvektor. Från vektorerna beräknades hur ofta modellerna gav klassificeringar som stämde överens med facit, vilket här benämns som numerisk inferens. Värden på hur ofta klassificeringarna var sant positiva, falskt positiva, sant negativa och falskt negativa, där positivt representerar ett bi med varroakvalster och negativt ett bi utan varroakvalster, noterades. Från dessa resultat kunde F1-värden beräknas. Framtagandet av F1-värdet benämns här som F1-inferens. Efter evaluering av resultaten kunde den modell som presterade bäst vid numerisk inferens och F1-inferens väljas som den slutgiltiga. Visuella representationer av resultaten skapades genom att markera binas klass och modellens klassificering direkt i de genererade bilderna från testsetet efter den numeriska evalueringen var gjord.

Den slutgiltiga modellen laddades till sist över på mikrodatorn, som är kopplad till kameran. När varroakvalsterdetektion aktiveras i mikrodatorn tar kameran bilder var tionde minut och varje bild analyseras av modellen. Antalet bin klassificerade med varroakvalster skickas därefter till Ericsson OWL.

4.4 Bidrottningdetektion med KNN-klassificerare

Modellen för bidrottningdetektion avgör om drottningen är närvarande genom att analysera ljudet som spelas in av bikupans mikrofon. För att träna olika klassificeringsmodeller tillgängliga i Pythonbiblioteket scikit-learn användes ett dataset med ljudfiler. Modellerna som testades var K-nearest neighbors, Random forests, enkel logistisk regression och Support vector machines. Datan laddades upp till Amazon S3 och kunde därifrån nås från Amazon SageMaker där modellerna utvecklades. Efter att modellernas precision jämfördes på testdata bestämdes det att en KNN-klassificerare skulle användas för den slutgiltiga modellen. Efter att ha testat olika k -värden valdes slutligen $k = 7$ eftersom modellen presterade bäst med det värdet. Denna modell tränades med hela datasetet i efterhand för att öka precisionen.

Datasetet som användes finns tillgängligt att ladda ned via internet [56]. Det innehåller tre samlingar av ljudfiler med namnen "bee", "noqueen" och "nabee". De två första samlingarna innehåller biljud från när drottningen är närvarande respektive frånvarande i bikupan. Den tredje samlingen, "nabee", innehåller ljudfiler där mikrofonen har fångat upp oljud som inte kommer från bikupan. Alla ljudfiler är två sekunder långa och datan är samlad från flera bikupor med olika typer av mikrofoner. Datan annoterades med hjälp av Pythonkod och delades slumpvis in i ett träningsset och ett testset med proportionerna 80 % respektive 20 %.

Savitzky-Golay filtrering användes för att reducera brus i ljudinspelningarna. Bandpass- och waveletfilter testades också under projektets gång, men Savitzky-Golay filtrering visade högst precision vid klassificering av ljud. Efter att ha brusreducerat inspelningarna användes Pythonbiblioteket Librosa för att extrahera konkreta värden från ljudfilerna (feature extraction). Kromagrammet för varje ljudfil samt de 20 första MFCC:s under korta delintervall extraherades. Därefter bildades en vektor med tolv element, där varje element var tidsmedelvärdet för en ton i kromagrammet. Ytterligare en vektor med 20 element bildades genom att beräkna tidsmedelvärdet för varje MFCC. Dessa två vektorer användes som indata till KNN-klassificeraren för att klassificera varje ljudfil.

Den första versionen av modellen tränades för att klassificera ljud till en av tre klasser, vilka motsvarar "bee", "noqueen" och "nabee". Vid utvärdering av den första modellen upptäcktes att flera inspelningar som borde klassificerats som "nabee" felklassificerades. På grund av detta

bestämdes det att modellen skulle delas upp i två separata modeller som körs sekventiellt. Den första modellen används för att avgöra om inspelningen innehåller ljud medan den andra modellen avgör om biljud indikerar en närvarande drottning.

I det slutgiltiga programmet för att detektera bidrottningen spelar bikupans mikrofon in ljud i tio sekunder. Den första och sista sekunden av ljudinspelningen klipps bort för att filtrera oönskat ljud från mikrofonen. Det resterande ljudet delas upp i fyra separata inspelningar, med längden två sekunder vardera, för att efterlikna datan som modellen tränades med. Inspelningarna brusreduceras och värdena till modellernas indata extraheras ur dem. Värdena matas sedan till den första modellen för att avgöra om allt ljud kommer från bikupan. Ifall ingen av inspelningarna klassificeras som ljud används den andra modellen för att avgöra om ljudet indikerar en närvarande drottning. Då måste minst tre av inspelningarna visa att drottningen är närvarande respektive frånvarande för att modellen ska fatta ett beslut. Om ett beslut inte kan fattas, eller om den första modellen indikerar ljud, påbörjas ett nytt försök med en ny inspelning på tio sekunder. Detta repeteras endast en gång för att undvika att programmet fastnar i en cykel. Modellens beslut skickas till Ericsson OWL i formen av en etta eller nolla, vilka motsvarar att drottningen är närvarande respektive frånvarande. Om inget resultat kan ges av inspelningarna visas det senaste resultatet i webbapplikationen.

För att testa modellen på en av Ericssons bikupor planerades ett tillfälle för att temporärt plocka bort bidrottningen för hand. Detta möjliggör ett kontrollerat sätt att samla ljud medan drottningen är frånvarande, vilket modellen förhoppningsvis hade indikerat. Efter konsultation med en biodlare bestämdes det att testet skulle skjutas upp tills vädret blivit varmare för att undvika en negativ inverkan på bisamhället. Av denna anledning kunde testet inte utföras inom projektets tidsram.

4.5 Svärmningsdetektion med expertsystemsmodell

Programmet som detekterar svärmning får in data från vikt- och temperatursensorer samt ett applikationsprogrammeringsgränssnitt (API) för väder. Inledningsvis bearbetas rådatan som kommer in från sensorerna. Den bearbetade datan skickas sedan vidare till en expertsystemsmodell. Till modellen skickas även det aktuella vädret med hjälp av ett väder-API från OpenWeather. Modellen använder datan för att avgöra om svärmning pågår eller om det finns biägg i kupan, vilket kan vara en indikation på att svärmning kommer ske. Biäggen kan upptäckas genom att detektera temperaturreglering i bikupan, men biodlaren behöver sedan själv kolla vad det är för typ av biägg.

Det finns två program som bearbetar sensordatan, ett för vikt och ett för temperatur, som fungerar på liknande sätt. Alla temperaturvärden sedan två veckor tillbaka och viktvärden från en dag tillbaka lagras i programmet för att vara tillgängliga för analys. Programmet för bearbetning av temperaturdatan beräknar temperaturskillnaden över 20 minuter och även hur länge temperaturreglering har pågått i kupan med hjälp av Pythonbiblioteket Numpy, som kan hantera stora datamängder på ett effektivt sätt. Temperaturreglering över flera dagar tas fram genom att först beräkna den genomsnittliga temperaturen för varje dag och sedan ta skillnaden i temperatur mellan dagarna. Programmet som bearbetar viktdatan beräknar viktskillnaden över 20 minuter.

Expertsystemsmodellen analyserar den bearbetade datan samt väderdatan för att avgöra bikupans tillstånd utifrån kriterier som bestämts för varje fall. För svärmningsutslag krävs en viktminskning på mellan 1–3 kg och en temperaturökning på över 2 °C under 20 minuter, samt klart

väder. Viktminskningsintervallet bestämdes utifrån analys av befintlig data från Ericssons bikupor, och gränsen på temperaturökningen utifrån data samt teori. Tidsintervallet på 20 minuter som skillnaderna uppmäts över bestämdes utifrån data över tidigare svärmar. För temperaturregleringsdetektion, med andra ord detektion av biägg, sattes kriterier att temperaturen i kupan ligger mellan 32–38 °C samt att temperaturskillnaden över minst två dagar är under 2 °C, utifrån analys av befintlig data och teori. Uppfylls ingen av de två andra fallen ges utslaget "No warning".

Inledningsvis när modellen körs kommer inga utslag kunna ges på grund av att värden från minst 20 minuter behövs för att något fall ska kunna uppfyllas. De första 20 minuterna kommer därför utslaget "No data" ges. För att modellen ska kunna detektera temperaturreglering för biägg behöver den köras i minst ett dygn. Utslaget från modellen översätts till siffervärden för att kunna skickas till Ericsson OWL. "No warning" representeras av en nolla, "Eggs for x number of days" av ett decimaltal med en etta i basen följt av en decimal x som indikerar hur många dagar temperaturregleringen pågått, "Swarm" av en tvåa och "No data" av minus ett. Siffervärdet skickas till Ericsson OWL som översätter siffran till motsvarande fall och presenterar utslaget på instrumentpanelen.

Det fullständiga svärmsdetektionsprogrammet testades genom att skicka in befintlig data från när två svärmar och tre temperaturregleringar skedde. Mer data fanns inte tillgänglig. Till programmet har även enhetstester skrivits där genererad testdata för de olika fallen skickats in. Programmet har även körts i realtid på en mikrodator där utslagen har kontrollerats.

4.6 Utveckling av grafiskt gränssnitt för webbapplikation

Det grafiska gränssnittet skapades i Ericsson OWL, en webbapplikation där digitala instrumentpaneler kan skapas för att visualisera information. Informationen visas i modulära paneler, så kallade widgets. Dessa widgets kan vara av olika typer som till exempel grafer, bilder eller tabeller. Datan som skickas från mikrodatorn lagras i Ericsson OWL och kan sedan användas i widgets, för att exempelvis visa upp hur mätvärden har förändrats över tid i ett linjediagram. För att styra vad som visas i en widget kopplas widgeten samman med en automation, som är ett sätt att automatisera datahanteringen i Ericsson OWL. Automationen styrs av kod som skrivs i programmeringsspråket Javascript.

Ett första steg för att skapa det grafiska gränssnittet var att bestämma hur informationen skulle presenteras. Det som skulle presenteras var dels resultatet från modellerna, det vill säga om en bidrottning detekteras i kupan, om svärmning pågår samt antalet bin med varroakvalster. Dessutom skulle vädret där kupan befinner sig, kupans vikt samt temperatur och luftfuktighet inuti kupan visas. För att presentera informationen för användaren på ett sätt som är tydligt och lätt att överblicka skapades en widget för var och en av dessa parametrar. Varje widget gavs en tydlig titel för att göra det enkelt att förstå vilken data som presenteras. Viktförändringen samt antalet varroakvalster de senaste fem dygnen presenteras i form av ett linjediagram. Även antalet bin med varroakvalster de senaste fem dygnen presenteras i ett linjediagram.

Därefter skapades automationer som gör att den inkommande datan från mikrodatorn direkt kan visas upp i widgets på Ericsson OWL. För att visa vädret på platsen där bikupan står används API:et OpenWeather, som tillhandahåller data om nuvarande väder. Genom att skapa en automation i Ericsson OWL med kod skriven i Javascript kan väderdatan hämtas från OpenWeather i JSON-format och visas upp i en widget.

5 Resultat


I detta avsnitt visas hur programmen som skapades för presentation av miljön i bikupan, bidrottningdetektion, svärnmingsdetektion respektive varroakvalsterdetektion presterade. Detta görs genom att evaluera modellernas resultat vid testning. Därefter presenteras webbapplikationens grafiska gränssnitt och dess funktioner.

5.1 Presentation av miljön i bikupan

När programmet för presentation av miljön i bikupan kördes på mikrodatorn fungerade datainsamlingen väl. Sensorerna som registrerade vikten, luftfuktigheten samt temperaturer fungerade. All data kunde skickas till och presenteras i Ericsson OWL.

5.2 Resultat av varroakvalsterdetektion

Två modeller skapades från den förtränade modellen ResNet50. Skillnaden mellan modellerna var att den ena var tränad på bilder som skiftade i färgnyans. Träningen gjordes totalt i 50 epoker och för varje epok sparades modellerna, vilket gav 50 versioner av vardera modell, där varje version var tränad olika mycket. Hur väl modellerna presterade undersöktes genom numerisk inferens och F1-inferens. För den numeriska inferensen bestämdes modellernas precision utifrån hur ofta de gav klassificeringar som stämde överens med facit. Precisionen undersöktes både från bilder ur träningssetet, vilket innehöll bilder modellerna tidigare sett, och ur testsetet. Hur precisionen för varje modell varierar med antalet epoker samt med de olika bildseten går att se i grafen i Figur 12.



Figur 12: Graf över hur de två modellernas precision ändras när de tränats i olika antal epoker. Den ena modellen är tränad på bildset med tillagd varierande färgnyans. Grafen visar även en jämförelse av modellernas precision då de testades med bilder från tränings- och testsetet.

Figur 12 visar att modellen som tränats på bilder utan någon ändring i färgnyans har högst precision både under träning och vid testning. Denna modell har även ett stabilt precisionsintervall på 71–82 % för samtliga epoker. För den andra modellen börjar precisionen vid ca 17 % och ökar sedan under fyra epoker för att slutligen stabilisera sig i precisionsintervallet 59–67 %. Figuren

visar därmed vikten av att se bildernas verkliga färg då modellen ska klassificera, speciellt då modellen tränats ett fåtal epoker. Vidare visar grafen ingen signifikant skillnad i precision när modellerna undersöktes med de olika bildseten. Eftersom precisionen inte är högre för tränings-
et än för testsetet, indikerar grafen inte att modellerna är överanpassade.

För att utvärdera modellernas prestation användes även F1-inferens genom att beräkna F1-precisionen, F1-känsligheten och F1-värdet. Samtliga 50 versioner av vardera modell klassificerade efter tröskelvärde aldrig något bi FP eller FN vid testning. För alla versioner visade det sig därmed att

$$\text{F1-precision} = 1$$

$$\text{F1-känslighet} = 1$$

$$\text{F1-värde} = 1.$$


Som det beräknade F1-värdet antyder har alla falska klassificeringar sorterats bort efter användning av tröskelvärde. F1-värdet i kombination med att precisionsvärdena i Figur 12 aldrig når 100 % visar att tröskelvärde även sorterat bort sanna klassificeringar för båda modellerna. Det sammantagna resultatet av de båda inferenserna blir att modellerna efter tröskelvärde inte har klassificerat alla bin i testsetet, men att varje utförd klassificering har varit korrekt. Från resultaten av den numeriska inferensen och F1-inferensen kunde modellen som tränats på bilder utan variationer i färgnyans väljas som den slutgiltiga.

Tabell 2 visar ett exempel på resultat när versionen av den slutgiltiga modellen som tränats i 50 epoker testades på en genererad bild med fyra bin. Facitvektorn i tabellens första rad visar binas klass, där en etta representerar ett bi med varroakvalster och en tvåa ett bi utan. Vektorn indikerar därmed att tre av de fyra bina har varroakvalster. Som andra raden i tabellen visar gav modellen ibland fler klassificeringar än antal bin. I de flesta sådana fall gavs de överflödiga klassificeringarna en sannolikhet som är lägre än tröskelvärde, vilket innebär att de utelämnades. Ett exempel på detta går att se i tabellens tredje rad, där sannolikheterna modellen har tilldelat de olika klassificeringarna visas. Eftersom tröskelvärde sattes till 85 % anses den sista klassificeringen i vektorn, med sannolikhet 6,99 %, inte vara trovärdig. Resultaten efter tröskelvärde använts går att se i tabellens sista rad. Elementens position i vektorerna för klassificering och sannolikhet är ordnade från högst till lägst sannolikhet, medan elementen i facitvektorn är ordnade efter vilket bi som först placerades på bakgrunden.

Tabell 2: Resultat vid test av en genererad bild med fyra bin. Tabellen visar binas verkliga klass och modellens klassificering med tillhörande sannolikhet. Resultaten efter tröskelvärde använts går även att se.

Facit	[1 , 1 , 1 , 2]
Modellens klassificering	[1 , 2 , 1 , 1 , 2]
Sannolikhet (%)	[99,9 , 97,9 , 97,7 , 96,6 , 6,99]
Klassificering efter tröskelvärde	[1 , 2 , 1 , 1]

En visuell representation av resultaten går att se i Figur 13a. Det finns fyra typer av rektanglar utmålade i figuren. De orangea indikerar ett bi med varroakvalster och är uppdelade i ljusorange för facit och mörkorange för modellens klassificering. De blå rektanglarna är uppdelade på samma sätt för bin utan varroakvalster. Om biet har två rektanglar av samma färg innebär det att biets klassificering stämmer överens med facit. Figuren visar därmed att klassificeringarna efter tröskelvärde i Tabell 2 är korrekta. Figur 13b visar samma modells klassificering av en bild tagen av kameran vid Ericssons bikupa. Utav de fem bin vars hela kroppar syns i bilden är alla korrekt klassificerade att inte ha varroakvalster.



(a) Visuell representation av resultaten i tabell 2. Binas verkliga klass är markerade med mörkare rektanglar.



(b) Visuell representation av resultat från bild tagen vid Ericssons bikupa.

Figur 13: Modellens klassificeringar visas på en bild ur testsetet samt på bild tagen vid Ericssons bikupa. En orange rektangel indikerar ett bi med varroakvalster och en blå rektangel ett bi utan.

Den slutgiltiga modellen tränad i 50 epoker kunde laddas över och integreras i kod på mikrodatorn. Programmet kunde exekveras och bilder tagna av kameran analyseras var tionde minut. Antalet bin klassificerade med varroakvalster visas i Ericsson OWL.

5.3 Resultat av bidrottningdetektion

Prestandan för de två KNN-modellerna som används i programmet för bidrottningdetektion utvärderades med testdata. Modellen som tränades för att skilja på biljud och oljud (ljud som inte kommer från kupan) hade precisionen 0,864, medan modellen som tränades för att skilja mellan biljud med drottning och utan drottning hade precisionen 0,996. Sammanblandningsmatriserna för de två modellerna visas i Tabell 3 respektive 4. Den andra modellen visar konsekvent hög precision, medan den första modellen är markant sämre på att klassificera oljud än biljud.

Tabell 3: Sammanblandningsmatris för KNN-modellen som tränades för att skilja mellan oljud och biljud.

		Faktisk klass	
		Biljud	Oljud
Modellens klassificering	Biljud	2401	320
	Oljud	144	546

Tabell 4: Sammanblandningsmatris för KNN-modellen som tränades för att skilja mellan biljud med drottning och utan drottning.

		Faktisk klass	
Modellens klassificering		Ingen drottning	Drottning
	Ingen drottning	1235	7
	Drottning	3	1333

När den andra modellen testades på 184 ljudfiler som var två sekunder vardera och som tidigare spelats in från Ericssons kupor gavs uteslutande resultatet att drottningen fanns närvarande, vilket är korrekt. Samma test gjordes inte för modellen som tränades för att skilja på biljud och

oljud. Detta eftersom datan inte var annoterad och mycket arbete därför hade krävts för att identifiera ljudstycken som innehåller oljud.

Programmet för bidrottningsdetektion i sin helhet fungerade att köra i realtid på mikrodatorn, och kontinuerlig status skickades då till Ericsson OWL. I samtliga fall (cirka 70) identifierade programmet korrekt att drottningen var närvarande. Inget oljud detekterades heller i dessa fall.

5.4 Resultat av svärmsdetektion

När programmet för svärmsdetektion kördes på data från tidigare svärmar och temperaturregleringar erhöles korrekta utslag, undantaget en temperaturreglering. Modellen kunde inte detektera temperaturreglering på en av bikuporna eftersom temperatursensorernas värden skiftade för mycket. Detta kan bero på att temperatursensorerna i den specifika kupan inte placerats tillräckligt långt in i kupan, och därmed inte uppmätt binas temperaturreglering helt korrekt. Enhetstesterna med genererad data som avspeglar verkliga förhållanden för alla möjliga utslag fungerade. När modellen kördes i realtid på mikrodatorn gavs rätt utslag för "No swarm" på samtliga kupor. Eftersom bina inte har svärmat när modellen körts på mikrodatorn under projektet har det inte testats om en faktisk svärm kan detekteras.

5.5 Grafiskt gränssnitt för webbapplikation

Webbapplikationens grafiska gränssnitt visas i Figur 14 och 15. Gränssnittet består av totalt tolv widgets som visar olika detaljer om den uppkopplade bikupans tillstånd. Nio av dessa widgets ligger direkt på startsidan till applikationen i ett rutnät, medan tre nås genom att klicka på ikonerna i det övre högra hörnet. Dessa är markerade med en röd ruta i Figur 14. Varje widget har en titel och en beskrivande text vars syfte är att förklara vilken information som visas.


I den översta raden ligger en textruta som innehåller instrumentpanelens titel samt enklare instruktioner till användaren. Bredvid textrutan ligger en bild på bikupan. Målet med bilden är att användaren enkelt ska kunna se vilken bikupa instrumentpanelen är kopplad till. Längst till höger i översta raden finns information om vädret på kupans plats. Denna information inkluderar temperatur, molnighet och nederbörd. Målet med denna widget är att biodlaren enkelt ska få en överblick över vädret, vilket kan underlätta vid skötseln av bikupan.

Mittenraden innehåller tre widgets som presenterar resultatet från bidrottningsdetektionen, varroakvalsterdetektionen och svärmsdetektionen. Widgeten för bidrottningsdetektion kan antingen ge utslagen "Queen present" eller "Queen not present". Om drottningens närvaro indikeras är texten grön, annars blir den orange. I widgeten i mitten av raden visas antalet bin med varroakvalster som har detekterats den aktuella dagen. Widgeten för svärmsdetektion ligger längst till höger. Denna visar antalet dygn som ägg har detekterats, och om en svärmning indikeras visar den "Swarm now". Om inga ägg och ingen svärm detekteras visas "No warning". När ägg har detekterats i över sju dygn eller om en svärmvarning sker blir texten orange, annars är den grön. För samtliga widgets i mittenraden visas dessutom datum och tid då senaste analysen gjordes.


I den nedersta raden finns widgets som visar information om den nuvarande miljön i bikupan. Denna information inkluderar bikupans vikt, temperaturen från en av sensorerna i kupan och luftfuktigheten inuti kupan. Datum och tidpunkt då datan inhämtades visas också.

Graferna som kan öppnas genom att klicka på ikonerna visar förändringen av vikten, anta-

let detekterade bin med varroakvalster samt temperaturen från olika temperatursensorer de senaste fem dygnen. Graferna skapas genom att alla tillgängliga datapunkter sammankopplas med rätta linjer. För temperaturen och vikten finns datapunkter var tionde minut, medan detekteringen av varroakvalster har en datapunkt per dag som visar det totala antalet detekterade bin med varroakvalster den dagen.



Figur 14: Det grafiska gränssnittet för webbapplikationen. Menyn längst upp till vänster i bilden används för att navigera till andra instrumentpaneler inom Ericsson OWL. Om användaren klickar på ikonerna markerade med en röd ruta i övre högra hörnet visas grafer. En, två eller tre grafer kan vara öppna samtidigt. Observera att den röda rutan inte är en del av gränssnittet.



Figur 15: Alla grafer som kan öppnas genom att klicka på ikonerna i Figur 14. I temperaturgrafen kan användaren gömma grafen för en viss sensor genom att klicka på rutan med sensorns namn i. Båda axlarna i alla grafer anpassas dynamiskt efter den aktuella datan som visas.

6 Diskussion

Detta avsnitt inleds med att utvärdera resultatet av projektets olika delar. Därefter lyfts och diskuteras samhälleliga och etiska aspekter av projektet. Slutligen diskuteras utvecklingsmöjligheter för de tre modellerna som skapats samt det grafiska gränssnittet.

6.1 Utvärdering av systemet

I följande avsnitt utvärderas presentationen av miljön i bikupan, resultatet av de tre modeller som skapats samt det grafiska gränssnittet för webbapplikationen.

6.1.1 Presentation av miljön i bikupan

En bikupas vikt, temperatur och luftfuktighet avspeglar en stor del av hur välmående ett bisamhälle är. Som det beskrivs i avsnitt 2.2 visar exempelvis en ökning av vikten på att bisamhället är aktivt, vilket är ett gott tecken under sommarsäsongen. Temperaturen och luftfuktigheten är två parametrar som bina reglerar noggrant för att få optimal miljö i bikupan, vilket beskrivs i avsnitt 2.3. Genom att automatisera övervakningen av dessa parametrar får biodlaren hjälp med att upptäcka avvikelser och kan vidta åtgärder i tid för att hjälpa bisamhällets välmående.

Bikupans vikt, temperatur och luftfuktighet presenteras som siffervärden utan någon tolkning, och applikationen indikerar exempelvis inte om värdena är något utöver det vanliga. Detta kan göra applikationen något mindre hjälpsam för användare med mindre erfarenhet av biodling. Trots detta bedöms parametrarna som mäts och uppdateras i realtid i webbapplikationen som användbara för biodlare.

6.1.2 Varroakvalsterdetektion

Modellen utan färgnyansändringar hade högst precision av de två som jämfördes. En möjlig förklaring till detta är att varroakvalstrets röda färg är lätt att urskilja på bikroppen givet att färgerna inte manipuleras. Tvärtom skulle därför också en manipulerad bild med extra röd nyans istället dölja varroakvalstren. Valet av tröskelvärde har också påverkat modellens precision. Med dess höga tröskelvärde klassificerade modellen väldigt sällan fel, men samtidigt ställde den så höga krav på klassificeringarna att modellen sannolikt underapproximerar antalet varroakvalster.

En orsak till att maskininlärningsmodeller får låg precision är förekomsten av datasetsskiftet (dataset shifts). Ett skifte som kan uppstå är samvariationsskiftet (covariate shift) där olika detaljer skiljer bilderna i dataseten åt [57]. Till exempel kan faktorer som varierande ljusförhållanden vid fotografering leda till att modellen har svårare att hitta likheter bland bilderna i ett dataset. Samtidigt som varierande förhållanden försvårar bildigenkänningen kan noggrant kontrollerad variation förbättra modellens kapacitet att känna igen bilder som liknar dem från träningssetet. I projektet infördes därför transformer som slumpvis varierar detaljer såsom ljusstyrka, färgmättnad samt kontrast i bilderna. När nya detaljer introduceras får de ursprungliga detaljerna en mindre betydelse.

Eftersom annoterade bilder på bin framför en bikupa inte fanns tillgängliga behövde sådana bilder genereras. Slumpan det av antalet bin på bilden samt deras varroastatus och position utgjorde ytterligare detaljer som motverkar samvariationsskiftet. Dock blev bilderna inte lika representativa för den kontext den ska användas i eftersom bilderna endast innehöll uniformt fotograferade bin som var utspridda på en enfärgad bakgrund. En risk som uppstår är att modellen då lär sig mönster som inte finns i verkligheten där bin ses från alla vinklar och rör sig

framför en riktig bikupa. Sammanfattningsvis kommer samvariationsskiften sannolikt förekomma vid steget från träning till verklighet, men som följd av en gemensam källa för testsetet och förebyggande åtgärder bör dessa skiften inte ha påverkat modellens precision signifikant.

Förhandsfördelningsskifte (prior probability shift) är en annan form av datasetsskifte där träningsdatan har en oproportionerlig fördelning gentemot testdatan [57]. Ett exempel på detta är att de genererade bilderna som användes för träning hade ett avsevärt högre antal bin med varroa än bin utan varroa. I verkligheten utgör spridningen av varroakvalster en stor fara för kupan redan när en sådan liten andel som 3 % av populationen är drabbad, men i träningen var andelen drabbade närmare 33 % [58]. Obalansen i bin med och utan varroa innebär också att den numeriska inferensen blir känslig och får kraftigt minskad precision efter enstaka klassificeringsfel [57].

Överanpassning är en annan faktor som kan minska precisionen hos modeller [59]. Modellens användbarhet beror på dess förmåga att generalisera sin kunskap från gammal data och utifrån den dra slutsatser om ny data. Om träningen pågår för länge börjar modellen istället fokusera på brus och irrelevant information som ökar dess komplexitet. Resultatet är en modell med hög precision på känd data men låg på ny data. För att hålla modellen generell undersöktes antalet tränade epoker som en faktor. Målet med detta var att hitta vändpunkten där modellens resultat slutade förbättras av mer träning. Träningstiden på träningsplattformen AWS begränsade modellen till 50 epoker vilket inte var tillräckligt för att påvisa en vändpunkt hos den numeriska inferensen. Denna hade sannolikt kunnat hittas med andra träningsförutsättningar. Däremot finns ett tydligt mönster av underanpassning vid få tränade epoker för modellen som tränats på dataset med varierande färgnyans och som använder numerisk inferens. Denna karakteriseras av att modellen inte har data nog att skapa meningsfulla förhållanden mellan in- och utdatan.

Modellen kommer inte kunna hitta alla varroakvalster på bilderna även om den har perfekt precision. Vissa kroppsdelar, som till exempel magen, är svåra att få med i bilderna samtidigt som de har en mycket högre sannolikhet att ha varroa än mer synliga kroppsdelar [60]. Dålig skärpa på kameran kan också göra det svårt att se detaljer som modellen kan urskilja varroa med. Vissa objekt som förekommer i bilderna såsom kablar kan också felaktigt klassificeras som bin, vilket kan påverka precisionen. På grund av dessa faktorer är det teoretiskt osannolikt att kunna fånga alla varroa på bild.

Trots felfaktorer kan varroakvalsterdetektionen vara ett användbart verktyg för biodlare. Det faktum att varroakvalster kan orsaka allvarliga problem för bisamhället redan vid spridning som utgör enstaka procent av populationen innebär att det finns belägg för att F1-inferensen kan vara användbar [58]. Givet att spridningen till exempel är 3 % i kupan skulle bilderna med varroakvalster vara mer sällsynta och därmed mer informativa. En möjlig risk är dock att de få varroakvalstren som förekommer inte identifieras av modellen, vilket hade kunnat leda till opålitliga resultat. En biodlare som endast förlitar sig på modellen med F1-inferens kan därför råka ut för en underapproximering som inger falsk säkerhet. Istället bör det ses på som en ungefärlig uppskattning av angreppsgraden som möjligtvis kan minska antalet besök till kupan överlag.

I den slutgiltiga webbapplikationen använder varroakvalsterdetektionen numerisk inferens. Detta beror på att en indikator på antalet drabbade bin som har identifierats kan uppfattas vara mer användbar för biodlare än en indikator på hur många bilder med varroakvalster som har identifierats. Genom att räkna fallen med varroakvalster kan en mer precis bild av angreppsgraden skapas och spridningens utveckling i bikupan blir tydligare för användaren.

6.1.3 Bidrottningdetektion

Som Tabell 3 och Tabell 4 visar skiljer sig precisionen mellan de två modellerna som användes i syftet att detektera bidrottningen. Medan modellen som avgör om ljudet indikerar en närvarande drottning visade hög precision på testdatan, kan detsamma inte sägas om modellen för att detektera oljud. En anledning till detta kan vara att oljud är en bred kategori som kan förekomma i former vilka skiljer sig från varandra. Exempelvis kan buller från tågtrafik låta väldigt annorlunda jämfört med ett billarm, men ändå ska modellen klassificera dessa som samma. Skillnader i olika typer av oljud kan göra det svårare för modellen att hitta likheter som pekar på att ljuden tillhör samma klass. En annan orsak till den låga precisionen kan vara att ljudinspelningar som fångat upp oljud fortfarande innehåller ljud från bikupan. Om biljudet är tillräckligt tydligt är det möjligt att modellen felklassificerar ljudinspelningen.

Den första versionen av modellen hade båda uppgifterna som de två slutgiltiga modellerna har. Genom att dela upp den i två modeller var det möjligt att specialisera dem till högre grad, vilket var motivationen bakom beslutet. Den första modellen kan ses som ett filter, vars uppgift är att undvika att oljud blir klassificerat till en indikation för bidrottningen. Från Tabell 3 är det möjligt att se att biljud väldigt sällan felklassificeras som oljud. Däremot klassificeras endast 63 % av oljudinspelningarna i testdatan som oljud. Detta kan vara på grund av att dessa inspelningar innehåller ett tydligt biljud och därmed felklassificeras av den första modellen. Om biljudet är tillräckligt tydligt är det möjligt att den andra modellen klassificerar ljudet korrekt, även om den första modellen felklassificerade ljudet.

Datasetet som användes för att träna modellerna innehåller ljudinspelningar från flera bikupor med olika typer av mikrofon placerade på olika ställen. Jämfört med data endast samlad från en bikupa och en typ av mikrofon, är datasetet som användes mycket mer generellt. Därmed minskar risken att modellen tränas på detaljer specifika för en viss konfiguration av bikupa och mikrofon, vilket hade resulterat i en överanpassad modell. Av denna anledning var det fördelaktigt att använda den tillgängliga datan istället för att samla och annotera data från Ericssons bikupor, vilket också hade varit väldigt tidskrävande. Modellen hade då sannolikt varit mer anpassad för Ericssons bikupor, men presterat sämre när den används under nya förutsättningar.

Genom att kontinuerligt detektera bidrottningens närvaro med ljud från bikupan slipper biodlare besöka kupan för att kontrollera att drottningen är där. Utöver att frigöra tid från biodlaren, påverkas bisamhället mindre av färre besök. Eftersom ingen av modellerna har testats på en verklig bikupa i stor utsträckning, medförs även risker med deras användning. Det är möjligt att ljud som indikerar en frånvarande drottning felklassificeras som oljud. I detta fall skulle inte biodlaren bli notifierad, vilket i värsta fall kan innebära att bisamhället dör. Det finns även en risk för falska alarm om biodlaren blir notifierad att drottningen saknas, när detta inte är fallet. Utan att ha haft möjligheten att testa modellerna på en bikupa utan bidrottning är det svårt att avgöra hur stora riskerna verkligen är. De tester som har utförts har gett en viss indikation att modellerna är pålitliga, men fler tester hade behövts genomföras.

6.1.4 Svärningsdetektion

En svårighet i utvecklingen av programmet för svärningsdetektion var den begränsade tillgången till data att bygga och testa modellen med. Modellen behövde byggas utifrån slutsatser som dragits från faktainsamling i samspel med den begränsade datan som fanns. Det går därmed inte att avgöra med full säkerhet om modellen faktiskt kan detektera en pågående svärm eller temperaturreglering i verkligheten. Att enhetstesterna fungerar visar endast på att programmets

funktioner fungerar som tänkt, men inte om det kan upptäcka verkliga svärmar eller temperaturregleringar. Kriterierna för varje fall är dock enkla att modifiera och kan behöva kontrolleras när en större mängd data har samlats in.

En svaghet hos modellen är att temperatursensorerna måste vara placerade på rätt ställe för att mäta temperaturen i de områden där temperaturreglering pågår. För att täcka så många områden som möjligt i bikupan används flera temperatursensorer placerade på olika ställen, men det finns fortfarande en risk att ingen av sensorerna sitter i ett område där temperaturreglering pågår. Detta innebär att modellen riskerar att missa att det finns biägg i kupan. Modellen kan inte heller avgöra om det är just bidrottningar som håller på att födas upp, vilket innebär att biodlare fortfarande behöver kolla vad det är för typ av bin som föds upp när modellen varnar om biägg. Just varningen om biägg är därför inte lika hjälpsam för att upptäcka en svärm i förtid, men kan göra att biodlare undviker besök när det inte finns några biägg i kupan alls. Varningen indikerar även att en äggläggande bidrottning finns i bikupan och kan därför ses som ett komplement till modellen för bidrottningdetektion.

Sensorernas mätosäkerhet bör inte vara en faktor som påverkar utslaget hos modellen. Temperatursensorernas precision är $\pm 0,5^\circ\text{C}$ [61]. Lastcellernas precision påverkas av flera faktorer såsom temperaturförändring och icke-linjäritet. Det största möjliga viktmätningsfelet med avseende på alla faktorer uppskattas till $\pm 0,15\text{ kg}$ [62]. För äggdetektion krävs att temperaturen uppmäts till $32\text{--}38^\circ\text{C}$ samt att temperaturregleringen inte varierar mer än 2°C i minst två dagar. Som beskrivet i avsnitt 2.6 temperaturreglerar bina kupan omkring $34\text{--}35^\circ\text{C}$, så med en precision på $\pm 0,5^\circ\text{C}$ bör detta kriterium inte påverkas av temperatursensorernas mätosäkerhet. För svärmutslag krävs en temperaturhöjning på över 2°C samt en viktminskning mellan $1\text{--}3\text{ kg}$ under 20 minuter. Temperaturen stiger till ca 39°C vid svärmning, och vid analys av befintlig data sjunker vikten på bikupan med ungefär 2 kg . Även i detta fall är mätosäkerheten hos sensorerna såpass små i jämförelse med de intervall som angetts att de inte bör påverka utslaget.

Att intervallen har angetts med så omfattande omfång i modellen bör inte utgöra en risk för falska utslag eftersom flera faktorer måste uppfyllas för utslagen. Sannolikheten att exempelvis temperaturen i kupan ligger omkring $34\text{--}35^\circ\text{C}$ i flera dagar när det inte finns biägg i kupan är låg. Dels på grund av att temperaturen i Sverige under sommaren inte brukar bli så hög, men även på grund av att bina har förmåga att reglera temperaturen i kupan. De kan exempelvis kyla ned bikupan som beskrivet i avsnitt 2.3 då den höga temperaturen inte är önskvärd om det inte finns ägg i kupan. Svärmningsförhållanden bör inte heller kunna uppfyllas av utomstående påverkan. En plötslig viktminskning mellan $1\text{--}3\text{ kg}$ kan ske exempelvis om en del av bikupan tas bort, men för utslaget "Swarm" behöver även en plötslig temperaturökning ske. Detta har låg sannolikhet att ske när en del av kupan tas bort.

Om en svärm upptäcks och förhindras i tid undviker biodlaren stora förluster av bin och även spridning av eventuella bisjukdomar till andra bisamhällen. Det förhindrar även risken att bina bygger upp nya samhällen på oönskade ställen. Modellen kan behöva förbättras när mer data har samlats in, men kan detektera majoriteten av de svärmar och temperaturregleringar som tidigare har skett. Därför anses modellen vara ett användbart verktyg för biodlare.

6.1.5 Grafiskt gränssnitt för webbapplikation

Målet med det grafiska gränssnittet för webbapplikationen var att presentera information på ett sätt som är lätt att förstå och överblicka. Därav var målet att designa ett enkelt och tydligt gränssnitt med tydliga texter och lättillgänglig information. För att användaren ska kunna dra

nytta av informationen i gränssnittet är det viktigt att den är aktuell, och därför visas tidpunkten för när varje widget senast uppdaterades. Informationen som visas på webbapplikationens startside är menad att vara så överskådlig som möjligt, och därför visas inga grafer där. Om användaren vill se graferna kan dessa visas genom att använda knapparna i menyn högst upp på startsidan. Detta minskar mängden information som användaren möts av direkt när webbapplikationen öppnas, för att ge ett överskådligt intryck.

Det grafiska gränssnittet har inte genomgått användartester och därför finns inga åsikter om slutprodukten från applikationens målgrupp, som utgörs av biodlare, att tillgå. En fördel med Ericsson OWL är dock att det är enkelt för administratörer att redigera både innehåll och utseende på det grafiska gränssnittet. När administratörer gör ändringar på instrumentpanelen blir de direkt synliga för användarna. Biodlare som använder applikationen ser endast den publicerade versionen av instrumentpanelen, och kan inte komma åt data eller redigera vad som presenteras. Eftersom datan är tillgänglig direkt i Ericsson OWL är det därför enkelt att lägga till ytterligare grafer eller att presentera data på ett annat sätt om det önskas av applikationens användare.

6.2 Samhälleliga och etiska aspekter

Ingen interaktion har krävts mellan projektgruppen och bina eftersom datan har samlats in med bikupornas sensorer. Den enda gången som interaktion skulle ha krävts var vid ett test av bidrottningsdetektionen. Förslaget att temporärt avlägsna drottningen från kupan lades fram till den ansvariga biodlaren hos Ericsson. För att hinna genomföra testet inom projektets tidsram behövde det ske i april månad, men vid detta laget var bikupan fortfarande i tillväxtstadiet efter vintern. Ett ingrepp så tidigt under året skulle påverka bisamhällets välmående negativt, vilket innebär att testet bedömdes vara olämpligt och därför genomfördes det inte.

Trots att applikationen kan vara användbar för biodlare är den inte perfekt. Även vid hög precision kan okända faktorer såsom underapproximering eller problem med sensorerna innebära att biodlaren får en felaktig bild av bikupans tillstånd. En bidrottningsfrånvaro, svärmningar och varroaspridning kan drabba kupan allvarligt om de inte åtgärdas i tid, vilket gör det viktigt att biodlaren inte helt förlitar sig på modellerna, utan istället ser dem som ett underlättande komplement till biodlingsarbetet.

Bikupornas ökade autonomi möjliggör en expansion av tambisamhällen, vilket kan bidra till ökad pollinering. När fler tambin placeras i naturen motverkas den pågående globala minskningen av bin [63]. Expansionen av tambisamhällen är dock inte enbart positiv, då den innebär att vilda bin får konkurrens när det gäller föda och boplatser [64].

6.3 Utvecklingsmöjligheter för systemet

I detta avsnitt diskuteras förbättringsmöjligheter för de tre modellerna och det grafiska gränssnittet. Dessutom lyfts aspekter som skulle kunna vidareutvecklas i framtiden eller i liknande projekt.

6.3.1 Varroakvalsterdetektion

Modellens träning kan sannolikt effektiviseras genom ett byte av träningsplattform. En träningsplattform där träningen inte är tidsbegränsad samt där träningen som faktiskt genomförs går fortare hade på kort sikt lämnat mer tid till testning och finjustering av modellen. På längre

sikt lär dessa finjusteringar bidra till att modellen får en ökad precision. Ett förslag på en finjustering som kan undersökas på den vunna tiden är vilka transformer som ska inkluderas och hur tydligt dessa ska manipulera bilden. När modellen kan tränas fler epoker är det även troligt att vändpunkten för överanpassning kan hittas, vilket indikerar den maximala precisionen som kan uppnås med den befintliga modellen.

En annan förbättringsåtgärd är att revidera dataseten. Under projektet saknades annoterad data från en riktig bikupa som hade kunnat användas i ett ytterligare valideringssteg. Om sådan data hade tagits fram hade modellerna kunnat genomgå en ännu mer noggrann testningsprocess där testsetet hade kunnat användas för att finjustera modellen istället för att utgöra det slutgiltiga valideringssteget. För att förhindra framtida förhandsfördelningsskiftet bör även modellens genererade bilder bestå av data vars fördelning mellan bin med och utan varroa motsvarar fördelningen som finns i verkligheten.

Figur 11a visar att kablar och andra objekt förekommer i bilderna som tas av bikupans kamera. Genom att istället fotografera bina framför en enhetlig bakgrund hade det blivit lättare för modellen att identifiera bin samtidigt som bakgrunden hade gömt objekt som annars felaktigt hade kunnat klassificeras som bin. En sådan lösning övervägdes i ett tidigt stadie av projektet men nedprioriterades till förmån för fokus på att förbättra modellens precision.

6.3.2 Bidrottningsdetektion

Att träna modellerna med mer data hade varit ett sätt att åstadkomma bättre precision. Detta hade kunnat genomföras genom att kombinera den använda träningsdatan med annan data tillgänglig via internet. Eftersom datan som är samlad från Ericssons bikupor inte är annoterad är den oanvändbar för modeller som tränas genom väglett lärande. Manuellt arbete hade krävts för att annotera datan, vilket är besvärligt på grund av svårigheten att höra skillnaden mellan olika typer av ljud. Genom att samla data medan drottningen garanterat befinner sig i respektive utanför bikupan, hade det varit möjligt att samla en stor mängd data som direkt kan annoteras. Det är sedan möjligt att använda den nya datan för att fortsätta träna och förbättra modellerna.

Egna klasser för de vanligast förekommande oljuden som bikupans mikrofon fångar upp hade varit ett sätt att öka precisionen av modellen för att detektera oljud. Detta hade kunnat minska osäkerheten genom att specialisera modellen för att detektera specifika typer av oljud. Om exempelvis oljud från biltrafik hade varit vanligt förekommande, hade det varit möjligt att träna modellen att lyssna efter specifikt den typen av ljud. På samma sätt hade andra typer av oljud varit lättare att detektera genom att träna modellen efter dem. Mer välspecifierade klasser hade möjligtvis kunnat öka precisionen av denna modell.

6.3.3 Svärmningsdetektion

Ett förslag på ytterligare en parameter att integrera för att kunna detektera svärmning med högre precision är ljud. När svärmning sker ökar ljudvolymen markant eftersom aktiviteten i bikupan ökar. Ljudet kunde inte integreras i den slutgiltiga modellen eftersom det inte fanns en mikrofon på kupan när tidigare svärmar skedde, vilket gjorde att det inte fanns någon data på hur ljudet ändras när en svärm sker. För att detektera en svärm i förtid skulle även vikten över flera dagar i teorin kunna övervakas, då den i avsnitt 2.6 beskrivs som relativt konstant dagarna innan svärmning. Denna faktor integrerades inte i nuvarande modell på grund av att den befintliga datan som fanns inte avspeglade denna teori.

En utvecklingsmöjlighet med svärmsdetektionsmodellen är att göra om den till en maskininlärningsmodell istället för en analytisk modell när mer data har samlats in. Förhoppningen är att maskininlärningsmodellen inte är lika känslig för viss avvikelse i sensordatan som den analytiska modellen. Samma databearbetningsprogram som har utvecklats för den analytiska modellen kan även användas till en eventuell maskininlärningsmodell. För tillfället är det största hindret i utvecklingen av en maskininlärningsmodell bristen på data.

6.3.4 Grafiskt gränssnitt för webbapplikation

I det grafiska gränssnittet visas resultatet från de modeller som används, men ingen information om hur modellerna kom fram till dessa resultat. När modeller baserade på artificiell intelligens används för att dra slutsatser krävs en avvägning mellan transparens och tydlighet, och för att göra applikationen så lätt som möjlig att använda för en biodlare utesluts information om processen bakom modellerna. En nackdel med detta är att användaren riskerar att inte få en förståelse för att information som visas om svärmning, bidrottning och varroakvalster är ett resultat av modeller och inte en garanti. För att undvika detta skulle mer utförlig information om hur modellerna fungerar kunna finnas tillgänglig på webbapplikationen.

En funktion som hade kunnat vara användbar för en biodlare som använder applikationen är notifikationer. Notifikationer hade exempelvis kunnat ges om en bidrottning inte detekteras i bikupan eller om modellen varnar för svärmning. Ett framtida arbetsområde kan alltså vara att utöka applikationen med notifikationer via till exempel mail, sms eller i webbläsaren. Biodlare som har mer än en bikupa behöver använda en instrumentpanel för varje kupa. Ytterligare ett framtida arbetsområde hade varit att i Ericsson OWL utveckla en överblick över flera instrumentpaneler, så att biodlare med flera kupor kan ges översikt av statusen för sina olika bisamhällen för att snabbare kunna upptäcka och åtgärda problem.

Webbapplikationen fokuserar i sin nuvarande utformning på att presentera information på ett tydligt sätt snarare än att guida användaren till vad informationen betyder. Det krävs därför att den som använder applikationen har en viss kunskap om hur olika faktorer kan påverka bisamhället. För att göra webbapplikationen mer användbar för mindre erfarna biodlare hade den kunnat utökas med mer information, till exempel om vad en viss temperatur i bikupan kan indikera.

Det grafiska gränssnittet är inte anpassningsbart av användaren, vilket innebär att det inte går att välja vilken information som visas eller hur den visas. Detta är något som bidrar till att webbapplikationen är enkel att komma igång med och använda, men samtidigt är det möjligt att olika användare är intresserade av olika saker. Till exempel visas endast temperaturförändringar över fem dygn, och en förbättringsmöjlighet är att låta användaren välja vilken tidsperiod som grafen ska visa. Det grafiska användargränssnittet hade även kunnat anpassas efter användarens erfarenhetsnivå av biodling. Fler tips och mer information hade gynnat en mer oerfaren biodlare medan någon med mer erfarenhet kanske hade valt ett mer avskalat gränssnitt. Att låta användaren anpassa applikationens utseende och innehåll kan dock bli en kompromiss med användarvänligheten, och därför prioriterades ett enkelt gränssnitt.

7 Slutsats

Syftet med projektet var att ta fram en webbapplikation som biodlare kan använda för att övervaka sina bisamhällens välmående. Projektet resulterade i en webbapplikation med tre huvudsakliga funktionaliteter, som genom maskininlärnings- och analytiska modeller detekterar varroakvalster, bidrottning samt svärmning. Webbapplikationen presenterar även miljön i bikupan, vilket inkluderar bikupans vikt, temperatur och luftfuktighet.

Modellen för varroakvalsterdetektion uppnådde en maximal precision på ca 80 % vid testning med numerisk inferens. Genom användning av tröskelvärde minimerades modellens felaktiga klassificeringar vilket resulterade i att F1-värdet blev maximalt. Två modeller skapades för drottningdetektion. Modellen vars uppgift var att filtrera ut oljud som inte kom från bikupan hade precisionen 86,4 % på testdata medan modellen vars uppgift var att detektera drottningens närvaro utifrån ljudet hade en precision på 99,6 %. Pågående svärmning och symptom innan svärmning kunde detekteras med svärmmodellen när den testades med insamlad data.

Samtliga modeller var svåra att testa på verkliga bikupor på grund av att aktiviteten i Ericssons kupor var låg under perioden projektet utfördes. Trots detta fungerar webbapplikationen där resultaten av modellerna ger en indikation på bisamhällets välmående. Applikationen kan därmed användas som ett verktyg för biodlare. Sammanfattningsvis kan projektets syfte anses vara uppnått.

Referenser

- [1] UNRIC, "En värld utan bin är en värld utan mat," 2021. [Online]. Tillgänglig: <https://unric.org/sv/en-varld-utan-bin-ar-en-varld-utan-mat/> (hämtad: 2022-03-22).
- [2] Naturskyddsföreningen, "Bin och deras livsmiljö," 2021. [Online]. Tillgänglig: <https://www.naturskyddsforeningen.se/faktablad/bin-och-deras-livsmiljo> (hämtad: 2022-03-22).
- [3] Sveriges Biodlares Riksförbund, "Antalet biodlare ökar rekordartat," 2019. [Online]. Tillgänglig: <https://www.biodlarna.se/antalet-biodlare-okar-rekordartat> (hämtad: 2022-03-22).
- [4] Sveriges lantbruksuniversitet, "Våra viktiga bin," 2021. [Online]. Tillgänglig: <https://www.slu.se/centrumbildningar-och-projekt/futurefood/food-facts/matologi/vara-viktiga-bin> (hämtad: 2022-05-08).
- [5] Allt om biodling, "Bisamhället," [Online]. Tillgänglig: <https://alltombiodling.se/bisamhallet> (hämtad: 2022-03-22).
- [6] Britannica, The Editors of Encyclopaedia, "Honeybee," *Britannica*, Mar. 24, 2020, [Elektronisk bild]. Tillgänglig: <https://www.britannica.com/animal/honeybee#/media/1/270903/141787> (hämtad: 2022-04-22).
- [7] J. Lang, C. O. Mattson, *Bin till nytta och nöje*. 5 uppl., Stockholm, Sverige: Art & copy produktion, 2013.
- [8] N. Persson, *Boken om Biodling*. 3 uppl., Skänninge, Sverige: Biodlarna, Sveriges biodlares riksförbund, 2011.
- [9] NASA, "A bee is more than a bug," *NASA Climate Kids*, Feb. 11, 2020, [Elektronisk bild]. Tillgänglig: <https://climatekids.nasa.gov/bees/> (hämtad: 2022-05-02).
- [10] Allt om biodling, "Ramar," [Online]. Tillgänglig: <https://alltombiodling.se/ramar> (hämtad: 2022-03-22).
- [11] Mid-Atlantic Apiculture Research and Extension Consortium, "Seasonal cycles of activities in colonies," [Online]. Tillgänglig: <https://canr.udel.edu/maarec/honey-bee-biology/seasonal-cycles-of-activities-in-colonies> (hämtad: 2022-03-28).
- [12] Cornell University Master Beekeeper Program, "Beekeeping calendar for the northeast," [Online]. Tillgänglig: <https://pollinator.cals.cornell.edu/sites/pollinator.cals.cornell.edu/files/shared/documents/Beekeeping%20Calendar%20for%20the%20Northeast.pdf> (hämtad: 2022-03-28).
- [13] M. A. Döke, M. Frazier och C. M. Grozinger, "Overwintering honey bees: biology and management," *Current Opinion in Insect Science*, vol. 10, ss. 46–129, Aug. 2015, doi:10.1016/j.cois.2015.05.014.
- [14] A. Lecocq, P. Kryger, F. Vejsnæs, A. B. Jensen, "Weight watching and the effect of landscape on honeybee colony productivity: Investigating the value of colony weight monitoring for the beekeeping industry," *PLoS ONE*, vol. 10, Jul. 2015, doi: 10.1371/journal.pone.0132473.
- [15] H. Jarimi, E. Tapia-Brito och S. Riffat, "A review on thermoregulation techniques in honey bees' (apis mellifera) beehive microclimate and its similarities to the heating and cooling management in buildings," *Future Cities and Environment*, vol. 6, Aug. 2020, doi: 10.5334/fce.81.
- [16] D. Mitchell, "Nectar, humidity, honey bees (apis mellifera) and varroa in summer: A theoretical thermofluid analysis of the fate of water vapour from honey ripening and its implications on the control of varroa destructor." *Interface*, vol. 16, Maj 2019, doi: 10.1098/rsif.2019.0048.
- [17] Jordbruksverket, "Bin och humlor," [Online]. Tillgänglig: <https://jordbruksverket.se/djur/ovriga-djur/bin-och-humlor> (hämtad: 2022-03-09).
- [18] FAO, "Good beekeeping practices: Practical manual on how to identify and control the main diseases of the honeybee (apis mellifera)," FAO, Rome, Italy, TECA – Technologies and practices for small agricultural producers, nr. 1, 2020. [Online]. Tillgänglig: <https://doi.org/10.4060/ca9182en>, Hämtad: 2022-05-08.
- [19] Plant Health Australia, "Varroa mites," [Online]. Tillgänglig: <https://beeaware.org.au/archive-pest/varroa-mites> (hämtad: 2022-04-03).
- [20] C. Klein, H. Norrman och E. Petersson, "Varroakvalster och bisamhället," gymnasiearbete, Berzeliusskolan, Linköping, Sverige, 2016. [Online]. Tillgänglig: https://alltombiodling.se/wp-content/uploads/Varroakvalster_och_bisamhallet.pdf (hämtad: 2022-03-09).
- [21] P. Kristiansen, "Varroa," *Biodlarna*, [Online]. Tillgänglig: <https://www.biodlarna.se/bin-och-biodling/bihalsa/bisjukdomar-och-parasiter/varroa> (hämtad: 2022-03-09).
- [22] C. Gillespie, "What happens when a queen bee dies?" *Sciencing* [Online]. Tillgänglig: <https://sciencing.com/happens-queen-bee-dies-5159216.html> (hämtad: 2022-03-21).
- [23] University of Georgia, Honey bee program, "Non-infectious diseases and pests," [Online]. Tillgänglig: <https://bees.caes.uga.edu/bees-beekeeping-pollination/honey-bee-disorders/honey-bee-disorders-non-infectious-diseases-and-pests.html#Queenlessness> (hämtad: 2022-05-11).
- [24] Wildflower meadows, "The queenless roar," 2016. [Online]. Tillgänglig: <https://wildflowermeadows.com/2016/12/queenless-roar/> (hämtad: 2022-05-11).
- [25] T.D. Seeley, M. Kleinhenz, B. Bujok, J. Tautz, "Thorough warm-up before take-off in honey bee swarms,"

- Naturwissenschaften*, nr. 90, ss. 256–260, May. 2003.
- [26] D. Trent, “Strain gauge load cell basics,” *Load Cell Central*, [Online]. Tillgänglig: <https://www.800loadcell.com/load-cell-and-strain-gauge-basics.html> (hämtad: 2022-04-04).
 - [27] eFunda, Inc, “Wire,” [Online]. Tillgänglig: https://www.efunda.com/designstandards/sensors/strain_gages/strain_gage_selection_matl.cfm (hämtad: 2022-04-13).
 - [28] R. J. Widlar, “An exact expression for the thermal variation of the emitter base voltage of bi-polar transistors,” *Proceedings of the IEEE*, vol. 55, nr. 1, ss. 96–97, Jan. 1967, doi: 10.1109/PROC.1967.5396.
 - [29] OEM Electronics, “Vad Är en termistor?” [Online]. Tillgänglig: <https://oemelectronics.se/kunskap/vad-aer-en-termistor.html> (hämtad: 2022-05-05).
 - [30] Rotronic, “The capacitive humidity sensor,” [Online]. Tillgänglig: https://www.rotronic.com/en-us/humidity_measurement-feuchtemessung-mesure_de_l_humidite/capacitive-sensors-technical-notes-mr (hämtad: 2022-05-05).
 - [31] *SiSonic Design Guide: Application Note AN24*, Knowles, 2017. [Online]. Tillgänglig: https://www.knowles.com/docs/default-source/default-document-library/sisonic-design-guide.pdf?sfvrsn=ddda77b1_6, Hämtad: 2022-03-23.
 - [32] Britannica, The Editors of Encyclopaedia, “Microcomputer,” [Online]. Tillgänglig: <https://www.britannica.com/technology/microcomputer> (hämtad: 2022-04-04).
 - [33] University Information Technology Services, “Understand measures of supercomputer performance and storage system capacity,” 2021. [Online]. Tillgänglig: <https://kb.iu.edu/d/apeq> (hämtad: 2022-05-12).
 - [34] The Weaver Computer Engineering Research Group, “The gflops/w of the various machines in the vmw research group,” [Online]. Tillgänglig: https://web.eece.maine.edu/~vweaver/group/green_machines.html (hämtad: 2022-05-10).
 - [35] Nanoreview, “Apple iphone 11 pro,” [Online]. Tillgänglig: <https://nanoreview.net/en/phone/apple-iphone-11-pro> (hämtad: 2022-05-10).
 - [36] A. El Gamal, H. Eltoukhy, “Cmos image sensors,” *IEEE Circuits and Devices Magazine*, vol. 21, nr. 3, ss. 6–20, Jun. 2005, doi: 10.1109/MCD.2005.1438751.
 - [37] C. Woodford, “Digital cameras,” *Explainthatstuff!*, [Online]. Tillgänglig: <https://www.explainthatstuff.com/digitalcameras.html> (hämtad: 2022-04-01).
 - [38] R. W. Schafer, “What is a savitzky-golay filter? [lecture notes],” *IEEE Signal Processing Magazine*, vol. 28, nr. 4, ss. 111–117, Jun. 2011, doi: 10.1109/MSP.2011.941097.
 - [39] M. Müller, F. Zalkow, “Log-frequency spectrogram and chromagram,” *International Audio Laboratories Erlangen*, [Online]. Tillgänglig: https://www.audiolabs-erlangen.de/resources/MIR/FMP/C3/C3S1_SpecLogFreq-Chromagram.html (hämtad: 2022-04-24).
 - [40] A. V. Oppenheim, R. Schafer, “From frequency to quefrency: A history of the cepstrum,” *IEEE Signal Processing Magazine*, vol. 21, ss. 95–106, Aug. 2004, doi: 10.1109/MSP.2004.1328092.
 - [41] F. Zheng, G. Zhang och Z. Song, “Comparison of different implementations of MFCC,” *Journal of Computer Science and Technology*, vol. 16, ss. 582–589, Nov. 2001, doi: 10.1007/BF02943243.
 - [42] S. Madhavan, M. T. Jones. Deep learning architectures. *IBM Developer*, [Online]. Tillgänglig: <https://developer.ibm.com/articles/cc-machine-learning-deep-learning-architectures/> (hämtad: 2022-04-22).
 - [43] T. Shah, “About train, validation and test sets in machine learning,” *Towards Data Science*, [Online]. Dec 6, 2017. Tillgänglig: <https://towardsdatascience.com/train-validation-and-test-sets-72cb40cba9e7> (hämtad: 2022-05-03).
 - [44] Y. Sasaki, “The truth of the f-measure,” *Teach Tutor Mater*, Jan. 2007.
 - [45] J. Brownlee, “What is a confusion matrix in machine learning,” *Machine Learning Mastery*, [Online]. Nov. 18, 2016. Tillgänglig: <https://machinelearningmastery.com/confusion-matrix-machine-learning/> (hämtad: 2022-05-08).
 - [46] A. Biswal, “Convolutional neural network tutorial,” *Simplilearn*, [Online]. Feb. 21, 2022. Tillgänglig: www.simplilearn.com/tutorials/deep-learning-tutorial/convolutional-neural-network (hämtad: 2022-04-25).
 - [47] T. Wood, “Softmax function,” *Deep AI*, [Online]. Tillgänglig: <https://deepai.org/machine-learning-glossary-and-terms/softmax-layer> (hämtad: 2022-04-25).
 - [48] H. Tan, K. H. Lim, “Vanishing gradient mitigation with deep learning neural network optimization,” *2019 7th International Conference on Smart Computing Communications (ICSCC)*, 2019, ss. 1–4. [Online]. Tillgänglig: 10.1109/ICSCC.2019.8843652 Hämtad: 2022-05-10.
 - [49] B. Keng, “Residual networks,” *Bounded Rationality*, [Online]. Feb. 18, 2018. Tillgänglig: <https://bjlkeng.github.io/posts/residual-networks/> (hämtad: 2022-04-25).
 - [50] C. Zhang et al., “Gradient descent optimization in deep learning model training based on multistage and

- method combination strategy,” *Security and Communication Networks*, vol. 2021, ss. 1–15, Jul. 2021, doi: 10.1155/2021/9956773.
- [51] Javatpoint, “K-nearest neighbor(knn) algorithm for machine learning,” [Online]. Tillgänglig: <https://www.javatpoint.com/k-nearest-neighbor-algorithm-for-machine-learning> (hämtad: 2022-05-05).
- [52] V. Zwass, “expert system,” *Britannica*, [Online]. Tillgänglig: <https://www.britannica.com/technology/expert-system> (hämtad: 2022-04-07).
- [53] V. Shrimali, “Pytorch for beginners: Image classification using pre-trained models,” *Learn Open CV*, [Online]. Jun. 3, 2019. Tillgänglig: <https://learnopencv.com/pytorch-for-beginners-image-classification-using-pre-trained-models/> (hämtad: 2022-04-25).
- [54] S. Schurischuster, M. Kampel, *VarroaDataset Version 1.2.0*, Zenodo, 2020. Tillgänglig: <https://doi.org/10.5281/zenodo.4085044> (hämtad: 2022-04-01).
- [55] PyTorch, “TORCH.OPTIM,” [Online]. Tillgänglig: <https://pytorch.org/docs/stable/optim.html> (hämtad: 2022-05-03).
- [56] I. Nolasco och E. Benetos, “To bee or not to bee: Investigating machine learning approaches to beehive sound recognition,” in *Workshop on Detection and Classification of Acoustic Scenes and Events (DCASE), 2018*, Zenodo, 2018. Tillgänglig: <https://doi.org/10.5281/zenodo.1321278> (hämtad: 2022-04-01).
- [57] M. Stewart, “Understanding dataset shift,” *Towards Data Science*, [Online]. Dec. 11, 2019. Tillgänglig: <https://towardsdatascience.com/understanding-dataset-shift-f2a5a262a766> (hämtad: 2022-04-25).
- [58] Honey Bee Health Foundation, “Tools for varroa management: A guide to effective varroa sampling control,” HBHC, Keystone, CO, USA, Tools for varroa management: A guide to effective varroa sampling control, nr. 7, 2018. [Online]. Tillgänglig: https://honeybeehealthcoalition.org/wp-content/uploads/2018/06/HBHC-Guide_Varroa_Interactive_7thEdition_June2018.pdf, Hämtad: 2022-04-29.
- [59] IBM Cloud Education, “Overfitting,” 2021. [Online]. Tillgänglig: <https://www.ibm.com/cloud/learn/overfitting> (hämtad: 2022-04-25).
- [60] S. D. Ramsey et al., “Varroa destructor feeds primarily on honey bee fat body tissue and not hemolymph,” *Proceedings of the National Academy of Sciences*, vol. 116, ss. 201818371, Jan. 2019, doi: 10.1073/pnas.1818371116.
- [61] Maxim Integrated, “Parametric specs for temperature sensors,” [Online]. Tillgänglig: <https://www.maximintegrated.com/en/products/sensors/DS18B20.html> (hämtad: 2022-05-01).
- [62] T. Kopczynski, “Five factors that can affect your weighing system’s accuracy,” Hardy Process Solutions, San Diego, CA, USA, 2011. [Online]. Tillgänglig: <https://www.hardysolutions.com/tenants/hardy/documents/5factorsa.pdf> Hämtad: 2022-05-07.
- [63] Europaparlamentet, “Varför minskar bin och andra pollinerare?” 2021. [Online]. Tillgänglig: <https://www.europarl.europa.eu/news/sv/headlines/society/20191129STO67758/varfor-minskar-bin-och-andra-pollinerare-grafik> (hämtad: 2022-05-11).
- [64] S. A.M. Lindström, H. G. Smith, “Konkurrens mellan honungsbin och vilda bin – evidens, kunskapsluckor och möjliga åtgärder,” CEC, Lund, Sverige, CEC Rapport, nr. 6, 2020. [Online]. Tillgänglig: <https://www.cec.lu.se/sv/sites/cec.lu.se.sv/files/2022-01/Web%20%20Konkurrens%20cec%20nr%206.pdf>, Hämtad: 2022-05-11.
- [65] Z. D. Jastrzebski, *Nature and Properties of Engineering Materials*. Wiley International uppl. John Wiley Sons, Inc., 1959.
- [66] R. Huston, H. Josephs, *Practical Stress Analysis in Engineering Design*. 3:e uppl. CRC Press, 2009.
- [67] T. G. Beckwith, *Mechanical Measurements*. 3:e uppl. Addison-Wesley Publishing Co., 1982.
- [68] J. Griffin, “Circuits in practice: The wheatstone bridge, what it does, and why it matters,” YouTube, Maj. 7, 2014, [Video]. Tillgänglig: https://www.youtube.com/watch?v=-G-dySnSSG4&ab_channel=ES.333 (hämtad: 2022-04-13).
- [69] M. Müller, F. Zalkow, “Discrete short-time fourier transform (STFT),” *International Audio Laboratories Erlangen*, [Online]. Tillgänglig: https://www.audiolabs-erlangen.de/resources/MIR/FMP/C2/C2_STFT-Basic.html (hämtad: 2022-04-26).
- [70] Librosa, “librosa.filters.chroma,” [Online]. Tillgänglig: <https://librosa.org/doc/main/generated/librosa.filters.chroma.html#librosa.filters.chroma> (hämtad: 2022-04-26).

A Viktmätning med lastceller och Wheatstonebrygga

Töjningsmätande lastceller består av en metallkropp och fyra trådtöjningsgivare. Metallkroppens elastiska egenskaper kan beskrivas av materialets elasticitetsmodul som definieras enligt

$$E = \frac{\sigma}{\epsilon} \quad (3)$$

där σ är spänningen och ϵ är töjningen [65]. Spänningen σ kan relateras till pålagd kraft F enligt


$$\sigma = \frac{F}{A} \text{ [Pa]} \quad (4)$$

där A är arean som påverkas av kraften [66]. Då metallkroppen deformeras av en last kommer trådtöjningsgivarna tryckas ihop vilket gör att resistansen hos dem minskar [67]. Resistansförändringen hos trådtöjningsgivarna kan relateras till töjningen med den så kallade töjningsfaktorn G_F

$$G_F = \frac{\Delta R/R_G}{\epsilon} \quad (5)$$

vilken är en materialspecifik konstant där ΔR är resistansförändringen, R_G är trådtöjningsgivarens egna resistans och ϵ är töjningen.

Ur en Wheatstonebrygga kan en okänd resistans mätas genom att finna en balanspunkt där både spänningen och strömmen mellan punkterna B och D är noll [68].



Figur 16: Kopplingsschema för en Wheatstonebrygga. Fyra resistanser, tre kända varav en justerbar samt en okänd, kopplas i en bryggkrets. En galvanometer placeras mellan två motstående noder i bryggkretsens.

Balanspunkten hittas genom att variera resistansen R_2 tills V_g blir noll. Från Kirchoffs första lag fås då

$$\begin{aligned} I_3 - I_x + I_G &= 0 \\ I_1 - I_2 - I_G &= 0 \end{aligned} \quad (6)$$

Från Kirchoffs andra lag ställs en potentialvandring upp i slingorna ABDA och BCDB, och använder sedan att spänningsskillnaden mellan punkt B och D är noll i balanspunkten vilket innebär $I_G = 0$. Detta ger

$$\begin{aligned} (I_3 \cdot R_3) - (I_G \cdot R_G) - (I_1 \cdot R_1) &= 0 \xrightarrow{I_G=0} I_3 \cdot R_3 = I_1 \cdot R_1 \\ (I_x \cdot R_x) - (I_2 \cdot R_2) + (I_G \cdot R_G) &= 0 \xrightarrow{I_G=0} I_x \cdot R_x = I_2 \cdot R_2 \end{aligned} \quad (7)$$

Kombineras Ekvation 6 och 7 kan R_x lösas ut enligt

$$R_x = \frac{R_3 \cdot R_2}{R_1} [\Omega]. \quad (8)$$

Alternativt, om galvanometerens resistans är så hög att I_G är försumbar blir $I_1 = I_2$ och $I_3 = I_x$. Med hjälp av Ohms lag får vi då

$$\begin{aligned} I_{1,2} &= \frac{V}{R_1 + R_2} [\text{A}], \\ I_{3,x} &= \frac{V}{R_3 + R_x} \end{aligned} \quad (9)$$

Även följande spänningsskillnader kan ställas upp med Ohms lag enligt

$$\begin{aligned} V_D - V_C &= I_{1,2} R_2 \stackrel{(9)}{=} \frac{V R_2}{R_1 + R_2} [\text{V}], \\ V_B - V_C &= I_{3,x} R_x \stackrel{(9)}{=} \frac{V R_x}{R_3 + R_x} \end{aligned} \quad (10)$$

Galvanometern mäter spänningsskillnaden

$$V_G = V_D - V_B = (V_D - V_C) - (V_B - V_C). \quad (11)$$

Insättning av Ekvation (10) i (11) ger

$$\begin{aligned} V_G &= V \left(\frac{R_2}{R_1 + R_2} - \frac{R_x}{R_3 + R_x} \right) \iff \\ R_x &= \frac{R_2 \cdot V - (R_1 + R_2) \cdot V_G}{R_1 \cdot V + (R_1 + R_2) \cdot V_G} R_3. \end{aligned} \quad (12)$$

Den okända resistansen kan då mätas före och efter pålagd vikt och på så sätt kan en resistansförändring ΔR fås enligt $\Delta R = R_x^{\text{före}} - R_x^{\text{efter}}$ där $R_x^{\text{före}}$ och R_x^{efter} beräknas enligt Ekvation (8) alternativt Ekvation (12) beroende på galvanometerens egenskaper. Resistansförändringen vid pålagd vikt på en lastcell kan alltså mätas i Wheatstonebryggan genom att hitta R_x före och efter pålagd last. Genom att kombinera Ekvation (3), (4) och (5) kan den sökta kraften F lösas ut enligt

$$F = \frac{\Delta R E A}{G_F R_G} [\text{N}]. \quad (13)$$

Vikten på objektet m som orsakar den pålagda kraften F kan slutligen beräknas genom att dividera med tyngdaccelerationen g enligt


$$m = \frac{F}{g} = \frac{\Delta R E A}{g G_F R_G} [\text{kg}].$$

B Temperaturmätning med kiseldioder

En av de vanligaste digitaltermometrarna består av två kiseldioder kopplade i en Brokaw-bandgaps-referenskrets. Framspänningen hos kiseldioder, vilka i detta specifika fall representeras av bas-emitterövergången hos bipolära NPN-transistorer, är temperaturberoende enligt

$$V_{BE} = V_{G0} \left(1 - \frac{T}{T_0} \right) + V_{BE0} \left(\frac{T}{T_0} \right) + \left(\frac{n k_B T}{q} \right) \ln \left(\frac{T_0}{T} \right) + \left(\frac{k_B T}{q} \right) \ln \left(\frac{I_C}{I_{C0}} \right) [\text{V}] \quad (14)$$

där T är temperaturen som dioden upplever och T_0 är en referenstemperatur [28]. V_{G0} är bandgapsspänningen vid absoluta nollpunkten, V_{BE0} är korsningspunktsspänningen vid T_0 och styrström I_{C0} som matas till basingången på transistoren. k_B är Boltzmanns konstant, I_C är strömmen som går genom transistoren från kollektorn, q är elementarladdningen och n är en komponentberoende konstant. Med hjälp av en Brokaw-bandgaps-referenskrets, se Figur 17, kan spänningsskillnaden mellan två transistorer med samma temperatur men som opererar med olika ström mätas.



Figur 17: Kopplingsschema för en Brokaw-bandgaps-referenskrets. Kretsen består av två NPN-transistorer Q_1 och Q_2 , en operationsförstärkare och fyra resistanser.

Spänningsskillnaden $\Delta V_{BE} = V_{BE1} - V_{BE2}$ kan beräknas genom att ställa upp Ekvation (14) för de två transistorerna Q_1 och Q_2 och förenklas enligt

$$T = \frac{\Delta V_{BE} \cdot q}{k_B \cdot \ln\left(\frac{I_{C1}}{I_{C2}}\right)} \text{ [K]}. \quad (15)$$

Enligt Ekvation (15) kan alltså temperaturen T beräknas genom att mäta spänningsskillnaden ΔV_{BE} mellan de två transistorerna.

C Teoretisk fördjupning i metoder för dataanalys

Nedan presenteras hur en signal kan filtreras genom Savitzky-Golay filtrering samt hur kromagrammet och mel frequency cepstra coefficients för en signal kan beräknas.

Notationskommentar: I avsnitten nedan används notationen $f[x]$ för att markera att funktionen f har en definitions mängd som är diskret.

C.1 Savitzky-Golay filtrering av en signal

Följande process används för att Savitzky-Golay filtrera en signal [38]. Antag att signalen består av datapunkter $x[i]$. Tag en datapunkt $x[i]$ samt de $2m$ närmsta datapunkterna. Anpassa därefter ett polynom av grad k , $k < 2m + 1$, till punkterna, som ges av $x[i + j]$, $j = -m, -m + 1, \dots, m$. Låt polynomet vara $p(j) = a_0 + a_1j + a_2j^2 + \dots + a_kj^k$. En minstakvadratanpassning av $p(j)$ till datapunkterna kan nu göras och varje koefficient a_n i polynomet blir en funktion av $x[i + j]$, $\forall j$. Det går allmänt att visa att

$$a_n = \sum_{j=-m}^m b_{n,j} x[i + j],$$

för några koefficienter $b_{n,-m}, \dots, b_{n,m}$ som är oberoende av x . Låt nu det nya värdet, $\tilde{x}[i]$, av datapunkt i ges av det anpassade polynomet enligt

$$\tilde{x}[i] = p(0) = a_0 = \sum_{j=-m}^m b_{0,j} x[i + j].$$

Denna beräkning görs för varje datapunkt, i , i signalen. Eftersom $b_{0,-m}, \dots, b_{0,m}$ enbart beror på det anpassade polynoms grad, k , samt antal närliggande datapunkter som tas med, $2m$, behöver dessa värden enbart beräknas en gång eller kan hämtas ur tabell. Detta gör att filtreringen kräver relativt få beräkningar. Man kan också visa att $\sum_{l=i-m}^{i+m} b_{0,l} = 1$, vilket gör att applicering av Savitzky-Golay filter kan tolkas som en viktad medelvärdesbildning i varje datapunkt.

C.2 Metod för beräkning av kromagram

Kromagrammet för en ljudsignal under en tidsperiod kan beräknas med följande process [39], [69], [70]. Först tas spektrogrammet för signalen fram, vilket representerar signalens energiinnehåll som en funktion av frekvens och tid. Detta görs med en Short-time Fourier Transform (STFT), som för en kontinuerlig signal, $F(t)$, definieras enligt

$$\text{STFT}\{F(t)\}(f, \tau) = \int_{-\infty}^{\infty} F(t)w(t - \tau)e^{-2\pi ift} dt,$$

där $w(t)$ är en lämplig fönsterfunktion. Således erhålls signalens frekvensinnehåll som en funktion av tid, τ . Genom att diskretisera formeln ovan erhålls definitionen för Discrete Short-time Fourier Transform (DSTFT). Antag att en signal $x[n]$ är tidsdiskret och samplad med en frekvens F från ursprungssignalen $F(t)$. Antag också att fönsterfunktionen, $w[n]$, är definierad för $n \in \{0, 1, \dots, N - 1\}$. Då kan DSTFT:n beräknas med formeln

$$\text{DSTFT}\{x[n]\}[m, k] = \sum_{n=0}^{N-1} x[n + mH]w[n]e^{-2\pi i kn/N}.$$

Indexen $m \in \{0, 1, \dots, M\}$ och $k \in \{0, 1, \dots, K\}$ relaterar då till τ och f enligt $\tau = mH/F$ samt $f = kF/N$. H är en parameter som används för att bestämma upplösningen i τ för DSTFT:n. Vanligtvis implementeras denna formel med en Fast Fourier Transform algoritm, vilket resulterar i en snabb beräkning. Resultatet blir en $(M + 1) \times (K + 1)$ matris, från vilken spektrogrammet, S , bildas med följande formel

$$S_{mk} = |\text{DSTFT}\{x[n]\}[m, k]|^2.$$

Därefter appliceras en filtermatris, A , som innehåller information om vilka frekvenser som ingår i vilka toner. Om de vanliga 12 tonerna används blir dimensionerna för A därmed $12 \times (K + 1)$. Ett enkelt sätt att konstruera A på är att välja $A_{ik} = 1$ om $f = kF/N$ ingår i ton i och $A_{ik} = 0$ annars. Kromagrammet, C , erhålls slutligen från spektrogrammet genom $C = AS$.

C.3 Metod för beräkning av mel frequency cepstra coefficients

Mel frequency cepstra coefficients (MFCC:s) kan beräknas med följande process [41]. Antag att signalen, $F[t]$, som ska analyseras är tidsdiskret och samplad med en konstant frekvens. Först beräknas Fouriertransformen av signalen under den sökta tidsperioden. Ett enkelt sätt att göra detta på är att använda en Discrete Short-time Fourier Transform (se ovan för definitionen av denna) och sedan välja ett specifikt m -index. Ett annat sätt är att först multiplicera signalen med en lämplig fönsterfunktion och därefter använda en vanlig diskret Fouriertransform. Därefter bildas effektspektrumet genom $P[f] = |\hat{F}[f]|^2$. Detta omvandlas sedan till en funktion av melfrekvensen, m , genom formeln för melfrekvens

$$m(f) = 2595 \log_{10}(1 + f/700).$$

Effektspektrumet som funktion av mel-frekvens, $P[m]$ nedsamlas sedan genom att samla närliggande värden. Resultatet blir ett nytt mer "glost" effektspektrum, $\theta[m_l]$, $l = 1, \dots, L$, som bildas genom

$$\theta[m_l] = \sum_m P[m - m_l] \phi(m),$$

där ϕ är en filterfunktion som vanligtvis är triangelformad och symmetrisk kring 0 och m_l är placerade med lika mellanrum. Alternativt om θ är vektorn $[\theta[m_1] \dots \theta[m_L]]^T$ och P är vektorn med alla M värden för $P[m]$ så kan θ beräknas med $\theta = AP$, där A är en $L \times M$ filtermatris. Efter detta steg logaritmeras spektrumet enligt $X[l] = \ln \theta[m_l]$. Slutligen bildas MFCC:s genom att applicera en diskret cosinustransform på $X[l]$ enligt

$$\text{MFCC}[d] = \sum_{l=1}^L X[l] \cos\left(\frac{\pi}{L} d \left(l - \frac{1}{2}\right)\right),$$

för $d = 1, \dots, D$, där D kan väljas fritt.

INSTITUTIONEN FÖR FYSIK
CHALMERS TEKNISKA HÖGSKOLA

Göteborg, Sverige
www.chalmers.se



CHALMERS