



DIGITALA SYSTEM
SMART INDUSTRIAL
AUTOMATION



Processoptimering med hjälp av Artificiell Intelligens i glasbruk. Slutrapport

Mats Tallfors, Göran Bäcklund, Kristian Haller, Katya
Mishchenko

Abstract

Denna rapport beskriver allt arbete och alla resultat i projektet “Processoptimering med hjälp av Artificiell Intelligens i glasbruk” som syftar till att utveckla och implementera avancerade system för datainsamling och analys för att förbättra kvaliteten på glasmassa.

Rapporten omfattar flera delmoment, inklusive utveckling av ett fysiskt datainsamlingssystem, uppladdning och sammanställning av data, samt skapandet av en webbsida för datainmatning. Vidare inkluderar rapporten automatisk analys av glaspuckar med hjälp av maskininlärning, där experiment och modellträning sammanfattas och framtida steg diskuteras. Ett maskininlärningsverktyg har utvecklats för att förbättra glasmassans kvalitet genom noggrann databehandling och algoritmutveckling. Rapporten undersöker även detektering av bubblor i varm glasmassa med ultraljudsteknik. Slutligen sprids rapportens resultat och lärdomar, inklusive erfarenheter från datainsamlingssystemet och arbetet under Covid-pandemin, samt en sammanfattning från slutpresentationen.

Innehåll

Abstract.....	2
Innehåll.....	3
1 Projektbeskrivning	4
1.1 Projekt sammanfattning.....	4
1.2 Projektmål och Projektleverabler.....	4
2 Projektnytt.....	5
2.1 Datainsamlingssystem.....	5
2.1.1 Fysiskt datainsamlingssystem.....	5
2.1.2 Uppladdning av data	7
2.1.3 Websida för inmatning av data	8
2.1.4 Sammanställning av data	9
2.2 Automatisk analys av glaspuckor (glaskroppar)	10
2.2.1 Sammanfattning av experiment och dataset.....	10
2.2.2 Sammanfattning av modellträningen	10
2.2.3 Möjliga framtida steg.....	11
2.3 Maskininlärningsverktyg för förbättring av glasmassakvalité.....	11
2.3.1 Databehandling	11
2.3.2 Maskininlärningsalgoritmen	12
2.3.3 Resultat av maskininläring	13
2.4 Detektering av bubblor i varm glasmassa med ultraljud	15
2.5 Spridning av information	15
3 Lessons Learned	16
3.1 Datainsamlingssystem.....	16
3.1.1 Fysiskt datainsamlingssystem.....	16
3.1.2 Datainsamlingssystem (Zenta).....	16
3.2 Projektarbete och arbetssätt.....	17

1 Projektbeskrivning

1.1 Projekt sammanfattning

Glasbruk jobbar idag med en glasmassa med variationer som är svåra att förutsäga även när produktionen verkar ske likadant mellan olika smältor. Den materialkontroll som görs tillhandahåller endast resultat flera timmar senare efter att glaset har svalnat och då är det för sent att påverka resultatet.

I projektet identifierades de variabler som påverkar kvaliteten på glasmassan mest och har tagit fram metoder för att mäta dessa faktorer och identifiera deras effekter på glaskvaliteten. Projektet hade också som mål att kunna påverka eller motverka de effekter av faktorerna som försämrar glaskvaliteten, men glasbruken har ännu inte implementerat resultaten i sin produktion. Resultaten analyserades med hjälp av AI där deep learning användes för att identifiera kvaliteten på glaset via bildigenkänning. Machine learning användes för att analysera data och korrelera effekterna med resultaten av bildigenkänningen. Målet var att implementera metoden på glasbruken med en programvara som kontinuerligt utför operationerna och ger feedback i den dagliga processen, men automatiseringen har inte slutförts inom projektet. "Acoustic Agree" har testat sin NAW®-teknik för att detektera bubblor i glas. Resultatet av deras arbete presenteras i rapporten **Detektering av lusor och bubblor i smält glas med NAW®-inspektion**.

1.2 Projektmål och Projektleverabler

Målet med projektet är att utveckla ett system för datainsamling, analys och återkoppling för att optimera glaset. Projektet inkluderar följande leverabler:

- 1) Datainsamlingssystem (se även kapitel 2.1)
 - Typ: Konceptbevis
 - Ansvarig: Zenta leder arbetet med utvecklingen med stöd från RISE AI forskare.
 - Mål: Digital plattform där data lagras och tvättas för att göras enhetlig och därmed tillgänglig för analys. Systemet ägs och supporteras av Zenta och tänkta kunder är glasbranchen.
- 2) Datainsamling (se även kapitel 2.1)
 - Typ: Konceptbevis
 - Ansvarig: RISE leder arbetet i nära samarbete med glasbruk och Glasma
 - Mål: Kontrollerad datainsamling med tillräckligt hög kvalitet för användning i dataanalys. Detta innefattar både indata från smältprocessen samt resultatvärden från provkroppar.
- 3) Analysverktyg för bubblor
 - Typ: Demonstrator
 - Ansvarig: RISE
 - Mål: Identifierat verktyg för automatisk analys av glaskroppar effektivare än manuell analys. Mottagare av denna produkt kommer vara glasbruken
- 4) Dataträning
 - Typ: Konceptbevis

- Ansvarig: Zenta med stöd av RISE AI forskare
 - Mål: Tränat machine learning-verktyg med hjälp av data insamlad från glasbruken
- 5) Dataanalys
- Typ: Demonstrator
 - Ansvarig: Zenta med stöd av RISE AI forskare
 - Mål: Genomförd dataanalys som predikterar analys av glaskropp. Mottagare av denna tjänst kommer vara glasbruken och verktyget kommer ägas av Zenta.
- 6) Rapport
- Typ: Rapport
 - Ansvarig: RISE
 - Mål: Rapport skapad för spridning av information och som stöd för likande arbeten i framtiden.
 - Rapporten riktar sig till glasbranschen och branscher med liknande utmaningar

2 Projektresultat


2.1 Datainsamlingssystem

2.1.1 Fysiskt datainsamlingssystem

2.1.1.1 Systemuppbyggnad

Datainsamlingssystemet samlar in data från ugnar och från pelletsförråd i glasbruken. Arduino controllers samlar in mätdata från givarna till som i sin tur skickar data vidare via USB till Raspberry PI 4 vid ugnarna (se

Ugn



Figur 1) och till Windows-PC i pelletsförråden (se Figur 2). Vid ugnarna sitter dessutom PICO dataloggers som samlar in mätdata från termoelement i ugnarna och skickar

datat vidare via USB till Raspberry PI. Raspberry PI och Windows PC skickar datat via OneDrive över WiFi vidare till molnet.


I de Arduino controllers som används körs en kort programloop som samlar in mätdata och andra signaler från givare och RFID läsare eller tryckknapp och skickar alla data vidare till Raspberry PI via USB.

Raspberryn sitter monterad i en låda med passiv kylning, för att undvika att fläkten slutar att fungera om det t ex fastnar smuts i den. Lådan saknar powerknapp och i lösningen kopplar man upp sig från en annan dator för att komma åt Raspberryn via terminalprogram eller Remote Desktop, så att man kan slå av den på ett säkert sätt. I övrigt förväntas Raspberry PI starta och exekvera program för datainsamling automatiskt då strömförsörjning kopplas in.

Vid ugnarna samlas följande data in:

- Lufttryck i lokalen
- Temperatur i lokalen
- Relativ luftfuktighet i lokalen
- Om operatören tryckt på knappen för att indikera ilägg i ugnen
- Skillnad i tryck i ugnen och utanför ugnen (differentialtryck)
- Temperatur vid två positioner i ugnen.

Schemat i Figur 1 visar hur Raspberry PI, Arduino och PICO logger kopplats samman med varandra och hur de kopplats ihop med respektive givare och tryckknapp vid ugnen.




Figur 1. Datainsamlingssystemet vid ugnar.

Vid pelletsförråden samlas följande data in:

- Temperatur i lokalen

- Relativ luftfuktighet i lokalen
- Dragning av RFID-taggar som motsvarar vagn med pellets och skärv som används.
- Fukthalt i glaspelleten som uppmätts med fuktmätaren.

Schemat i Figur 2Figur 1 visar hur Raspberry PI och Arduino kopplats samman med varandra och hur de kopplats ihop med respektive givare och RFID-läsare vid pelletsförrådet.



Figur 2. Datainsamlingssystem vid pelletslagren.

2.1.1.2 Resultat datainsamlingssystem

Flera problem uppstod vid insamling av mätdata, som vi på grund av brist på tid och pengar fick vi hantera enligt beskrivningen nedan så att vi skulle få tillräckligt lång tidperiod med data.

- Den specade differentialtrycksgivaren visade sig inte ha tillräckligt hög mätupplösning för sammanhanget, så den ger i praktiken inget utslag. Så vi valde att inte använda denna givares mätvärden.
- Det blir ett skalfel i temperaturmätningarna med PICO-loggrarna som vi inte lyckats hitta orsaken till, trots kontakt med tillverkaren av PICO loggrar. Därför har vi valt att använda ugnstemperaturmätningar från glasbrukets utrustning i stället. Det skulle kanske gå att använda data från PICO loggrar trots skalfel, men vi har valt att inte göra det.

2.1.2 Uppladdning av data

Zenta har utvecklat ett konfigurerbart datainsamlingsverktyg som en konsolapplikation i C#. Applikationens syfte är att fånga data från sensorer via den seriella porten och spara

datan lokalt i en CSV-fil som en tidsserie. Tre typer av insamlingsenheter kan konfigureras:

- Netatmo: Ursprungligen var tanken att miljövariabler såsom temperatur och lufttryck skulle hämtas via en väderstation, men detta har senare justerats till att använda sensorer via Arduino
- Arduino: Konfigureras genom att ange portnummer och baudrate. Headers kan ställas in för att identifiera datakolumner baserat på den ordning i vilken data samlas in.
- Pico: Konfigureras med kanal-ID och sensortyp. Picologs eget SDK används för att registrera signalen, och olika DLL-filer krävs beroende på om verktyget används på Windows eller Raspbian.

Konsolapplikationen anropas med sensorns namn (Arduino, Pico) som kommandoargument. Enheterna konfigureras i en lista, vilket möjliggör att flera Pico-loggers eller Arduinos kan vara anslutna till samma insamling.

När en användare drar en RFID-taggs ID som en header i konfigurationen. Verktyget körs i en loop tills all data fångas. Schemalagda jobb på respektive maskin exekverar applikationen varannan minut. Användningen av RFID-taggar beskrivs i stycke 2.1.3 nedan.

Data laddas upp till OneDrive via Wi-Fi när uppkoppling finns. Varje glasbruk har en separat OneDrive-mapp. Eftersom OneDrive inte har en applikation för Raspberr används en open-source programvara Rclone för att hantera synkronisering och uppladdning till molnet. Eftersom Rclone fungerar bättre än OneDrives egen Windows-applikation används det även på Windows-maskiner. Uppladdningen av data sker med schemalagda jobb, och systemet är inte helt beroende av OneDrive eftersom Rclone stödjer de flesta molnbaserade fil lagringsleverantörer på marknaden.

2.1.3 Websida för inmatning av data

För manuell datainmatning har en webbapplikation utvecklats med React som frontend, .NET C# som backend och SQL Server som databas. Applikationen är hostad som en Azure App Service och Continuous Integration är konfigurerad för tre olika miljöer: Test, Stage och Production. Som en SaaS-lösning erbjuder applikationen separata inloggningar för de olika glasbruken.


Operatörerna har tillgång till webbapplikationen via en Windows PC vid pelletsförrådet. Applikationen är uppdelad i tre sektioner:

- Vagnar: Vagnar är kopplade till RFID-taggar. Vid registrering av en vagn måste RFID-taggen identifieras för att kunna matcha korrekt temperatur och fuktmätning till inlägget. Här kan vikt för pellets och skärv fyllas i.
- Ugnar: I denna sektion kopplas en vagn till en ugn. När operatören gör ett inlägg behöver denne trycka på en knapp i webbapplikationen i den här sektionen. Inlägget kopplas då till den senaste påfyllda vagnen.
- Glaspuckar: I den här sektionen kan antalet bubblor i glasspucken från den valda ugnen samt det angivna datumet och tiden registreras.

2.1.4 Sammanställning av data

Data sammanställs från molnet med hjälp av en C#-konsolapplikation. För närvarande körs denna applikation på utvecklarens arbetsstation, men vid produktionssättning kan den övergå till en molnbaserad lösning i Azure. Data synkroniseras med Rclone till en lokal filkatalog genom schemalagda jobb, ett för varje glasbruk och sensor. När filerna är nedladdade, körs ett ytterligare jobb som läser in data från dessa filer och sparar dem i en SQL-databas på en Azure Elastic Pool. Samtidigt hämtas den manuellt sparade datan från webbapplikationens databas och sparas i en struktur som är optimerad för vidare analys. På så sätt blir datan tillgänglig för granskning och för maskininlärningsverktyg. Figur 3 visar en översikt över dataflöden och applikationer.


Datagranskning sker via en Jupyter Notebook, där Python används tillsammans med Plotly för datavisualisering och Pandas för databehandling. Under detta steg förbereds också datan för maskininläring. Granskning av att data kommer in som det ska görs manuellt en gång i veckan.



Figur 3. Översikt över datasynkning mellan glasbruk, molnet och maskininlärningsverktygen.

2.2 Automatisk analys av glaspuckar (glaskroppar)

Ett av målen med projektet var att utveckla ett AI-baserat verktyg för automatisk analys av glaskroppar som är effektivare än manuell analys. Principen bygger på att de glaspuckar som gjuts då en glasmassa smälts fotograferas. Fotografierna skickas till en dator med ett program som använder computer vision för att räkna antalet bubblor.



2.2.1 Sammanfattning av experiment och dataset


- Kamera: Endast mobil
- Ljussättning: Rumsbelysning
- Dataset: 18 puckar, 108 bilder
 - Puckar utan bubblor: 8 st
 - Puckar med bubblor: 10 st:
 - 3 st med enbart små bubblor som kameran inte lyckas fånga;
 - 7 st med en mix av för små bubblor och tillräckligt stora;

Figur 4. Glaskropp med bubblor.

2.2.2 Sammanfattning av modellträningen

För att genomföra objekt-detektion inom datorseende användes AI-mjukvaran YOLOv8. Träningen utfördes på hela bilder, även om dessa skulle kunna delas upp i mindre bitar för potentiellt bättre resultat.

Tyvärr visade sig resultaten vara mindre användbara, vilket främst berodde på bristen på tillräckligt med data, se bild nedan.



Figur 5. Exempler på riktiga (vänster) och detekterade (höger) bubblor i glaskroppar.

2.2.3 Möjliga framtida steg

För att förbättra och utöka datasetet kan vi börja med att inkludera fler puckar och använda bättre kameror och ljussättning. Vi kan också förstärka datasetet med syntetiska bilder skapade i en 3D-grafikmjukvara. Därefter tränar vi objekt-detektion på det uppdaterade datasetet.

För att testa anomalidetektion tränar vi på bilder utan bubblor, så att bubblor identifieras som avvikelser. Ett exempel på open source-mjukvara för detta ändamål är Anomalib: <https://github.com/openvinotoolkit/anomalib>.

Sammanfattningsvis kan vi konstatera att problemet kan med stor sannolikhet lösas med den nuvarande AI-tekniken, förutsatt att man har tillgång till ett utökat och högkvalitativt dataset.

2.3 Maskininlärningsverktyg för förbättring av glasmassakvalité

2.3.1 Databehandling

För varje smältprocess genomförs flera inlägg med glas skärv och pellets. Inledningsvis görs ett inlägg med glas skärv från en vagn, följt av flera inlägg med pellets från samma vagn. Vikt och tillhörande vagn registreras i webbapplikationen. Därefter mäts fukt och temperatur för både glas skärv och pellets vid pelletsförrådet. När flera inlägg görs från samma vagn antas ett linjärt samband mellan temperatur och massa.

Under smältprocessen höjs ugnens temperatur till över 1340 grader och hålls på denna nivå under ett antal timmar. Vi har valt att undersöka följande sex variabler som input till vår modell:

- Vikt
- Fukt: Fuktmätning från pelletsförrådet

- Temperatur: Temperaturmätning från pelletsförrådet
- Typ: 1 för glas, 0 för pellets
- Medelvärde för högsta ugnstemperatur under smältprocessen
- Antal timmar vid högsta ugnstemperatur

De etiketter som används som output för vår modell har vi valt att hämta från Målerås egen kassationsrapport, där vi har tillgång till en lång historik av data. Rapporten ger information om andelen produkter av en viss artikel från en smälta som har kasserats på grund av blåsor. Om andelen kassationer på grund av blåsor för en artikel i en specifik smälta överstiger det statistiska medelvärdet för kassation av artikeln för alla smältor, klassificeras artikeln som dålig; annars klassificeras den som bra. Om en för stor andel av artiklarna i en smälta är dåliga, bedöms hela smältan som dålig.

2.3.2 Maskininlärningsalgoritmen

För att bygga och testa modeller har vi använt Python-biblioteket Scikit-learn (Sklearn).

Vi har utnyttjat Sklearns inbyggda metoder för korsvalidering genom att rotera datasetet så att olika delar används som tränings- och testdata vid varje iteration. Detta säkerställer att modellen tränas och testas på varierande data.

För att effektivisera processen har vi använt pipelines, som gör det möjligt att kedja samman flera steg och korsvalidera dem tillsammans. Varje steg i pipeline representerar en transformation eller en modell, vilket garanterar att alla operationer är korrekt ordnade och utförs under både tränings- och testfaserna.

En pipeline definierar:

- En skalare för att förbehandla indata
- En väljare för att identifiera de mest relevanta parametrarna
- En modell

Genom att definiera flera pipelines kommer vår algoritm att iterera genom dem och välja den pipeline som presterar bäst.


Vi använder också korsvalidering med GridSearchCV för att optimera hyperparametrarna och hitta de som ger bästa resultat för modellen. För varje pipeline definieras en parametergrid som specificerar de hyperparametrar som ska testas. Vi har utvärderat flera klassificeringsmodeller från Scikit-learn, inklusive K-Neighbors, Naive Bayes, Decision Tree, Random Forest, Logistic Regression, Gradient Boosting, Bagging, Support Vector Machines samt Neural Network från Keras-biblioteket.

För att utvärdera resultaten använder vi förvirringsmatriser och inlärningskurvor. Inlärningskurvor visar hur modellens prestanda utvecklas över tid eller med mängden träningsdata.

2.3.3 Resultat av maskininlärning

Data bestod av 178 inlägg motsvarande 38 smältor där 95 inlägg predikteras mot kvalitet 0 (sämre) och 83 inlägg mot kvalitet 1 (bättre). Där ett tröskelvärde på 17 procent har satts för att bedöma kvaliteten på smältan.

Logistic Regression med en poäng på 83% har visat sig ge bästa resultat för att klassificera mängden bubblor i glaset.



Figur 6. Förrvirringsmatris


På vertikala axeln i figur 6 visas de verkliga etiketterna och på den horisontella axeln de uppskattade. De korrekta uppskattningarna kommer då hamna på diagonalen från övre vänstra hörnet till nedre högra. Från bilden kan vi se att 73 stycken etiketter av kvalitet 0 har matchats korrekt ut av modellen medan 22 stycken har blivit felaktigt uppskattade att ha kvalitet 1 omvänt kan vi se att 12 stycken av kvalitet 1 har blivit feluppskattade att ha kvalitet 0 av modellen och 71 stycken av kvalitet 1 har blivit korrekt uppskattade.



Figur 7. Inlärningskurva

Inlärningskurvan i figur 7 visar tidig konvergens och en god balans mellan tränings- och valideringspoängen, vilket antyder att ytterligare data inte skulle leda till betydande förbättringar. Både träningspoängen och valideringspoängen är höga, omkring 0,8, och ligger nära varandra. Detta indikerar att modellen har lärt sig mönstren i träningsdatan effektivt och kan tillämpa dem på ny data med god generaliseringsförmåga.

De parametrar som visat sig påverka mängden bubblor mest är fukt, temperatur och medelvärde för högsta temperatur under smältprocessen. Genom att analysera data för de olika parametrarna i samma diagram för att se relationen kan man ta fram generella råd till glasbruket.



Figur 8. 3D-plot på samband mellan parametrarna och klasserna

I Figur 8 representerar de stora punkterna glas med kvalitet 1, medan de små punkterna representerar glas med kvalitet 0. Punkter som är färgade svarta indikerar felklassificeringar under modellträningen. Genom att markera gränsvärden i diagrammet kan vi identifiera de intervall där glasets kvalitet är som bäst.

- Fuktighet mellan 30% och 60% relativ luftfuktighet (RH)
- Temperatur mellan 10 C° och 25 C°
- Medeltemperatur i ugnen mellan 1348 C° och 1350,55 C°

Anledningen till att kassationsrapporten används som primär datakälla istället för analysresultaten från glaspuckarna är att rapporten har en lång historik av värden,

medan endast sex smältor med tillhörande glaspuckar ingår i undersökningen. Detta ger ett för litet datamaterial för att möjliggöra en tillförlitlig maskininlärningsanalys.

Korrelationen mellan glaspuckarnas egenskaper och värdena i kassationsrapporten är svag och inte statistiskt signifikant. Av de 18 puckarna saknar sex synliga bubblor, trots att de kommer från smältor som klassificerats som undermåliga i kassationsrapporten. En glaspuck med en mindre bubbla kommer från en smälta som bedömts som godkänd från kassationsrapporten. Den begränsade datamängden gör det dock svårt att dra tillförlitliga slutsatser.

Även om Logistic Regression presterar bra med de tillgängliga data, är datamängden för liten för att modellen ska kunna nå sin fulla potential. Med en större datamängd, särskilt från fler smältor och glaspuckar, skulle modellen sannolikt förbättras avsevärt och kunna generera mer pålitliga och robusta prediktioner av glasets kvalitet.

2.4 Detektering av bubblor i varm glasmassa med ultraljud

Acoustic Agree har testat sin NAW®-teknik för att detektera bubblor i glas, och resultaten presenteras i rapporten "Detektering av lusor och bubblor i smält glas med NAW®-inspektion". Tekniken användes för att identifiera defekter som blåsor, bubblor och lusor i smält glasmassa. Studien omfattade både bubblor i glukos och glastillverkning på Målerås Glasbruk. Ett mätsystem konfigurerades för att detektera bubblor under produktion, och grafitformar till inspektion producerades och användes. Resultaten visade en tydlig korrelation mellan skadevärde och antalet bubblor i provet, vilket innebär att glaskvaliteten kan bestämmas tidigt i produktionsprocessen. Detta kan hjälpa glasindustrin att förbättra lönsamheten genom att lösa ett av sina kvalitetsproblem.

Resultaten visade generellt en låg förekomst av bubblor och lusor. Inom provgruppen hade prov 1, som representerar glasmassan högst upp i degeln, det lägsta skadevärdet och den lägsta förekomsten av lusor och bubblor. Prov 10 hade det högsta skadevärdet, vilket innebär den högsta förekomsten av lusor och bubblor.

2.5 Spridning av information

Rapport skapad för spridning av information och som stöd för likande arbeten i framtiden. Rapporten riktar sig till glasbranschen och branscher med liknande utmaningar.

3 Lessons Learned

3.1 Datainsamlingssystem

3.1.1 Fysiskt datainsamlingssystem

3.1.1.1 Systemuppbyggnad

Det har tagit betydligt längre tid än planerat att ta fram ett system som löser överföring av data på ett robust sätt. Genom att återanvända den framtagna systemuppbyggnaden kan mycket tid besparas i andra kommande projekt. Även om andra data ska samlas in i andra sammanhang, är det värt mycket att slippa starta från noll. Det finns fortfarande flera problem i systemet som skulle behöva lösas för att ytterligare förenkla återanvändning av lösningen. Valet att använda Raspberry PI 4 verkade kostnadseffektivt, men har orsakat många problem på vägen som krävt mycket tid att lösa. Text att det blir ett skalningsfel i temperaturmätningarna med PICO-loggrarna som vi inte lyckats hitta orsaken till, trots kontakt med tillverkaren av PICO loggrar, har krävt både att dataloggning försenats och att projekttid lagts ned på att försöka hitta felet. Exempel på svagheter med med Raspberry PI 4. Den saknar powerknapp. Om strömmen bryts finns det risk att SD-kortet med operativsystem, programvara och data skrivs sönder. Mjukvaran till PICO-loggern är inte tillräckligt testad.

En bättre kamera som kan ta fler bilder med olika fokus skulle kunna fånga alla bubblor olika långt ner i glaset.

3.1.2 Datainsamlingssystem (Zenta)

Prototypen för datainsamlingen har testats på tre olika glasbruk: OKB, Reijmyre och Målerås. Vi har verifierat att dataöverföringarna fungerar som förväntat genom att etablera ett system för datagranskning. Initialt uppstod problem med dataluckor, vilket vi åtgärdade genom att byta applikation för synkronisering mellan enheten och molnet. Den nya synkroniseringslösningen visade sig dock vara resurskrävande och belastade bandbredden, särskilt eftersom OKB hade en begränsad datamängd på sitt abonnemang. Eftersom det är svårt att optimera överföringarna är det mer kostnadseffektivt att uppgradera abonnemanget.

Den manuella datainsamlingen via webbapplikationen har testats på Målerås. Efter ett möte mellan Zenta och Målerås har vi kommit fram till en bra arbetsrutin som gör att data kan användas så effektivt som möjligt som underlag för dataanalysen.

Eftersom arbetsrutiner kan variera mellan olika glasbruk behöver liknande dialoger och anpassningar eventuellt behövas, när fler användare ska börja använda plattformen.

En del förundersökningar på möjligheten att använda olika molnbaserade verktyg gjordes under projektets gång dels för att kunna skala när datamängden växer och för att kunna automatisera processen på sådant sätt att direkt återkoppling till glasbruken skulle kunna

ske. Men eftersom datainsamlingen drog ut på tiden och vi bara hade en begränsad datamängd att jobba med, så fokuserade vi på dataanalysen.

3.2 Projektarbete och arbetssätt

Test och igångkörning av utrustning för insamling av data från glasbruken drog ut på tiden då dåvarande projektledare inte fick besöka glasbruken på grund av covid under flera månader.

På grund av att ett stort antal nyckelpersoner i projektet, hos flera projektpartners, slutat under projektet har projektsamarbetet påfrestats rejält. Detta har medfört extra förseningar i projektet. Glasbrukens förtroende för projektet minskade under projektsgång på grund av bristen på kännedom hos den nya RISE projektgruppen om både projektet och glasbruksindustrin, vilket behövdes hanteras under projektledningens arbetspaket.

I slutet av projektet höll vi en online slutpresentation med alla projektmedlemmarna som inkluderade en ”lessons learned” session för att diskutera lärdomar från projektet. Några av förbättringsförslag är följande:

- **Förväntningshantering: Mål kontra budget:** Kommunicera tydligt vad som är realistiskt att uppnå inom budgeten. Regelbundna uppdateringar och flexibilitet är nyckeln.
- **Tidsuppskattning för datainsamling och installation av utrustning:** Planera noggrant och ta hänsyn till möjliga förseningar.
- **Bättre rutiner vid överlämning av resultat och uppgifter:** Dela information mellan projektmedlemmar i god tid och ha regelbundna avstämningar. Utse en ansvarig för överlämningar och skapa en tydlig plan.
- **Projektteam:** Om möjligt, skapa en grupp från varje företag i stället för att endast involvera en person.

Men projektmedlemmar framhävde också några positiva delar av projektet och projekts genomförande:

- **Spridning av kunskap mellan olika partners:** Projektet har effektivt delat kunskap och insikter mellan alla involverade parter, vilket har främjat samarbete och gemensam förståelse.
- **Resultat som öppen källkod:** De uppnådda resultaten har gjorts tillgängliga som öppen källkod, vilket innebär att alla kan använda och dra nytta av dem.
- **Användbara och vidareutvecklingsbara resultat:** Projektet har levererat resultat som inte bara är användbara i sin nuvarande form, utan också kan vidareutvecklas för framtida tillämpningar.
- **Projektet kan fungera som en startpunkt och grund för framtida initiativ inom lusedetektering.**

Några förslag på de nästa steg i projektet, (efter projekts slut) är:

- Skapa en visuell presentation av resultaten och projektet bör skapas för att kunna delas på sociala medier.
- Presentera resultaten och gör informationen tillgänglig så att andra kan fortsätta där vi avslutar.



RISE Research Institutes of Sweden AB Box 857, 501 15 BORÅS Telefon: 010-516 50 00 E-post: info@ri.se , Internet: www.ri.se	Smart industrial automation : ISBN:
---	--