



CHALMERS
UNIVERSITY OF TECHNOLOGY



Artificiell Intelligens för Detektionsproblem inom Industriella Kontinuerliga Processer

Kandidatarbete vid Institutionen för Elektroteknik

Oskar Lundström, Casper Lindberg, Arvid Persson, Martin Willbo, Filip Jo-

KANDIDATARBETE 2019:VT

Artificiell Intelligens för Detektionsproblem inom Industriella Kontinuerliga Processer

Oskar Lundström, Casper Lindberg, Arvid Persson, Martin Willbo, Filip
Johansson Gunnarsson, Klas Svensson Qvistberg



Institutionen för Elektroteknik

Avdelningen för Signalbehandling och medicinsk teknik

EENX15-19-25

CHALMERS TEKNISKA HÖGSKOLA

Göteborg 2019

© Oskar Lundström, 2019

© Casper Lindberg, 2019

© Arvid Persson, 2019

© Martin Willbo, 2019

© Filip Johansson Gunnarsson, 2019

© Klas Svensson Qvistberg, 2019

Handledare: Thomas Rylander, institutionen för Elektroteknik

Examinator: Tomas McKelvey, institutionen för Elektroteknik

Kandidatarbete 2019:VT

Institutionen för Elektroteknik

Avdelningen för Signalbehandling och medicinsk teknik

EENX15-19-25

Chalmers Tekniska Högskola

SE-412 96 Göteborg

Abstract

Today, there is an increasing risk that plastics end up in products that we eat. FRS AB is capable of detecting objects such as wood, plastic and bone matter in pumpable products, which other systems like X-ray and metal detectors can not detect. However, FRS AB is not able to detect objects in very inhomogeneous substances. This research study investigates the use of statistical methods and artificial intelligence to detect dielectric objects in inhomogeneous dielectric substances. To collect data, an experimental set-up was built to simulate the process in a factory where the product is transferred in pipes. A product imitation is created for testing in the experimental set up. The result of the detection methods show difficulty in detecting dielectric objects in inhomogeneous dielectric substances. Nevertheless, more research is needed to determine whether artificial intelligence can be used to detect dielectric objects in inhomogeneous dielectric substances. The results from the experiments conducted in this study seemed to be reliable. Hence, the experimental set-up and product imitation was probably sufficient for this purpose.

Tillkännagivanden

Vi vill visa vår tacksamhet till alla som hjälpt oss på vägen. Tack till vår handledare Thomas Rylander och Simon Nilsson för all rådgivning och hjälp med projektet. Vi vill även tacka Joakim Nilsson och Stig Norén på FRS AB för hjälp med de experimentella delarna av projektet.

Innehåll

Figurer	viii
Tabeller	xi
1 Inledning	1
1.1 Bakgrund	1
1.2 Syfte	2
1.3 Avgränsningar	2
1.4 Samhälleliga och etiska aspekter	2
2 Metod	4
2.1 Livsmedelsimitation	4
2.2 Detektion av främmande föremål	4
2.3 Experimentell uppställning	4
2.3.1 Flödessystem	5
2.3.2 Mätsystem	5
2.3.3 Styrsystem	5
3 Databehandling och detektionsmetoder	6
3.1 Multivariat normalfördelning	6
3.1.1 Sampelskattningar	7
3.1.2 Marginaltäthetsfunktion	7
3.1.3 Singulärvärdesfaktorisering	8
3.2 Histogram	9
3.2.1 Detektion	9
3.3 Autoencoder	10
3.3.1 Optimering av neuronnät	12
3.3.2 Träning, validering och test	14
4 Experimentanläggning	16
4.1 Översikt	16
4.2 Livsmedelsimitation	18
4.2.1 Permittivitet för livsmedelsimitation	19

4.3	Design och modell av flödessystem	19
4.4	Mikrovågsmätning	21
4.5	Referensmätning med kamera	25
4.6	Styrsystem	25
5	Resultat	27
5.1	Livsmedelsimitation	27
5.2	Detektion med kamera	27
5.3	Mikrovågsmätning	29
5.4	Förbehandling av data	29
5.5	Estimering av täthetsfunktioner	32
5.5.1	Reproducerbarhet	33
5.6	Histogram för detektion	34
5.7	Autoencoder	35
5.7.1	Estimering av underliggande frihetsgrader	35
5.7.2	Optimering av hyperparametrar	36
5.7.3	Rekonstruktion	38
6	Diskussion	42
6.1	Livsmedelsimitation	42
6.2	Detektion med kamera	42
6.3	Mikrovågsmätning	43
6.4	Förbehandling av data	44
6.5	Estimering av täthetsfunktioner	44
6.6	Histogram för detektion	44
6.7	Autoencoder för detektion	45
7	Slutsats och rekommendationer	46
	Litteraturförteckning	48
A	Experiment - Chili con carne	I
B	Experiment - Blandning av vatten och stärkelse	II
C	Bill of material	IV

Figurer

1	<i>Skalning av en enhetscirkel.</i>	8
2	<i>Neuronnäts-arkitektur där M är antal neuroner vid inlagret och N är antal neuroner det gömda lagret.</i>	10
3	<i>Neuron.</i>	11
4	<i>Experimentanläggningen utan styrsystemet inkopplat.</i>	17
5	<i>Experimentanläggningens struktur. Blått streck är lufttryck, grönt streck är flödet mellan tankarna och lila streck är elektriska signaler.</i>	17
6	<i>Mikrovågssensorcell med portar 1-4.</i>	21
7	<i>Position för kamera.</i>	25
8	<i>En kort sekvens av resultatet från videoanalysen.</i>	28
9	<i>Bilder ur vilka videoanalysen detekterat en $20\text{ mm} \times 20\text{ mm}$ hårdplastbit, t.v. $t = 129$ och t.h. $t = 159$.</i>	28
10	<i>Mätningar för en transmissionskoefficients magnitud och fas för ofiltrerad data från Watson för en specifik frekvens i tidsplanet.</i>	30
11	<i>Mätningar för en transmissionskoefficients magnitud och fas för högpasfiltrerad data från Watson för en specifik frekvens i tidsplanet.</i>	31
12	<i>Den diskreta fouriertransformen för ofiltrerad data samt filtrerad data av mätningar av en transmissionskoefficient för MTRX för en specifik frekvens.</i>	31
13	<i>Den diskreta fouriertransformen för ofiltrerad data samt filtrerad data av mätningar av en transmissionskoefficient för Watson för en specifik frekvens.</i>	31
14	<i>Reflektions- och transmissionskoefficients signalstyrka före normalisering för Watson.</i>	32
15	<i>Reflektions- och transmissionskoefficients signalstyrka efter normalisering för Watson.</i>	32
16	<i>Bivariat normalfördelning och histogram över S_{34} från Watson över andra frekvensen, ofiltrerad data.</i>	33
17	<i>Bivariat normalfördelning och histogram över S_{34} från Watson över andra frekvensen, filtrerad data.</i>	33
18	<i>Medelvärdesvektorer fyra olika mättillfällen på livsmedelsimitationen med mätinstrument Watson.</i>	34
19	<i>Singulärvärden för livsmedelsimitation med högpasfiltrerad data från Watson.</i>	36

20	<i>Singulärvärden för livsmedelsimitation med ofiltrerad data från Watson.</i>	36
21	<i>Singulärvärden för livsmedelsimitation med högpasfiltrerad data från MTRX. . .</i>	36
22	<i>Singulärvärden för livsmedelsimitation med ofiltrerad data från MTRX.</i>	36
23	<i>Antal neuroner i mittersta lagret i autoencodern för högpasfiltrerad data från Watson vid 250 iterationer.</i>	38
24	<i>Fel mellan indata och utdata för högpasfiltrerad data utan främmande föremål från ett överföringstillfälle, med en autoencoder tränad på högpasfiltrerad data från Watson. Varje heldragen linje representerar felet för en vägkombination. . .</i>	39
25	<i>Fel mellan indata och utdata för ofiltrerad data utan främmande föremål från ett överföringstillfälle, med en autoencoder tränad på ofiltrerad data från Watson. Varje heldragen linje representerar felet för en vägkombination.</i>	39
26	<i>Fel mellan indata och utdata för högpasfiltrerad data innehållande främmande föremål från ett överföringstillfälle, med en autoencoder tränad på högpasfiltrerad data från Watson. Den streckade linjen är det sampel där plastbiten befinner sig vid mikrovågssensorn på Watson och varje heldragen linje representerar felet för en vägkombination.</i>	39
27	<i>Fel mellan indata och utdata för ofiltrerad data innehållande främmande föremål från ett överföringstillfälle, med en autoencoder tränad på ofiltrerad data från Watson. Den streckade linjen är det sampel där plastbiten befinner sig vid mikrovågssensorn på Watson och varje heldragen linje representerar felet för en vägkombination.</i>	39
28	<i>Fel mellan indata och utdata för högpasfiltrerad data utan främmande föremål från ett överföringstillfälle, med en autoencoder tränad på högpasfiltrerad data från MTRX. Varje heldragen linje representerar felet för en vägkombination. . .</i>	40
29	<i>Fel mellan indata och utdata för ofiltrerad data utan främmande föremål från ett överföringstillfälle, med en autoencoder tränad på ofiltrerad data från MTRX. Varje heldragen linje representerar felet för en vägkombination.</i>	40
30	<i>Fel mellan indata och utdata för högpasfiltrerad data innehållande främmande föremål från ett överföringstillfälle, med en autoencoder tränad på högpasfiltrerad data från MTRX. Den streckade linjen är det sampel där plastbiten befinner sig vid mikrovågssensorn på MTRX och varje heldragen linje representerar felet för en vägkombination.</i>	41

31	<i>Fel mellan indata och utdata för ofiltrerad data innehållande främmande föremål från ett överföringstillfälle, med en autoencoder tränad på ofiltrerad data från MTRX. Den streckade linjen är det sampel där plastbiten befinner sig vid mikrovågssensorn på MTRX och varje heldragen linje representerar felet för en vägkombination.</i>	41
32	<i>Resultatet från de olika proportionerna som blandades.</i>	III
33	<i>Bill of material för projektet.</i>	IV
34	<i>ϵ'_r, ϵ''_r, samt konduktiviteten σ för kidneybönorna. De olika färgade linjerna korresponderar mot olika mätningar med den dielektriska proben. $\tan(\delta) = \epsilon''_r/\epsilon'_r$ är den dielektriska förlusttangente.</i>	V
35	<i>ϵ'_r, ϵ''_r, samt konduktiviteten σ för stärkelseblandningen utan salt. $\tan(\delta) = \epsilon''_r/\epsilon'_r$ är den dielektriska förlusttangente.</i>	V
36	<i>ϵ'_r, ϵ''_r, samt konduktiviteten σ för stärkelseblandningen med 0,75 % salt. $\tan(\delta) = \epsilon''_r/\epsilon'_r$ är den dielektriska förlusttangente.</i>	VI
37	<i>ϵ'_r, ϵ''_r, samt konduktiviteten σ för stärkelseblandningen med 1,5 % salt. $\tan(\delta) = \epsilon''_r/\epsilon'_r$ är den dielektriska förlusttangente.</i>	VI

Tabeller

1	<i>Hyperparametrar och aktiveringsfunktioner samt ursprungliga värden för trainAutoencoder i MATLAB.</i>	14
2	<i>Jämförelse mellan organisk och icke-organisk livsmedelsimitation.</i>	18
3	<i>Tabell över konstanter använda i strömningsmodell.</i>	20
4	<i>Resultat av experimentell framtagning av bönmängd från chili con carne.</i>	27
5	<i>Visuellt uppmätta flödeshastigheter.</i>	29
6	<i>Klassificerade utfall från detektion med histogram.</i>	35
7	<i>Valda hyperparametervärden och aktiveringsfunktioner efter optimering för funktionen trainAutoencoder i MATLAB med högpasfiltrerad data från Watson. . .</i>	37
8	<i>Valda hyperparametervärden och aktiveringsfunktioner efter optimering för funktionen trainAutoencoder i MATLAB med ofiltrerad data från Watson.</i>	37
9	<i>Valda hyperparametervärden och aktiveringsfunktioner efter optimering för funktionen trainAutoencoder i MATLAB med högpasfiltrerad data från MTRX. . . .</i>	37
10	<i>Valda hyperparametervärden och aktiveringsfunktioner efter optimering för funktionen trainAutoencoder i MATLAB med ofiltrerad data från MTRX.</i>	37
11	<i>Resultat av experimentell framtagning av bönmängd från chili con carne.</i>	I

1 Inledning

I följande kapitel beskrivs bakgrunden till problemet vilket mynnar ut i projektets syfte. Därefter beskrivs projektets avgränsningar. Till sist behandlas de samhälleliga och etiska aspekterna med projektet.

1.1 Bakgrund

En stor del av världens livsmedelsproduktion är idag automatiserad och storskalig. Denna storskalighet och automatisering bidrar till risken att främmande föremål tar sig igenom systemen och hamnar i slutprodukten. Metall- och röntgensensorer kan detektera metallföremål och föremål med hög densitet, men kan inte detektera föremål med låg densitet. Företaget FRS utvecklar och säljer ett system för detektion av främmande föremål i livsmedel. FRS:s system är speciellt lämpat för att komplettera andra detektionsmetoder då det kan detektera föremål med låg densitet, exempelvis föremål av trä, plast, stärkelseklumpar och hårda växtdelar. Detektionen av dessa föremål bygger på unik och patenterad mikrovågsteknik.

FRS:s system fungerar väl för livsmedelsprodukter som är homogena i termer av permittivitet, exempelvis barnmat, sylt och pesto. Detektion i nuläget bygger på skillnader mellan livsmedlets och de främmande föremålens permittivitet. Detta gör att det uppstår svårigheter för detektion när livsmedel med dielektriska kontraster analyseras, exempelvis livsmedel innehållandes bönor.

Artificiell intelligens (AI) är intelligens som uppvisas av maskiner, till skillnad från naturlig intelligens som uppvisas av människor och andra djur. Det är också namnet på det akademiska studieområde som studerar datorprogram med intelligent beteende och hur datorer skapas [1]. Artificiell intelligens kan delas upp i ett antal grenar varav maskininlärning är en utav dem. Maskininlärning är ett område inom datavetenskapen som handlar om metoder för att få datorer att lära sig en uppgift utifrån data utan att datorerna specifikt har programmerats för den uppgiften [2].

Djup maskininlärning har de senaste åren framgångsrikt identifierat komplicerade mönster i flera olika applikationsområden. Hypotesen är att maskininlärning även kan användas för att detektera föremål i dielektriskt heterogena substanser. En lyckad användning av ett neuronnät

för detektion av främmande föremål i heterogena livsmedel skulle innebära en mer heltäckande detektionsmetod för FRS samt ett tillskott till den allmänna kunskapen om djup maskininläring.

1.2 Syfte

Projektets syfte är att implementera en maskininlärningsalgorithm och statistiska metoder för att detektera främmande föremål i en dielektriskt heterogen substans.

1.3 Avgränsningar

Projektet begränsas till att använda en livsmedelsimitation som representation för heterogena livsmedel. Det livsmedel som imiteras är chili con carne. Den experimentella uppställningen är storleksmässigt begränsad. Därav finns en begränsning i hur stor volym livsmedelsimitation som kan behandlas per experiment. Stora mängder data samlas in under experimenten. För att behandla denna data ställs krav på kraftfull hårdvara, vilket är en begränsande faktor.

1.4 Samhälleliga och etiska aspekter

I detta arbete finns ett flertal relevanta samhälleliga och etiska aspekter som bör beaktas. För att undvika att göra skada är det viktigt att vid presentation av resultatet vara tydlig med dess begränsningar. En lyckad algorithm som lär sig detektera främmande föremål inom livsmedelsindustrin med hjälp av mikrovågor är inte ett komplett system. Fler detektionssystem behövs för att komplettera, exempelvis en metalldetektor. Att tydliggöra argumentet att detektionen inte är komplett är därav viktigt för att säkerställa att inga främmande föremål passerar detektionssystemet. Om man vänder på argumentet har detta arbete potential att göra samhällelig nytta. En lyckad användning av maskininläring för att detektera främmande föremål skulle kunna rädda liv.

För att undvika etiska problem bör projektet genomföras i en testanläggning under kontrollerade omständigheter för att säkerställa att ingen skada görs. I en riktig tillämpning på en industri finns risk att tillförda instrument och komponenter går sönder och förstör för indu-

strins verksamhet.

Om projektet skulle resultera i en maskininlärningsalgoritm som lyckas detektera främmande föremål i livsmedelsimiationen skulle detta kunna implementeras av FRS. Vid en industriell implementation är det viktigt att reda ut vem som har ansvaret om algoritmen missar att detektera främmande föremål. Potentiella ansvarstagare är FRS, Chalmers, projektgruppen eller industrin där systemet är implementerat.

Trots ansvarsdilemmat kan en lyckad detektionsalgoritm resultera i stor nytta. Det kan leda till att fler främmande föremål kan upptäckas i livsmedel och på så sätt ge FRS möjlighet att öka sitt sortiment av detektionssystem. En lyckad detektionsalgoritm med maskininläring skulle också leda till ökad allmän kunskap om maskininläring.

De som berörs av en lyckad detektionsalgoritm är framförallt Chalmers, FRS, FRS:s kunder samt FRS:s konkurrenter. Om maskininläring visar sig kunna detektera främmande föremål framgångsrikt skulle Chalmers få ett större incitament att fortsätta forska på detta. Dessutom skulle FRS kunna sälja denna lösning på marknaden, vilket skulle ge stor nytta till FRS:s kunder samt konkurrens till alternativa detektionsmetoder. Om maskininlärningsmetoden visar sig vara framgångsrik kan alternativa detektionsmetoder konkurreras ut då alternativkostnaden möjligtvis skulle kunna bli alltför hög.

2 Metod

För att uppfylla projektets syfte utfördes ett antal delmoment. Detta kapitel behandlar hur arbetet fortskred samt delproblem som uppstod och hur dessa löstes.

2.1 Livsmedelsimitation

Då projektet ämnar detektera främmande föremål i livsmedel behövdes en livsmedelsimitation. Flera imitationer undersöktes med hänsyn till kostnad, praktikalitet och representativitet.

2.2 Detektion av främmande föremål

Det huvudsakliga problemet var att detektera främmande föremål i livsmedelsindustrin med hjälp av artificiell intelligens. Maskininlärning användes för att lösa detta problem. För att framgångsrikt använda maskininlärning till detta syfte samlades data in under projektets gång. En autoencoder (en typ av neuronnät) tränades på data för situationen där livsmedelsimitationen var fri från främmande föremål. Neuronnätet testades sedan med data för situationen där imitationen innehöll främmande föremål. Utöver neuronnätet användes även statistiska modeller. Detta för att undersöka underliggande egenskaper för datan och som sannolikhetsbaserad detektionsmetod.

2.3 Experimentell uppställning

För att samla in data på ett kontrollerat sätt konstruerades en experimentell uppställning. Uppställningen syftade till att transportera en livsmedelsimitation genom ett rörsystem mellan två tankar. Datainsamlingen utfördes genom mätningar med nätverksanalysatorerna *MTRX* och *Watson*. För att synkronisera flödet av imitationen mellan de båda tankarna och mätningarna konstruerades ett styrsystem. Flödet eftersträvades att likna det flöde som finns hos en industriell process. Dessutom eftersträvades att flödet var kontrollerbart för de olika mätningarna. Detta för att säkerställa reproducerbara mätningar.

2.3.1 Flödessystem

Flödessystemets uppgift var att transportera livsmedelsimitationen utan att förändra dess fysiska egenskaper. Det säkerställdes att ett representativt flöde för en anläggning där livsmedel tillverkas uppnåddes.

2.3.2 Mätssystem

För att samla in data för maskininlärning uppmättes spridningsparametrar (S-parametrar). S-parametrarna uppmättes med nätverksanalysatorerna *MTRX* och *Watson*. Dessutom uppmättes flödes hastighet med en kamera samt temperatur med en temperatursensor. Kameran användes även för att detektera föremålen visuellt för att identifiera när främmande föremål passerar *MTRX* och *Watson*. Utöver detta säkerställdes att mätinstrumenten startades vid samma tidpunkt.

2.3.3 Styrsystem

Då maskininlärning kräver mycket data automatiserades den experimentella uppställningen. Ett styrsystem designades för att utföra mätningar och kontrollera flödet genom den experimentella uppställningen. De tryck- och nivåsensorer som krävdes för automatiseringen implementerades som en del av mätsystemet.

3 Databehandling och detektionsmetoder

Mätdata från mätinstrumenten *Watson* och *MTRX* organiseras i en datavektor. Datavektorn är en kolonnvektor $\mathbf{x}(t)$ där t betecknar samplingsögonblicket. $\mathbf{x}(t)$ har M element $x_1(t)$, $x_2(t)$, ..., $x_M(t)$ och beskrivs i ekvation (1). Sampel av datavektorn tas vid diskreta tidpunkter $t_1, t_2, \dots, t_K$ för K mätningar. En mätning sker i intervallet som anges i ekvation (2) där T_m är mättiden. Samplingsperioden eller periodtiden anges med ekvation (3). Utifrån samplingsperioden T_s kan samplingsfrekvensen anges med ekvation (4). Vetskapen om samplingsfrekvensen möjliggör jämförelse mellan mätinstrumenten.

$$\mathbf{x}(t) = \begin{bmatrix} x_1(t) \\ x_2(t) \\ \dots \\ x_M(t) \end{bmatrix} \quad (1)$$

$$t_i \leq t \leq t_i + T_m \quad (2)$$

$$T_s = t_{i+1} - t_i \quad (3)$$

$$f_s = \frac{1}{T_s} \quad (4)$$

Datavektorerna behandlades med statistiska metoder och med en autoencoder, med målet att hitta avvikelser. Först uppskattas marginaltäthetsfunktioner för data genom att använda multivariat normalfördelning. Därefter beskrivs en icke-parametrisk metod där datafördelningen representeras med hjälp av histogram, där relativ frekvens kan indikera avvikelser. Slutligen beskrivs metoden för att med datavektorerna träna ett neuronnät, mer specifikt en autoencoder. En färdig autoencoder har som uppgift att rekonstruera indata av storlek M genom $N < M$ frihetsgrader. Rekonstruktionen leder till ett visst fel i utdata. Felet kan uttryckas som normen mellan in- och utdata, som i sin tur kan indikera avvikelser.

3.1 Multivariat normalfördelning

Täthetsfunktioner skapades från mätdata. Multivariatanalys användes då mätresultatet är flerdimensionellt. Ekvation (5) beskriver den d -dimensionella multivariata normalfördelnings-

funktionen för en vektor $\mathbf{x}$ med d stokastiska variabler. Den multivariata normalfördelningsfunktionen implementerades i MATLAB med kommandot *mvnpdf* [3].

$$p_{\mathbf{x}}(\mathbf{x}, \boldsymbol{\mu}, \mathbf{C}) = \frac{1}{\sqrt{\det(\mathbf{C})(2\pi)^d}} e^{[-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu})\mathbf{C}^{-1}(\mathbf{x}-\boldsymbol{\mu})^T]} \quad (5)$$

I ekvation (5) är vektorn med mätpunkterna $\mathbf{x}$ och medelvärdesvektor $\boldsymbol{\mu}$ $1 \times d$ -vektorer och kovariansmatrisen $\mathbf{C}$ är en $d \times d$ matris. Medelvärdesvektorn och kovariansmatrisen skattades med ekvation (6) respektive ekvation (7).

3.1.1 Sampelskattningar

Sampelskattningar utförs i projektet för att kunna analysera mätdata. Det görs genom att jämföra data från olika mättdagar med varandra. En metod som användes för detta är medelvärdesvektorer för specifika frekvenser och mättdagar.

$$\hat{\boldsymbol{\mu}} = \frac{1}{K} \sum_{k=1}^K \mathbf{x}_k \quad (6)$$

Den estimerade medelvärdesvektorn enligt ekvation (6) resulterar i en vektor med M element. Estimeringen bygger på K stycken datavektorer $\mathbf{x}$. Kovariansmatrisen estimerades enligt ekvation (7) med $M \times M$ dimensioner ur K stycken datavektorer $\mathbf{x}$. För en numerisk beräkning av ekvation (5) krävs att estimatet för kovariansmatrisen $\hat{\mathbf{C}}$ inte ligger alltför nära mängden av singulära matriser, vars determinant är noll [4].

$$\hat{\mathbf{C}} = \frac{1}{K-1} \sum_{k=1}^K (\mathbf{x}_k - \hat{\boldsymbol{\mu}})(\mathbf{x}_k - \hat{\boldsymbol{\mu}})^T \quad (7)$$

3.1.2 Marginaltätthetsfunktion

Marginaltätthetsfunktioner uppskattas då det är svårt att visualisera högdimensionella funktioner. I marginaltätthetsfunktionen används en kovariansmatris och en medelvärdesvektor som har marginaliserats i förslagsvis två specifika dimensioner.

$$\mathbf{P} = \begin{bmatrix} 0 & \cdots & p_{1,10} = 1 & \cdots & 0 \\ 0 & \cdots & p_{2,20} = 1 & \cdots & 0 \end{bmatrix} \quad (8)$$

För att marginalisera oönskade dimensioner av medelvärdesestimatet användes en matris $\mathbf{P}$, se ekvation (8), med en rad per önskad dimension och M kolonner enligt ekvation (9) och (10).

$$\tilde{\boldsymbol{\mu}} = \mathbf{P}\hat{\boldsymbol{\mu}} = \begin{bmatrix} \mu_{10} \\ \mu_{20} \end{bmatrix} \quad (9)$$

$$\tilde{\mathbf{C}} = \mathbf{P}\hat{\mathbf{C}}\mathbf{P}^T = \begin{bmatrix} C_{10,10} & C_{10,20} \\ C_{20,10} & C_{20,20} \end{bmatrix} \quad (10)$$


Den reducerade medelvärdesvektorn samt kovariansmatrisen är därefter indata för den multivariata normalfördelningsfunktionen i ekvation (5) [5].

3.1.3 Singulärvärdesfaktorisering

Inom linjär algebra finns en metod som kallas singulärvärdesfaktorisering. Tekniken går ut på att faktorisera en matris till tre matriser.

$$\mathbf{A} = \mathbf{U}\mathbf{W}\mathbf{V}^T \quad (11)$$

$\mathbf{A}$ är den undersökta $M \times N$ -matrisen. $\mathbf{U}$ är en $M \times N$ matris vars kolumner är ortonormala. $\mathbf{W}$ är en $N \times N$ -diagonalmatris med enbart positiva och nollvärda element. $\mathbf{V}$ en $N \times N$ ortonormalmatris. Diagonalelementen i $\mathbf{W}$ är ekvivalenta med singulärvärdena till $\mathbf{A}$.



Figur 1: Skalning av en enhetscirkel.

Observeras de olika faktorerna i en geometrisk kontext ger matrisen $\mathbf{W}$ upphov till skalning

medan $\mathbf{U}$ och $\mathbf{V}$ ger upphov till rotation. Är $\mathbf{A}$ en kovariansmatris representerar diagonalelementen i $\mathbf{W}$ variansen längs respektive dimensions normal. Singulärvärdena kan därför beskriva frihetsgraderna hos variationen i en datamängd [6].

3.2 Histogram

Histogram kan användas som en icke-parametrisk metod för att skatta och visualisera täthetsfunktioner. På grund av de högdimensionella datavektorerna i detta projekt är det praktiskt otänkbart att sortera den insamlade datan i ett histogram med motsvarande dimensionalitet. Om enbart tio staplar per dimension används på datavektorer med 80 dimensioner så fås 10^{80} staplar i histogrammet totalt. Risken finns även att ett histogram av dessa dimensioner skulle beskriva den underliggande sannolikhetsfördelningen dåligt då förhållandet mellan det totala antalet sampel och antalet staplar är litet. Därmed skulle ett ytterst litet antal staplar fyllas i och inget eller lite går att säga om sannolikhetsfördelningens egentliga form. Dessutom är det svårt att på ett meningsfullt sätt visualisera resultatet.

Datavektorn $\mathbf{x}(t)$, se ekvation (1), har ett jämnt antal dimensioner och kan därför sorteras parvis i två-dimensionella histogram. Ur dessa fås marginaltäthetsfördelningar för den underliggande sannolikhetsfördelningen. Till skillnad från det högdimensionella fallet erhålls nu ett histogram som med mindre krav på det totala antalet sampels kan användas för att dra meningsfulla slutsatser. Histogrammet kan visualiseras vilket möjliggör vissa kvalitativa slutsatser angående marginaltäthetsfördelningen. Till exempel kan en jämförelse göras med den bivariata normalfördelningen enligt ekvation (5). Element ur datavektorn $\mathbf{x}(t)$ sorterades parvis enligt ekvation (12).

$$\{x_i, x_{i+1}\}, i = 1, 3, 5... \quad (12)$$

3.2.1 Detektion

Ett sampel av datavektorn $\mathbf{x}(t)$ delas in i par enligt ekvation (12), låt dessa par betecknas p_k . Sannolikhetsfunktionen för att se detta par ges av motsvarande histogram. Låt denna sanno-


likhetfunktion betecknas f_k . En skalär för varje sampel skapas enligt ekvation (13).

$$\sum_k \ln f_k(p_k) \quad (13)$$

Denna skalär jämförs sedan med ett tröskelvärde. Om skalären är mindre än detta tröskelvärde anses ett sampel inte tillhöra normalfallet [5].


3.3 Autoencoder

Mätdata från datainsamlingsprocessen användes för att träna en autoencoder. En autoencoder är ett nätverk av neuroner som kan organiseras i två delar, ett encoder-nätverk $\mathbf{f}$, och ett decoder-nätverk $\mathbf{g}$. Utifrån detta fås autoencoder-modellen $\mathbf{g}(\mathbf{f}(\mathbf{x}(t)))$ där $\mathbf{x}(t)$ är indatan [7]. Antag att encoder-nätverket ges indata av M frihetsgrader samt att det underliggande rummet kan representeras av N frihetsgrader där $N < M$. Encoder-nätverket komprimerar de M frihetsgraderna ner till N frihetsgrader i det underliggande rummet. Decoder-nätverket försöker därefter rekonstruera den M -dimensionella indatan till encoder-nätverket enbart utifrån kunskap om det underliggande rummet. Hypotesen i detta arbete är att främmande föremål inte kan representeras med de underliggande N st frihetsgraderna. På så sätt bör normalfallet utan främmande föremål kunna skiljas från fallet med främmande föremål så att en detektion kan uppnås.



Figur 2: Neuronnätts-arkitektur där M är antal neuroner vid inlagret och N är antal neuroner det gömda lagret.

Autoencoderns nätverksarkitektur består av sammankopplade noder arrangerade i lager, se figur 2, där varje neuron (nod) fungerar som ett enkelt bearbetningselement. Varje neuron i nätverket är sammankopplad med alla neuroner i föregående och efterföljande lager. Notera att neuroner i samma lager ej är sammankopplade. Inlagret syftar till att ta emot en M -dimensionell mätvektor. Denna mätvektor processas genom ett antal dolda neuronnättslager, via det N -dimensionella mittenlagret, till det M -dimensionella utlagret. Antalet lager kallas för djup, i figur 2 visas ett neuronnät med ett djup om fem [8].



Figur 3: *Neuron*.

Som figur 3 visar är indatan I_j till en neuron j en linjärkombination av vikterna w_{ij} från utdattan O_i i föregående skikt. Till denna linjärkombination adderas en biasterm som bidrar till om noden ska aktiveras eller inte. Linjärkombinationen och biastermen processas sedan av en aktiveringsfunktion f för att producera neuronens utdata O_j inom aktiveringsfunktionens område [8]. En av de aktiveringsfunktionerna som kan användas i MATLAB-implementationen är *logsig* som är en sigmoid-funktion som ges av ekvation (14) [9]. Utöver detta kan *purelin* och *satlin* användas som är en linjär överföringsfunktion respektive en mättande linjär överföringsfunktion [10, 11].

$$S(z) = \frac{1}{1 + e^{-z}} \quad (14)$$

3.3.1 Optimering av neuronnät

För att träna autoencodern på mätdatan jämförs utdatan med indatan, som borde ha samma värde. Detta sker genom att minimera en rekonstruktionsförlustfunktion E . Den autoencoder som implementerades i Matlab har en rekonstruktionsförlustfunktion enligt ekvation (15).

$$E = \frac{1}{N} \sum_{n=1}^N \sum_{k=1}^K (x_{kn} - \hat{x}_{kn})^2 + \lambda \Omega_{\text{weights}} + \beta \Omega_{\text{sparsity}} \quad (15)$$

Rekonstruktionsfunktionen består av tre delar: ett medelkvadratfel, en L_2 -regulariseringsterm som penaliserar vikterna till att vara små samt en sparsity-regulariseringsterm som begränsar antalet aktiverade neuroner [12]. I ekvation (15) ges medelkvadratfelet mellan utdatan och indatan av termen $\frac{1}{N} \sum_{n=1}^N \sum_{k=1}^K (x_{kn} - \hat{x}_{kn})^2$. λ och β är regulariseringskoefficienter för L_2 -regulariseringstermen som ges av $\lambda \Omega_{\text{weights}}$ respektive sparsity-regulariseringstermen som ges av $\beta \Omega_{\text{sparsity}}$ [12]. Regularisering används för att balansera autoencodern mellan över- och underinlärning [7]. Överinlärning innebär att anpassningen är för nära en viss uppsättning träningsdata. Modellen kan då misslyckas att rekonstruera data som inte ingår i den data som använts för träning av autoencodern [13]. L_2 -regulariseringstermen Ω_{weights} ges av ekvation (16).

$$\Omega_{\text{weights}} = \frac{1}{2} \sum_l^L \sum_j^n \sum_i^k (w_{ij}^{(l)})^2 \quad (16)$$

I ekvationen ovan är L antal dolda lager i autoencodern, n antal mätvärden och k antal variabler i träningsdatan. Vikterna w indexeras utifrån rad i och kolonn j i viktmatrisen. Notera att superindex (l) indikerar att vikterna gäller lager l [12].

Gleshet (sparsity) erhålls genom en regulariseringsterm som antar ett stort värde då neuron i 's genomsnittliga aktiveringsvärdet $\hat{\rho}_i$ och dess önskade aktiveringsvärde ρ inte ligger nära varandra. Den gleshets-regulariseringsterm som används av MATLAB:s autoencoder är Kullback-Leibler-divergensen som presenteras i ekvation (17), KL står för Kullback-Leibler-divergensen.

$$\Omega_{\text{sparsity}} = \sum_{i=1}^{D^{(1)}} KL(\rho || \hat{\rho}_i) = \sum_{i=1}^{D^{(1)}} \rho \log \frac{\rho}{\hat{\rho}_i} + \log \frac{1 - \rho}{1 - \hat{\rho}_i} \quad (17)$$

Kullback-Leibler-divergensen är en funktion för att relatera två normaldistributioner varav en är referens. I ekvationen ovan är $D^{(1)}$ antal dimensioner i första lagret i autoencodern, alltså

antal neuroner i första lagret. Neuron i :s genomsnittliga aktiveringsvärde $\hat{\rho}_i$ ges av ekvation (18).

$$\hat{\rho}_i = \frac{1}{n} \sum_{j=1}^n f(w_i^{(1)T} x_j + b_i^{(1)}) \quad (18)$$

I ekvationen ovan som ger det genomsnittliga aktiveringsvärdet $\hat{\rho}_i$ för neuron i är n antal träningsvärden, f encoderns aktiveringsfunktionen, $w_i^{(1)T}$ den i :te raden av den transponerade viktmatrisen för första lagret, x_j det j :te träningsvärdet, $b_i^{(1)}$ det i :te värdet i biasvektorn för första lagret i neuronnätet $b^{(1)}$.

När kostnadsfunktionen minimeras tvingas det genomsnittliga aktiveringsvärdet $\hat{\rho}_i$ att närma sig det önskade genomsnittliga aktiveringsvärdet ρ . Det önskade genomsnittliga aktiveringsvärdet ρ definieras med ett förbestämt argument inför träning av autoencodern. Ett lågt värde på ρ medför därför att neuronerna specialiserar sig, vilket medför hög gleshet [12]. Ett lågt aktiveringsvärde innebär att neuronen enbart aktiveras för ett litet antal träningsvärden och vice versa. Genom att lägga till en term för att begränsa aktiveringsvärdet till att vara litet fås att autoencoderna tvingas lära sig en representation där varje neuron enbart aktiveras för ett litet antal träningsvärden. På så sätt specialiserar sig neuronerna till att lära sig något särskilt kännetecken som enbart finns i en liten delmängd av alla träningsvärden [12].

Träningsprocessen är ett optimeringsproblem som sker genom minimering av rekonstruktionsförlustfunktionen. Minimeringen genomförs med gradientmetoden [7]. Gradientmetoden är en iterativ första-ordningens optimeringsalgoritm för att hitta minsta värdet av en funktion [14]. Det går inte att säkerställa att gradientmetoden konvergerar i det globala minimumet som är målet för att minimera rekonstruktionsförlustfunktionen. Om gradientmetoden istället hamnar i ett lokalt minimum kommer rekonstruktionsförlustfunktionen inte att ytterligare minimeras. Av den anledningen kan det vara värt att göra några omstarter av träningsprocessen med olika initialvärden på vikterna och jämföra resultatet då sannolikheten finns att gradientmetoden konvergerat i olika minimum [15].

För att förbättra neuronnätets valideringsnoggrannhet bör indatan till autoencodern normaliseras. För att gradientnedgångarna ska konvergera snabbare normaliseras datan [16]. Den normaliseringsmetod som använts för att skala mätvektorn x_i är $y_i = (x_i - m_i)/s_i$ där m_i är sampelmedelvärdet och s_i är sampelstandardavvikelsen för den i :te komponenten. Observera att eventuell kovarians ignoreras.

3.3.2 Träning, validering och test

Autoencodern implementerades i MATLAB. I MATLAB finns ett inbyggt kommando för att träna en autoencoder vid namn *trainAutoencoder* [12]. *trainAutoencoder* accepterar en $N \times M$ -matris där N är antal neuroner i autoencoderns första lager och M är antal mätsampel.

Det finns sex olika hyperparametrar, vilka presenteras i tabell 1. EncoderTransferFunction och DecoderTransferFunction är encoderns respektive decoderns aktiveringsfunktion. HiddenSize är antalet neuroner i det underliggande rummet, mittersta lagret. L2WeightRegularization är L_2 -regulariseringstermen Ω_{weights} som visas i ekvation (16). SparsityRegularization är sparsityregulariseringstermen Ω_{sparsity} som presenteras i ekvation (17). SparsityProportion är en parameter i sparsity-regulariseringen och är den önskade andelen av träningssampel som en neuron ska aktiveras för. SparsityProportion bestämmer alltså det önskade genomsnittliga aktiveringsvärdet ρ . Ett lågt värde på SparsityProportion leder vanligtvis till att varje neuron i de underliggande lagrerna specialiserar sig genom att de enbart aktiveras för ett litet antal träningssampel. Därav bör en låg SparsityProportion resultera i en större gleshet av antal aktiverade neuroner [12].

Tabell 1: *Hyperparametrar och aktiveringsfunktioner samt ursprungliga värden för trainAutoencoder i MATLAB.*

Parameter	Värde
EncoderTransferFunction	logsig
DecoderTransferFunction	logsig
HiddenSize	10
L2WeightRegularization	0,001
SparsityRegularization	1
SparsityProportion	0,05

Den insamlade datan delades in i två olika datamängder: en träningsmängd och en valideringsmängd. Träningsmängden utgjorde 80 % av datan och valideringsmängden 20 % av datan. Hyperparametrarna bestämdes genom att variera en parameter medan de andra var konstanta. En autoencoder tränades för varje variation. Varje autoencoder utvärderades därefter med valideringsmängden. Den autoencoder med minsta medelkvadratfelet valdes. Till sist tränades den valda autoencodern med hela datamängden, alltså unionen av tränings- och valideringsmängden.

Autoencodern testades på datavektorer från mätningar där främmande föremål förekommer i

livsmedelsimitationen. Ett fel beräknas genom att summera normen av skillnaden mellan autoencoderns utdata $\mathbf{g}(\mathbf{f}(\mathbf{x}(t)))$ och dess indata för varje sampel, där indatan är datavektorn $\mathbf{x}(t)$ definierad i ekvation (1). Felet är definierat enligt ekvation (19). Observera att autoencodern endast accepterar en vektor med längd M , därför måste utdatan $\mathbf{g}(\mathbf{f}(\mathbf{x}(t)))$ beräknas innan felen kan summeras. Om normen överstiger ett givet tröskelvärde har autoencodern detekterat en avvikelse som skulle kunna vara ett främmande föremål. Anledningen till att medekvadratfelet inte används som felfunktion är att ett främmande föremål kan ge upphov till olika mycket avvikelse i mätdata för olika vägkombinationer.

$$\sum_M \|x_M(t) - \mathbf{g}(\mathbf{f}(\mathbf{x}(t)))_M\| \quad (19)$$

4 Experimentanläggning

En experimentanläggning konstruerades för att möjliggöra insamling av mätdata. Anläggningen ska efterlikna en process i en fabrik där livsmedel transporteras genom rör. Datainsamlingen utfördes i en kontrollerad miljö för att erhålla reproducerbara mätningar. För att samla in stora mängder reproducerbar data krävdes ett styrsystem samt kringutrustning.

4.1 Översikt


Experimentanläggningen består av tre olika system: ett flödessystem, ett mätsystem och ett styrsystem. Alla system arbetar tillsammans för att kunna utföra transport samt mätning automatiskt. Flödessystemets uppgift är att transportera livsmedelsimitationen mellan två tankar, de vertikala rören i figur 4. Mätsystemet utför mätningar på livsmedelsimitationen under flödessystemets transporttid.

Styrsystemet styr mätsystemet samt flödesystemet och kan med hjälp av en nivåmätare i varje tank bestämma när en transport är klar. Styrsystemet bestämmer transportriktning genom ett antal ventiler markerade "Vent" i figur 5. Transport görs med hjälp av lufttryck som regleras till 0,4 MPa.

Mätsystemet består av två nätverksanalystatorer *MTRX* och *Watson*, en kamera samt en temperatursensor. Nätverksanalyatorerna samt temperatursensorn styrs genom en signal från datorn. Kameran filmar livsmedelsimitationen i röret och en LED-lampa är tänd när mätningar pågår. På så vis kan videofilerna analyseras och mätstart kan identifieras.



Figur 4: Experimentanläggningen utan styrsystemet inkopplat.



Figur 5: Experimentanläggningens struktur. Blått streck är lufttryck, grönt streck är flödet mellan tankarna och lila streck är elektriska signaler.

4.2 Livsmedelsimitation

En livsmedelsimitation användes för att representera ett verkligt livsmedel innehållandes bönor. Valet stod mellan att antingen konstruera en icke-organisk imitation av exempelvis plastkylor eller frigolitkylor som var tänkt att motsvara bönorna, alternativt en organisk imitation bestående av bönor, se bilaga C för detaljer samt en kostnadsuppskattning. En jämförelse av alternativen görs i tabell 2. Jämförelsen grundades i att de olika egenskaperna måste vara samma hos en livsmedelsimitation som för en färdig produkt.

Tabell 2: *Jämförelse mellan organisk och icke-organisk livsmedelsimitation.*

Egenskaper	Icke-organisk imitation	Organisk imitation
Dielektriska egenskaper	Komplicerat, svårt att efterlikna bönor	Dielektriska egenskaperna är identiska
Kostnad	Blir dyrt, verktyg för geometri samt inköp av material	Endast kostnad för bönor
Tidsuppskattning	Tidskrävande, planering samt genomförande för att få en imitation som är tillräckligt lik den organiska imitationen	Liten tidsåtgång, produkten finns färdig att köpa
Geometri	Krävs konstruktion för att få en ellipsform likt bönor	Finns färdigt givet att den håller sin geometri under datainsamlingen
Förändring över tid	Imitationen bibehåller egenskaperna	Förändras över tiden
Hållfasthet	God hållfasthet, material som tål mycket slitage	Sämre hållfasthet

Uppskattningsvis hade det varit tidskrävande att ta fram en icke-organisk imitation med representativa dielektriska egenskaper. Kostnaden för de båda alternativen jämfördes och den icke-organiska imitationen är dyrare än den organiska imitationen. Den organiska imitationen får en rörlig kostnad eftersom antalet körningar och därmed mängden organiskt material är okänt från början medan den icke-organiska imitationen förväntas vara samma genom alla körningar och därmed får den en fast kostnad.

Hållfastheten för en organisk imitation är sämre än för en icke-organiska imitation. Efter tester

kunde det säkerställas att hållfastheten för den organiska imitationen är tillräckligt god för att bibehålla de fysiska egenskaperna vid transport, i den experimentella uppställningen, under en dag. Den organiska imitationens fysiska egenskaper förändras över längre perioder. Att de fysiska egenskaperna förändras över längre perioder är problematiskt, men går att lösa genom att blanda en ny sats med livsmedelsimitation inför varje mättillfälle.

Efter att ha rangordnat betydelsen för de olika parametrarna bedömdes att den organiska imitationen var det bästa alternativet och således det alternativ som användes för datainsamlingen i projektet.

4.2.1 Permittivitet för livsmedelsimitation

Permittiviteten för bönorna och stärkelseblandningen i livsmedelsimitationen uppmättes med en dielektrisk prob. Permittivitet eller den absoluta permittiviteten är en frekvensberoende materialkonstant vars storhet är bestämd efter ett materials förmåga att polariseras i förhållande till dess elektriska fält. Permittivitet är ett komplext tal och betecknas i fortsättningen som ε . Dess komplexa beteckning kan ses i ekvation (20), där den reella delen $\varepsilon'(\omega)$ beskriver den faktiska permittiviteten och den imaginära delen $\varepsilon''(\omega)$ beskriver de dielektriska förluster som materialet ger upphov till. Man kan även beskriva vinkeln mellan den reella permittiviteten samt förlusterna, denna vinkel brukar betecknas med δ och kan ses i ekvation (21). Den relativa permittiviteten är den absoluta permittiviteten normerat med permittiviteten för vakuum [17, 18].

$$\varepsilon(\omega) = \varepsilon'(\omega) - j\varepsilon''(\omega) \quad (20)$$

$$\tan(\delta) = \frac{\varepsilon''(\omega)}{\varepsilon'(\omega)} \quad (21)$$

4.3 Design och modell av flödessystem

En strömmningsmodell sattes upp med hjälp av Bernouillis ekvation. Då tvåfasströmning är ett komplicerat problem, som denna rapport inte fokuserar på, har många förenklingar gjorts.

Förenklningarna innebär att strömningen modelleras som en fluid och att strömningen är laminär i de raka sektionerna samt turbulent i krökar och diameterförändringar. Numeriska antaganden listas i tabell 3 med kommentarer.

Tabell 3: *Tabell över konstanter använda i strömningsmodell.*

Variabel	Storhet	Enhet	Beskrivning
μ	1,49	kg/(ms)	Viskositet för glycerin [19]
R	0,070	m	Krökningsradien för rörets axel
d	0,060	m	Rörets innerdiameter
d_h	0,1031	m	Hydrauliska radien hos röret
V	0,5	m/s	Initialt uppskattad hastighet
Re	10	-	Initialt uppskattat Reynoldstal
ρ	975	kg/m ³	Beräknad densitet för stärkelseblandning, kap. (4.2)
p_1	0,4	MPa	Maximal tryckskillnad använd i experimentell uppställning
L	4	m	Total längd raka rör
ν	0,0015	m ² /s	Beräknad dynamisk viskositet

Bernouillis ekvation, även kallad energiekvationen, balanserar tillförd och förlorad energi i flödessystemet. I detta fall kommer den tillförda energin från tryckluften p_1 . Förlusterna kan delas upp i tidsberoende och tilläggsförluster. Den tidsberoende förlusten är den ständigt skiftande nivåförändringen Δz , något som försummas för enkelhetens skull.

$$\frac{p_1}{\rho g} + \frac{v_1^2}{2g} + z_1 = \frac{p_2}{\rho g} + \frac{v_2^2}{2g} + z_2 + \Delta h_f \quad (22)$$

Tilläggsförlusterna beräknas enligt ekvation (23) och är beroende av flödeshastigheten. Den första termen $f \frac{L}{D}$ representerar friktionsförluster längs hela röret.

$$\Delta h_f = \left(f \frac{L}{D} + \sum K\right) \frac{V^2}{2g} \quad (23)$$

Summan i andra termen i ekvation (23) kallas för lokala förluster och anges i ekvation (24). I detta fall uppkommer lokala förluster i de båda krökarna och diameterförändringarna.

$$\sum K = 2(K_{\text{krök}} + K_d) \quad (24)$$

Ekvation (25) och (26) visar lokal förlust för en 90° krök med radie R .

$$K_{\text{krök}} = 0,388\alpha\left(\frac{R}{d}\right)^{0,84} \text{Re}^{-0,17} \quad (25)$$

$$\alpha = 0,95 + 4,42 \cdot \left(\frac{R}{d}\right)^{-1,96} \quad (26)$$

Ekvation (27) visar lokal förlust för en diameterförändring med maximalt skarp kant.


$$K_d = 0,5 \quad (27)$$

Då den slutgiltiga funktionen för V beror av Reynoldstalet som i sin tur är beroende av V så löstes problemet iterativt. V beräknades med ekvation (28) och Reynoldstalet enligt ekvation (29) för varje iteration.

$$V = \sqrt{\frac{2p_1}{\rho} \left(\frac{64L}{\text{Re} \cdot d} + 0,776\alpha\left(\frac{R}{d}\right)^{0,84} \text{Re}^{-0,17} + 2 \cdot 0,5 \right)} \quad (28)$$

$$\text{Re} = \frac{VL}{\nu} \quad (29)$$

4.4 Mikrovågsmätning



Figur 6: Mikrovågssensorcell med portar 1-4.

Mikrovågsmätningar utfördes på livsmedelsimitationen för att mäta spridningsparametrarna, S-parametrarna, på de fyra portarna till en rörformad mikrovågssensor som blandningen passerar genom, se figur 6. S-parametrarna svarar mot reflektions- och transmissionskoefficienter betraktat från mikrovågsportarna för sensorn. Viktigt att notera är att S-parametrarna beror på permitiviteten $\varepsilon(\omega)$, vilket är en frekvensberoende materialkonstant. Därav måste frekvensen anges för alla S-parametervärden som mäts [20]. Generellt kan S-parametrarna beskrivas som förhållandet mellan mottagen och utskickad amplitud. För en 4-port kan detta beskrivas som en matris enligt ekvation (30).

$$S = \begin{bmatrix} S_{11} & S_{12} & S_{13} & S_{14} \\ S_{21} & S_{22} & S_{23} & S_{24} \\ S_{31} & S_{32} & S_{33} & S_{34} \\ S_{41} & S_{42} & S_{43} & S_{44} \end{bmatrix} \quad (30)$$

S_{11} är reflektionskoefficienten för port 1, se figur 6, när port 2 avslutas med en matchad last. På motsvarande sätt är S_{22} reflektionskoefficienten för port 2. S_{21} är transmissionskoefficienten från port 1 till port 2 och S_{12} är motsvarande transmissionskoefficient från port 2 till port 1 [21]. Samma teori gäller för övriga S-parametrar. Notera att S antas vara ett reciprokt system, alltså $S = S^T$ där T betecknar transponatet. Av den anledningen mäts exempelvis enbart S_{12} och inte S_{21} .

Två nätverksanalysatorer användes för att mäta S-parametrarna: *MTRX* utvecklad av FRS och *Watson* utvecklad av Keysight. *MTRX* är okalibrerad och ger enbart relativa mätvärden. Fördelen med detta är att ingen kalibrering behövs inför användning. Såväl mätastigheten T_m som samplingstiden T_s för *MTRX* är ungefär 40 000 mätningar per sekund, vilket motsvarar 25 μs per mätpunkt. En mätning med *MTRX* resulterar i en 4×4 S-parametermatris [22]. Nätverksanalysatorn *Watson* ger till skillnad från *MTRX*-instrumentet absoluta S-parametervärden. Detta kräver dock kalibrering inför användning. Kalibrering som görs är en SOLT-kalibrering. Denna kalibrering är en enportsmätning av varje testport. Kalibreringen går ut på att göra referensmätningar vid kortslutning (S - short), vid avbrott (O - open circuit), vid last, med ett 50 Ω -motstånd, (L - load) samt vid mätning mellan portarna (T - through). Dessutom görs en isolation-mätning där båda portarna ansluts till varsitt 50 Ω -motstånd. Att 50 Ω -motstånd används beror på att systemet är ett 50 Ω -system och att sensorerna är 50 Ω -optimerade. *Watson*

har en mät hastighet på cirka 5 000 000 mätningar per sekund vilket motsvarar cirka 200 ns per mätpunkt. Däremot begränsas antal mätningar till tiden som krävs för att skriva mätvärdena till fil. Således är samplingstiden $T_s = 36,2$ ms. Observera att *Watson* enbart har två portar. Därav används två *Watson*-enheter för att kunna mäta transmissionen i två riktningar. Det första *Watson*-instrumentet kopplas till port 1 och port 2 i figur 6 och mäter S_{12} samt S_{22} . Det andra *Watson*-instrumentet kopplas till port 3 och port 4 och mäter S_{34} samt S_{44} .

Mätområdet som analyserats är 2-3 GHz. Våglängden för mätsignalen är jämförbar med längden av en typisk böna, som ungefär är 20 mm lång. Detta innebär att det uppstår en betydande spridning av mätsignalen. Om våglängden var mycket större än en typisk böna hade Rayleigh-approximationen kunnat användas. För att räkna ut spridningen i detalj kan man möjligtvis anta att bönorna är sfäriska och använda Mie-serien [5].

Det är värt att notera att det inte går att ta fram ett exakt värde på livsmedelsimitationens permittivitet utifrån börnas permittivitet och stärkelsens permittivitet, vilket presenteras i figur 34 respektive 35 i bilaga D [5]. Däremot kan man utifrån kunskap om stärkelseblandningens permittivitet beräkna kortaste våglängden för mätsignalen i stärkelseblandningen. Kortaste våglängden beräknas med ekvation (31).

$$\lambda_{\min} = \frac{2\pi}{\beta} \quad (31)$$

I ekvationen ovan ges β av ekvation (32).

$$\beta = \frac{\omega}{\sqrt{2}} \sqrt{\mu_0 \epsilon' (\sqrt{1 + (\epsilon''/\epsilon')^2} + 1)} \quad (32)$$

I ekvation ovan är ω vinkelfrekvensen och μ_0 permeabiliteten i vakuum.

Den beräknade kortaste våglängden i stärkelseblandningen kan användas för att undersöka om man kan avgöra att mätningar sker under kvasistationära förhållanden. För att säkerställa kvasistationära förhållanden under en mätning behöver den maximala flödes hastigheten i röret $v_{\max}$ relateras till samplingsperioden T_m och den kortaste våglängden. Det kan antas vara kvasistationära förhållanden då den kortaste våglängden $\lambda_{\min}$ är större än den sträcka livsmedelsimitationen hinner röra sig under en mätning, se ekvation (33).

$$\lambda_{\min} \gg v_{\max} T_{\text{m}} \quad (33)$$

En mätning med *Watson* resulterar i mätvärden för S_{12} , S_{22} , S_{34} och S_{44} för n olika frekvenser f_i . Givet detta komplexvärda mätdata vektoriseras real- och imaginärdelarna för att konstruera en datavektor. Datavektorn $\mathbf{x}(t)$ för de två *Watson*-instrumenten som användes visas i ekvation (34) där kolonnvektorerna $\mathbf{x}^{\text{w1}}(t)$ och $\mathbf{x}^{\text{w2}}(t)$ i ekvation (35) motsvarar *Watson* 1 respektive *Watson* 2.


$$\mathbf{x}(t) = \begin{bmatrix} \mathbf{x}^{\text{w1}}(t) \\ \mathbf{x}^{\text{w2}}(t) \end{bmatrix} \quad (34)$$

$$\mathbf{x}^{\text{w1}}(t) = \begin{bmatrix} \text{Re}\{S_{12}^{\text{w1}}(f_1)\} \\ \vdots \\ \text{Re}\{S_{12}^{\text{w1}}(f_n)\} \\ \text{Im}\{S_{12}^{\text{w1}}(f_1)\} \\ \vdots \\ \text{Im}\{S_{12}^{\text{w1}}(f_n)\} \\ \text{Re}\{S_{22}^{\text{w1}}(f_1)\} \\ \vdots \\ \text{Re}\{S_{22}^{\text{w1}}(f_n)\} \\ \text{Im}\{S_{22}^{\text{w1}}(f_1)\} \\ \vdots \\ \text{Im}\{S_{22}^{\text{w1}}(f_n)\} \end{bmatrix} \quad \mathbf{x}^{\text{w2}}(t) = \begin{bmatrix} \text{Re}\{S_{34}^{\text{w2}}(f_1)\} \\ \vdots \\ \text{Re}\{S_{34}^{\text{w2}}(f_n)\} \\ \text{Im}\{S_{34}^{\text{w2}}(f_1)\} \\ \vdots \\ \text{Im}\{S_{34}^{\text{w2}}(f_n)\} \\ \text{Re}\{S_{44}^{\text{w2}}(f_1)\} \\ \vdots \\ \text{Re}\{S_{44}^{\text{w2}}(f_n)\} \\ \text{Im}\{S_{44}^{\text{w2}}(f_1)\} \\ \vdots \\ \text{Im}\{S_{44}^{\text{w2}}(f_n)\} \end{bmatrix} \quad (35)$$

För *Watson* som mäter över 10 olika frekvenser kommer vektorn som ska analyseras vara av dimension $80 \times M$ för M mätningar. Motsvarande datavektor skapas för *MTRX* som mäter 80 olika kombinationer av frekvens och mätriiktning, vilket resulterar i en datavektor av dimension $160 \times M$ för M mätningar.

4.5 Referensmätning med kamera

För att uppskatta mängden bönor i livsmedelsimitationen, detektera främmande föremål samt beräkna livsmedelsimitationens flödes hastighet användes en videokamera. Kameran är placerad mellan mätinstrumenten över siktglasets, se figur 7. Då livsmedelsimitationen inte är transparent fästes en LED-modul på undersidan av siktglasets vid mätningar. Ett rutat papper fästes på en del av röret, se figur 7. Detta för att med bildbehandling kunna uppskatta livsmedelsimitationens flödes hastighet. Utöver detta finns en referenspunkt markerad på det rutade pappret. Distansen från referenspunkten till mätcellerna för *MTRX* och *Watson* är uppmätt. Referenspunkten syftar till att med hjälp av flödes hastigheten och distansen till mätcellen kunna avgöra när mätinstrumenten mäter på ett främmande föremål. Videobehandling i MATLAB användes för att automatisera identifikation av de mätsampel som främmande föremål förekommer i.



Figur 7: *Position för kamera.*

4.6 Styrsystem

Ett styrsystem har utvecklats för att möjliggöra automatiserade mätningar. Styrsystemet består huvudsakligen av tre komponenter, i form av datorprogram, som kommunicerar med varandra.

Ett program på en mikrokontroller kontrollerar de fysiska delarna av den experimentella uppställningen, som visas i figur 5, och ansvarar för diverse sensoravläsningar. Utöver detta används

en utgång för att signalera pågående trycköverföring i flödessystemet. Med de fysiska delarna menas ventiler för insläpp eller utsläpp av tryckluft. Mikrokontrollern läser av nivågivare för de båda tankarna och använder detta som underlag för att avgöra om en överföring i uppställningen är genomförd. Mikrokontrollern läser även av uppställningens temperaturgivare.

Ett huvudprogram exekveras på en PC med mikrokontrollern kopplad till sig via seriekommunikation. Huvudprogrammet fungerar som ett abstraktionslager för mikrokontrollern, till exempel kan man från huvudprogrammet starta autonoma mätningar, utan att behöva veta hur mikrokontrollern utför denna uppgift. Huvudprogrammet och mikrokontrollern har ett etablerat kommunikationsprotokoll sinsemellan som bland annat används för statusuppdateringar. Huvudprogrammet har även en nätverksanslutning till det program som styr de båda nätverksanalysatorerna *Watson*, se figur 5. Kommunikationen går en väg och huvudprogrammet gör inte mer i detta avseende än att skicka start- och stoppkommandon.

Programmet som styr nätverksanalysatorerna *Watson* ansvarar för kalibrering och datainsamling för dessa. En mätning startas eller avslutats med kommandon mottagna från huvudprogrammet.

5 Resultat

I detta avsnitt presenteras resultatet av datainsamlingens processen samt detektionsmetoderna histogram och autoencoder. Dessutom görs en jämförelse mellan marginaltätetsfunktionerna och motsvarande histogram.

5.1 Livsmedelsimitation


Livsmedelsimitationen som användes vid datainsamlingen bestod av kidneybönor, stärkelse och vatten. En empirisk undersökning genomfördes för att säkerställa en livsmedelsimitation där de kritiska parametrarna transparens, densitet och viskositet uppfylldes, vilket visas i bilaga B. Efter genomförda tester beslutades att volymproportionen 1:11,5 mellan stärkelse och vatten bäst uppfyllde kriterierna. Proportionen bönor baserades på proportionen i en referens, chili con carne, vilket presenteras i tabell 4. För en detaljerad beskrivning hur bönproportionen bestämdes, se bilaga A.

Tabell 4: *Resultat av experimentell framtagning av bönmängd från chili con carne.*

Beskrivning	Storhet	Enhet
Total volym chili con carne	2,45	liter
Total massa chili con carne	2,38	kg
Volym bönor	0,25	liter
Massa bönor	0,36	kg
Volym / Massa chili con carne	1,03	liter/kg
Volym bönor / Volym chili con carne	10	%
Massa bönor / Massa chili con carne	15	%

5.2 Detektion med kamera

Kameran hade två syften: att visuellt detektera främmande föremål samt att mäta flödeshastigheten. Främmande föremål kunde inte urskiljas från bakgrunden alla gånger de passerade siktglaset, något som exemplifieras med datan i figur 8. I figuren bör detektionsmaximum generellt finnas mellan varje startad och slutförd överföring. Notera att datan baseras på ett mättillfälle där en 20 mm $\times$ 20 mm hårdplastbit användes.



Figur 8: *En kort sekvens av resultatet från videoanalysen.*

För att demonstrera kamerans förmåga så visas andra och tredje detektionsmaximum i figur 9.



Figur 9: *Bilder ur vilka videoanalysen detekterat en 20 mm × 20 mm hårdplastbit, t.v. t = 129 och t.h. t = 159.*

Från videobehandlingsprogrammet uppmättes strömningshastighet hos livsmedelsimitationen som visas i tabell 5. I avsnitt 4.3 *Design och modell av flödessystemet* beskrevs metoden för beräkning av flödes hastigheten, vilket resulterade i en hastighet $V = 3,828$ m/s, samt ett Reynoldstal $Re = 78$. Således skiljer det sig mycket mellan teoretiskt beräknad strömningshastighet

och uppmätt strömningshastighet. Notera att de tre sista värdena är avvikande på grund av falska positiv i videobehandlingsprogrammet.

Tabell 5: *Visuellt uppmätta flödeshastigheter.*

V [m/s]
0,2448
0,1358
0,1478
0,1291
0,1318
0,1137
0,1164
0,1438
0,1458
0,1117
0,1157
0,1064
0,0281
0,0308
0,0468

5.3 Mikrovågsmätning


För de använda mätinstrumenten har en kortast möjliga våglängd för mätsignalen genom livsmedelsimitationen beräknats, se ekvation (31). Det resulterar i en kortaste våglängd $\lambda_{\min}$, vid frekvens 3 GHz, på cirka 12 mm. *MTRX* har en mätastighet på 25 μs per mätpunkt, vilket innebär att en komplett mätvektor med 80 mätpunkter har en mättid på $T_m = 2$ ms. *Watson* har en mätastighet på 200 ns per mätpunkt och för 40 mätpunkter resulterar detta i en mättid på 8 μs . Den högsta uppmätta flödeshastigheten är $V_{\max} = 0,2448$ m/s. Utifrån detta kan säkerställas att $\lambda_{\min} \gg V_{\max}T_m$ är uppfyllt för både *MTRX* och *Watson*. Detta tyder på att det råder kvasistationära förhållanden under mätningarna.

5.4 Förbehandling av data


För att säkerställa att tillförlitlig data används avlägsnas den första och sista åttondelen av mätsekvensen för både *Watson* och *MTRX*. Detta eftersom visuell observation av en överföring visar en jämn fördelning av böror bortsett från den inledande och avslutande delen. I dessa

delar är livsmedelsimitation relativt fri från böror.


Data från *Watson* presenteras i tidsplanet i figur 10 och i frekvensplanet i figur 13. I tidsplanet syns tendenser till periodiskt beteende. Det periodiska beteendet syns extra tydligt i mätsekvansens diskreta fouriertransform. Det verkar alltså finnas lågfrekventa störningar i systemet. Utifrån mätningar som endast består av den mittersta fjärdelen av en överföring kan det säkerställas att den lågfrekventa störningen inte beror på att livsmedelsimitationen transporteras fram och tillbaka. Högpasstrerering utfördes för att eliminera den lågfrekventa störningen. Resultatet av högpasstrereringen för datan från *Watson* presenteras i tidsplanet figur 11 och i frekvensplanet i figur 13. Den lågfrekventa störningen uppkommer även för *MTRX*. Resultatet av högpasstrereringen för datan från *MTRX* presenteras i frekvensplanet i figur 12.




Figur 10: Mätningar för en transmissionskoefficients magnitud och fas för ofiltrerad data från *Watson* för en specifik frekvens i tidsplanet.



Figur 11: Mätningar för en transmissionskoefficients magnitud och fas för högpasfiltrerad data från Watson för en specifik frekvens i tidsplanet.



Figur 12: Den diskreta fouriertransformen för ofiltrerad data samt filtrerad data av mätningar av en transmissionskoefficient för MTRX för en specifik frekvens.




Figur 13: Den diskreta fouriertransformen för ofiltrerad data samt filtrerad data av mätningar av en transmissionskoefficient för Watson för en specifik frekvens.

Vid mätningar med MTRX utfördes enbart transmissionsmätningar, men för Watson utfördes även reflektionsmätningar. Reflektions- och transmissionskoefficientens signalstyrka för en S-parameter presenteras i figur 14. Transmissionskoefficientens signalstyrka är avsevärt lägre än för reflektionskoefficienten. Då denna data är av olika magnitud normaliseras datan kompo-


nentvis i ekvation (36).

$$x_{\text{norm}} = \frac{x - \mu}{\sigma} \quad (36)$$

I ekvationen ovan är μ och σ medelvärdet respektive standardavvikelsen för den specifika komponenten.




Figur 14: *Reflektions- och transmissionskoefficients signalstyrka före normalisering för Watson.*




Figur 15: *Reflektions- och transmissionskoefficients signalstyrka efter normalisering för Watson.*

5.5 Estimering av täthetsfunktioner

Då *Watson* är kalibrerad och *MTRX* är okalibrerad samt att mätfrekvenserna är något olika för mätinstrumenten är det svårt att jämföra *MTRX* och *Watson*. Därför analyseras mätinstrumenten endast var för sig. En visuell uppskattning av hur normalfördelad datan är före och efter högpasfiltrering presenteras i figur 16 respektive figur 17 för *Watson*. Figurerna visar den bivariata normalfördelningen med tillhörande histogram. Liknande resultat erhöles för *MTRX*.



Figur 16: *Bivariat normalfördelning och histogram över S_{34} från Watson över andra frekvensen, ofiltrerad data.*




Figur 17: *Bivariat normalfördelning och histogram över S_{34} från Watson över andra frekvensen, filtrerad data.*

5.5.1 Reproducerbarhet

För att undersöka reproducerbarheten skapas en medelvärdesvektor för flera mättillfällen. Medelvärdesvektorn visas i ekvation (37), där M antalet dimensioner i en mät punkt.

$$\bar{\mathbf{x}}(t) = \begin{bmatrix} \bar{x}_1(t) & \bar{x}_2(t) & \cdots & \bar{x}_M(t) \end{bmatrix}^T \quad (37)$$

Medelvärdesvektorn skapades för fyra olika mättillfällen och presenteras i figur 18. Medelvärdesvektorerna tycks konvergera mot liknande värden.



Figur 18: *Medelvärdesvektorer fyra olika mättillfällen på livsmedelsimitationen med mätinstrument Watson.*

5.6 Histogram för detektion

Tabell 6 visar resultatet för den detektionsmetod som är beskriven i avsnitt 3.2 *Histogram*. Tabellen visar frekvensen för de fyra olika utfallen: genomsläpp av normalfall, genomsläpp av främmande föremål, utkast av normalfall och utkast av främmande föremål. Metoden applicerades på datavektorer från både *Watson* och *MTRX* med ett antal olika tröskelvärden. Validering av utkastet baseras på den visuella detektionsmetod som är beskriven i avsnitt 4.5 *Referensmätning med kamera*. Som ett exempel, studera *Watson* för tröskelvärde -370. För detta fall sker 156 utkast av normalfall och 7 utkast av främmande föremål medan 423 normalfall och 2 främmande föremål släpps igenom.

Tabell 6: *Klassificerade utfall från detektion med histogram.*


Mätinstrument	Tröskelvärde	Händelse	Normalfall	Främmande föremål
<i>Watson</i>	-330	Genomsläpp	366	0
		Utkast	312	9
	-350	Genomsläpp	416	2
		Utkast	163	7
	-370	Genomsläpp	423	2
		Utkast	156	7
<i>MTRX</i>	-300	Genomsläpp	20	0
		Utkast	456	14
	-450	Genomsläpp	132	2
		Utkast	344	12
	-475	Genomsläpp	268	4
		Utkast	208	10
	-500	Genomsläpp	389	8
		Utkast	87	6

5.7 Autoencoder


Två autoencoders optimerades för varje nätverksanalysator, en för högpasfiltrerad och en för ofiltrerad data.

5.7.1 Estimering av underliggande frihetsgrader


Kovariansmatrisens singularvärden användes till att estimeras antalet underliggande frihetsgrader för autoencodern. Dessa singularvärden beskriver en normalfördelnings varians i varje dimension. Antalet frihetsgrader baseras på singularvärdernas relativa storlek till varandra. Ett litet singularvärde innebär relativt liten skillnad i mätdata för denna dimension. Vid projicering på ett underrum leder avsaknaden av denna dimension till relativt liten informationsförlust. Singularvärdena för högpas- och ofiltrerad data från mätningar av *Watson* visas i figur 19 och figur 20. I dessa graf visas att de första 15-20 indexen är av märkbart större magnitud än de resterande. Dessa singularvärden kan därav antas vara tillräckliga för att beskriva det underliggande rummet. Utifrån singularvärdena estimeras antal underliggande frihetsgrader i mittersta lagret av autoencoder för *Watson* till cirka 18. På motsvarande sätt estimeras antal underliggande frihetsgrader för *MTRX* utifrån figur 21 och figur 22 till cirka 33.




Figur 19: *Singulärvärden för livsmedelsimitation med högpasfilterad data från Watson.*



Figur 20: *Singulärvärden för livsmedelsimitation med ofiltrerad data från Watson.*



Figur 21: *Singulärvärden för livsmedelsimitation med högpasfilterad data från MTRX.*



Figur 22: *Singulärvärden för livsmedelsimitation med ofiltrerad data från MTRX.*

5.7.2 Optimering av hyperparametrar

Resultatet från optimeringen av hyperparametrarna för *Watson* med högpasfilterad data visas i tabell 7 och för ofiltrerad data i tabell 8. För optimering användes en 80×193351 matris. För validering användes en 80×48337 matris. För *MTRX* visas resultatet av optimeringen av hyperparametrarna i tabell 9 och tabell 10. Datan från *MTRX* var en 160×183477 matris för optimering och en 160×45869 matris för validering.

Tabell 7: Valda hyperparametervärden och aktiveringsfunktioner efter optimering för funktionen `trainAutoencoder` i MATLAB med högpasfiltrerad data från *Watson*.

Parameter	Värde
EncoderTransferFunction	satlin
DecoderTransferFunction	purelin
HiddenSize	16
L2WeightRegularization	0,015
SparsityRegularization	2,5
SparsityProportion	0,5

Tabell 8: Valda hyperparametervärden och aktiveringsfunktioner efter optimering för funktionen `trainAutoencoder` i MATLAB med ofiltrerad data från *Watson*.

Parameter	Värde
EncoderTransferFunction	logsig
DecoderTransferFunction	purelin
HiddenSize	15
L2WeightRegularization	0,001
SparsityRegularization	4,35
SparsityProportion	0,75


Tabell 9: Valda hyperparametervärden och aktiveringsfunktioner efter optimering för funktionen `trainAutoencoder` i MATLAB med högpasfiltrerad data från *MTRX*.

Parameter	Värde
EncoderTransferFunction	logsig
DecoderTransferFunction	logsig
HiddenSize	65
L2WeightRegularization	0,004
SparsityRegularization	2,5
SparsityProportion	0,5

Tabell 10: Valda hyperparametervärden och aktiveringsfunktioner efter optimering för funktionen `trainAutoencoder` i MATLAB med ofiltrerad data från *MTRX*.

Parameter	Värde
EncoderTransferFunction	logsig
DecoderTransferFunction	purelin
HiddenSize	95
L2WeightRegularization	0,005
SparsityRegularization	4,5
SparsityProportion	0,5


Ett exempel på en hyperparamereroptimering visas i figur 23. Denna figur presenterar optimeringen av antal underliggande frihetsgrader i mittersta lagret av autoencodern, med hyperparameternamn "HiddenSize" i MATLAB. Optimeringen utfördes mellan 2-40 i steg om två för högpasfiltrerad data från *Watson*. Minstakvadratfelet blev lägst för 16 neuroner i det mittersta lagret av figuren att döma. På motsvarande sätt erhöles en "HiddenSize" för *MTRX* på 65 för högpasfiltrerad data, se tabell 9, och 95 för ofiltrerad data, se tabell 9.




Figur 23: *Antal neuroner i mittersta lagret i autoencodern för högpassfiltrerad data från Watson vid 250 iterationer.*

5.7.3 Rekonstruktion

Rekonstruktion av mätdata utan främmande föremål från *Watson* gjordes. Detta för att undersöka hur rekonstruktionsfelet varierar över en mätsekvens. Rekonstruktionsfelet beräknades enligt ekvation (19). Detta visas i figur 24 och figur 25 för högpassfiltrerad respektive ofiltrerad data. Notera att rekonstruktionsfelet för reflektionskoefficienterna S_{22} och S_{44} uppvisar ett avvikande beteende jämfört med rekonstruktionsfelet för autoencodern tränad på ofiltrerad data.




Figur 24: Fel mellan indata och utdata för högpassfiltrerad data utan främmande föremål från ett överföringstillfälle, med en autoencoder tränad på högpassfiltrerad data från Watson. Varje heldragen linje representerar felet för en vägkombination.




Figur 25: Fel mellan indata och utdata för ofiltrerad data utan främmande föremål från ett överföringstillfälle, med en autoencoder tränad på ofiltrerad data från Watson. Varje heldragen linje representerar felet för en vägkombination.

Autoencodern för ofiltrerad och högpassfiltrerad data användes för att undersöka om data innehållande främmande föremål visade stort fel för det sampel där en 20 mm $\times$ 20 mm bit av hårdplast passerade mikrovågssensorn. Autoencodern för högpassfiltrerad och ofiltrerad data från Watson presenteras i figur 26 respektive figur 27.




Figur 26: Fel mellan indata och utdata för högpassfiltrerad data innehållande främmande föremål från ett överföringstillfälle, med en autoencoder tränad på högpassfiltrerad data från Watson. Den streckade linjen är det sampel där plastbiten befinner sig vid mikrovågssensorn på Watson och varje heldragen linje representerar felet för en vägkombination.




Figur 27: Fel mellan indata och utdata för ofiltrerad data innehållande främmande föremål från ett överföringstillfälle, med en autoencoder tränad på ofiltrerad data från Watson. Den streckade linjen är det sampel där plastbiten befinner sig vid mikrovågssensorn på Watson och varje heldragen linje representerar felet för en vägkombination.

För *MTRX* rekonstruerades även datan utan främmande föremål och felet beräknades på samma sätt. Då *MTRX* mäter fler S-parameterar än *Watson* namngavs inte de olika S-parametrarna i grafen. I figur 28 visas resultatet från den högpasfiltrerade datan medan i figur 29 visas resultatet från den ofiltrerade datan. För *MTRX* visade båda autoencoders ett normalt beteende jämfört med autoencodern för högpasfiltrerad data från *Watson*, se figur 24.




Figur 28: Fel mellan indata och utdata för högpasfiltrerad data utan främmande föremål från ett överföringstillfälle, med en autoencoder tränad på högpasfiltrerad data från *MTRX*. Varje heldragen linje representerar felet för en vägkombination.




Figur 29: Fel mellan indata och utdata för ofiltrerad data utan främmande föremål från ett överföringstillfälle, med en autoencoder tränad på ofiltrerad data från *MTRX*. Varje heldragen linje representerar felet för en vägkombination.

Resultatet av rekonstruktionen för högpas- samt ofiltrerad data innehållande samma 20 mm $\times$ 20 mm hårdplastbit presenteras i figur 30 respektive figur 31.



Figur 30: Fel mellan indata och utdata för högpassfiltrerad data innehållande främmande föremål från ett överföringstillfälle, med en autoencoder tränad på högpassfiltrerad data från MTRX. Den streckade linjen är det sampel där plastbiten befinner sig vid mikrovågssensorn på MTRX och varje heldragen linje representerar felet för en vägkombination.



Figur 31: Fel mellan indata och utdata för ofiltrerad data innehållande främmande föremål från ett överföringstillfälle, med en autoencoder tränad på ofiltrerad data från MTRX. Den streckade linjen är det sampel där plastbiten befinner sig vid mikrovågssensorn på MTRX och varje heldragen linje representerar felet för en vägkombination.

6 Diskussion

I detta kapitel diskuteras de resultat som erhöles, för- och nackdelar med de använda metoderna samt vad som bör tänkas på för vidare analys.

6.1 Livsmedelsimitation

I figur 18 presenteras medelvärdesvektorn för olika mättillfällen. Då medelvärdesvektorerna ser ut att överensstämma mellan mättillfällena kan reproducerbarhet antas. Reproducerbarheten kan ses som ett gott resultat på att livsmedelsimitationerna som blandades inför varje mätning efterliknade varandra.

Då den billigare stärkelsen valdes till livsmedelsimitationen uppstod vissa problem med transparens. Detektionen med kameran var inte framgångsrik alla gånger, troligen på grund av stärkelsens dåliga ljusgenomsläpp.

Det uppstod svårigheter att detektera främmande föremål i livsmedelsimitationen. Fler variationer av livsmedelsimitationen bör ha analyserats för att avgöra vid vilket proportion av bönor det uppstår svårigheter att detektera främmande föremål.

6.2 Detektion med kamera

För datainsamling på livsmedelsimitationen innehållandes ett främmande föremål observeras det främmande föremålet endast sporadiskt i videoinspelningen. Ibland misslyckas kameran att identifiera de främmande föremålen. Detta beror sannolikt på att livsmedelsimitationen inte är tillräckligt transparent och att ansamlingar av bönor skymmer sikten. Vid kortare avstånd mellan det främmande föremålet och kameran var identifieringen mer frekvent eftersom kortare avstånd innebär mindre livsmedelsimitation mellan kameran och det främmande föremålet. En potentiell förbättring är att placera flera kameror runt siktglasets för att lättare identifiera det främmande föremålet. Ett alternativ kan vara att ha ett siktglas som är mörklagt och belyst med till exempel ultraviolett strålning. Detta möjliggör detektion av fluorescerande föremål av varierande storlek för en livsmedelsimitation av samma transparens. En hypotes är att främmande föremål av betydligt mindre storlek kan detekteras med kamera i detta fall.

Den stora differensen mellan uppmätt strömningshastighet och teoretiskt beräknad strömningshastighet beror troligen på de många förenklingar som gjorts vid den teoretiska beräkningen, se avsnitt 4.3 *Design och modell av flödessystem*. Variationen i den uppmätta strömningshastigheten kan ha flera anledningar. För det första är mätningarna osäkra på grund av begränsningar i videoanalys-metoden beskriven i avsnitt 4.5 *Referensmätning med kamera*. Positionsbestämningen av det främmande föremålet är endimensionell, och kan därför ge en felaktig bild av rörelsen om föremålet roterar. Tiden mellan position ett och position två är liten och därmed känslig för vart på föremålet mittpunkten antas vara. För det andra är inte hastigheten konstant genom tvärsnittet utan är nästan noll vid kanterna och maximal i mitten. Objektets position spelar därför stor roll.

Då hastigheten inte är speciellt tillförlitlig påverkas även uppskattningen av vilken tidpunkt som föremålet befinner sig i mätcellerna. Det är problematiskt då verifiering av detektion utförs med kameradatan som grund. Kameradetektionen blir därför en medföljande felkälla i de testade detektionsmetoderna. I den visuella detektionen hittades falska positiv. De kunde dock identifieras på grund av avvikande flödes hastigheter och därmed sorteras bort.

6.3 Mikrovågsmätning

Vid mikrovågsmätningar med *Watson* var samplingsperioden betydligt långsammare än mättiden på grund av tiden det tog för programmet att skriva över datan till disken. Av den anledningen erhöles färre mätpunkter för *Watson*. Utifrån den uppmätta flödes hastigheten i storleksordningen 0,1 m/s är en frekvens på 27,6 Hz dock tillräcklig för att inte missa något förbipasserande främmande föremål.

Signalstyrkans amplitud uppmättes till att vara avsevärt mindre för reflektionskoefficienten än för transmissionskoefficienten. Detta tyder på att mycket av signalens energi absorberas av livsmedelsimitationen samt att signalen troligtvis reflekteras mot bönorna. Notera även att *MTRX* inte mäter reflektionskoefficienter, vilket *Watson* gör. För att det ska fylla ett syfte att mäta reflektionskoefficienter bör plastbiten därav finnas relativt nära mätporten. Möjligtvis hade det varit mer värt att istället för att mäta reflektionskoefficienter mäta transmissionskoefficienter mellan de båda *Watson*-instrumentens portar, exempelvis S_{13} , S_{14} , S_{23} och S_{24} . Detta hade däremot krävt mer tid för att implementera och prioriterades därav bort i detta arbete.

6.4 Förbehandling av data

Vid mätningarna upptäcktes lågfrekventa störningar. Av den anledningen utfördes högpasfiltering för att eliminera effekterna av störningen. Ursprunget till störningarna är oklart men antogs inte uppstå till följd av bönkonstellations förändring över tid genom flödessystemet under en överföring.

På grund av börnas fördelning i livsmedelsimitationen togs inledande och avslutande data bort i varje överföring. I de fall där datan behandlades sekventiellt hade de skarpa övergångarna mellan mätsekvenserna kunnat innebära problem. Då detta inte är fallet kan trimningen av datan ses som oproblematiske.

6.5 Estimering av täthetsfunktioner

För en frekvens visualiserades varje S-parameter med en multivariat normalfördelning och ett histogram. Den ofiltrerade mätdatan var inte normalfördelad enligt jämförelsen mellan täthetsfunktionen och histogrammet, se figur 16. Den filtrerade mätdatan följer dock en approximativ normalfördelning, se figur 17. En tänkbar förklaring till resultatet är den lågfrekventa störningen i mätdatan. För en mer noggrann analys bör de underliggande orsakerna till den lågfrekventa störningen utredas.

6.6 Histogram för detektion

Resultaten för den detektionsmetod som är beskriven i avsnitt 3.2 *Histogram* behöver tolkas för specifika applikationsområden. För de fall där främmande föremål absolut inte får vara en del av livsmedlet kan metoden möjligen vara användbar. För vissa tröskelvärden detekteras främmande föremål alltid eller ofta. I dessa fall fås dock även många utkast av livsmedel utan främmande föremål.

För de applikationsområden där det inte är av lika stor vikt att alla främmande föremål detekteras kan metoden anses vara mindre lyckad. En stor del normalfall blir klassade som främmande föremål och metoden blir kostsam för livsmedelstillverkaren.

Histogram som detektionsmetod kan antas vara dålig då de främmande föremålen dielektriskt liknar bakgrunden eller inklusionerna. Risk finns att de främmande föremålen i dessa fall klassas just som detta. Den höga andelen utkastade normalfall kan bero på de tidigare berörda felkällorna i avsnitt 6.2 *Detektion med kamera*. Därav kan det inte garanteras att det är histogrammetoden som är bristfällig.

6.7 Autoencoder för detektion

Orsaken till autoencoderns avvikelser för reflektionskoefficienterna S_{22} och S_{44} vid högpassfilterad data från *Watson* är okänt, se figur 24. Detta bör undersökas vid framtida studier.

Detektion med den implementerade autoencodern tycks inte fungera då ingen av nätverksanalysatorerna gav utslag för sampel innehållande främmande föremål. Autoencoder bör dock inte uteslutas som detektionsmetod då möjligheten inte har utforskats fullständigt. Det behöver nödvändigtvis inte vara autoencodern som är bristfällig. Det kan istället bero på hur rekonstruktionsfelet beräknades, se ekvation (19). Andra metoder för att beräkna rekonstruktionsfelet bör undersökas vid framtida studier.

Ett möjligt fel i optimeringsprocessen är att ingen hänsyn togs för risken att gradientmetoden inte hittar det globala minimumet. Processen är stokastisk, vilket kan resultera i att medelkvadratfelet blir litet för ett hyperparametervärde på grund av slumpen. För att minimera denna risk kan ett flertal autoencoders tränas, istället för en, för varje hyperparameterförändring och ett medelvärde av medelkvadratfelet kan beräknas.

Hårdvara var en begränsande faktor till träningsmöjligheterna för autoencodern. Träning kunde endast utföras på en bråkdel av den totala insamlade datan. För *Watson* användes ungefär hälften av den totala insamlade datan. För *MTRX* användes ungefär 2 % av totala datan till träningsprocessen. Mer arbetsminne hade gjort det möjligt att skapa en större träningsmatris. Mjukvaran var även en begränsning vid träning av autoencodern. Kommandot *trainAutoencoder* i MATLAB kunde inte pausas vilket krävde att all träningsdata laddades in i arbetsminnet. En annan begränsning är att kommandot *trainAutoencoder* i MATLAB endast skapar en autoencoder med ett djup om tre lager. Det är möjligtvis inte tillräckligt för att representera datan från livsmedelsimitationen. En förbättring hade därav varit att använda andra program för att få mer kontroll över neuronnätet, exempelvis kunna reglera djupet.

7 Slutsats och rekommendationer

De detektionsmetoder som undersöktes i projektet gav blandade resultat. För histogram detekterades, i vissa fall, alla främmande föremål till kostnaden av relativt många utkast av livsmedelsimitation utan främmande föremål. När tröskelvärdet ändras för att minska antalet utkast av normalfallet släpps främmande föremål igenom. Samtidigt förblir antalet utkast av normalfall relativt högt. En rekommendation för framtida studier är att skapa en detektionsmetod baserad på multivariat normalfördelning då datan tycktes vara approximativt normalfördelad efter högpasfiltrering.

Implementation av detektionsmetoden histogram i en industriell miljö anses orealistiskt. Utkastet av livsmedelsimitation utan främmande föremål förekommer alltför frekvent för att kunna anses vara lönsamt. Dessutom skulle matsvinnet bli alltför stort.

De neuronnät som tränades för att användas som detektionsmetod testades aldrig för detta ändamål. När rekonstruktionsfelet visualiserades för en mätsekvens innehållandes främmande föremål i samband med föremålets position i mätsekvensen sågs inget avvikande beteende. En rekommendation för framtida studier är att använda en autoencoder med större djup och som tränas på mer data.

Flödessystemets utformning gav ett representativt flöde i förhållande till en livsmedelsindustri. En tydlig variation observerades i bönkonstellationen mellan överföringarna, vilket säkerställer att sampel från hela populationen av bönkonstellationer är möjliga att erhålla.

Kameran kunde inte detektera alla främmande föremål som passerade siktglasets. Av den anledningen bör fler kameror från olika vinklar användas vid framtida studier för att säkerställa att alla främmande föremål detekteras och att det inte uppstår utslag för falska positiv i videoanalysen.

Styrsystemet som automatiserade mätningarna möjliggjorde att en stor mängd data kunde samlas in. Den datamängd som erhöles ansågs vara mer än tillräcklig för denna undersökning. I mätdata fanns dock en lågfrekvent störning. Orsaken till störningen är okänd och bör i framtida studier undersökas.

Trots olika mät dagar erhöles reproducerbara mätningar. De reproducerbara mätningarna tyder

på att livsmedelsimitationen fungerar bra i syftet att samla in mätdata. En förbättringsmöjlighet till framtida studier är att använda en mer transparent stärkelse för att lättare identifiera förbipasserande främmande föremål.

Referenser

- [1] Wikipedia: den fria encyklopedin, *Artificiell intelligens*, 2019. [Online]. Tillgänglig: https://sv.wikipedia.org/wiki/Artificiell_intelligens, hämtad: 2019-04-30.
- [2] Wikipedia: den fria encyklopedin, *Maskininlärning*, 2019. [Online]. Tillgänglig: <https://sv.wikipedia.org/wiki/Maskininlärning>, hämtad: 2019-04-30.
- [3] The MathWorks, Inc., *Multivariate Normal Distribution*, 2019. [Online]. Tillgänglig: <https://se.mathworks.com/help/stats/multivariate-normal-distribution.html>, hämtad: 2019-04-18.
- [4] N. Janakiev, *Understanding the Covariance Matrix*, 2018. [Online]. Tillgänglig: <https://www.youtube.com/watch?v=R3DNKE3zKFk&list=PLzWRmDOVi2KXcrTVBSK2w-VyjAAfNaqgF&index=6>, hämtad: 2019-04-18.
- [5] T. Rylander, Personlig kommunikation.
- [6] W. H. Press, S. A. Teukolsky, W. T. Vetterling, B.P. Flannery, *Modeling of Data in Numerical Recipes*, 3rd ed., New York, USA: Cambridge University Press, 2007, Sid. 793-798.
- [7] N. Kant, *Deep Learning Decall Fall 2017 Day 6: Autoencoders and Representation Learning*, 2017. Machine Learning at Berkeley Foundation. [Videofil]. Tillgänglig: <https://www.youtube.com/watch?v=R3DNKE3zKFk&list=PLzWRmDOVi2KXcrTVBSK2w-VyjAAfNaqgF&index=6>, hämtad: 2019-04-04.
- [8] C. Karmen, K. Bousnobra, O. Taha, B. Raymond, *Estimation of River Ice Thickness Using Artificial Neural Networks*, 2019. [Online]. Tillgänglig: https://www.researchgate.net/publication/255629329_Estimation_of_River_Ice_Thickness_Using_Artificial_Neural_Networks, hämtad: 2019-03-06.
- [9] The MathWorks, Inc., *logsig*, 2019. [Online]. Tillgänglig: <https://se.mathworks.com/help/deeplearning/ref/logsig.html>, hämtad: 2019-05-07.
- [10] The MathWorks, Inc., *purelin*, 2019. [Online]. Tillgänglig: <https://se.mathworks.com/help/deeplearning/ref/purelin.html>, hämtad: 2019-05-15.

- [11] The MathWorks, Inc., *satlin*, 2019. [Online]. Tillgänglig: <https://se.mathworks.com/help/deeplearning/ref/satlin.html>, hämtad: 2019-05-15.
- [12] The MathWorks, Inc., *Train an autoencoder*, 2019. [Online]. Tillgänglig: <https://se.mathworks.com/help/deeplearning/ref/trainautoencoder.html>, hämtad: 2019-04-18.
- [13] Wikipedia: den fria encyklopedin, *Overfitting*, 2019. [Online]. Tillgänglig: <https://en.wikipedia.org/wiki/Overfitting>, hämtad: 2019-04-04.
- [14] Wikipedia: den fria encyklopedin, *Gradient descent*, 2019. [Online]. Tillgänglig: https://en.wikipedia.org/wiki/Gradient_descent, hämtad: 2019-04-04.
- [15] Deeplearning.ai *The Problem of Local Optima (C2W2L10)*, 2017. [Videofil]. Tillgänglig: <https://www.youtube.com/watch?v=fODpu1-lNTw>, hämtad: 2019-05-06.
- [16] I. Goodfellow, Y. Bengio, A. Courville, *Deep Learning*, 2016. MIT Press. Tillgänglig: <http://www.deeplearningbook.org>, hämtad: 2019-05-16.
- [17] Wikipedia: den fria encyklopedin, *Permittivity*, 2019. [Online]. Tillgänglig: <https://en.wikipedia.org/wiki/Permittivity>, hämtad: 2019-03-12.
- [18] IEEE Std 211-1997, *IEEE Standard Definitions of Terms for Radio Wave Propagation*, 1997. [Online]. Tillgänglig: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=8638365>, hämtad: 2019-03-12.
- [19] Franc M White, *Fluid Mechanics*, 8th edition, 2016.
- [20] Wikipedia: den fria encyklopedina, *Scattering parameters*, 2019. [Online]. Tillgänglig: https://en.wikipedia.org/wiki/Scattering_parameters, hämtad: 2019-02-28.
- [21] F. Caspers, *RF engineering basic concepts: S-parameters*, CERN Yellow Report CERN-2011-007, sid. 67-93, 2012. [Online]. Tillgänglig: <https://cds.cern.ch/record/1415639/files/p67.pdf>, hämtad: 2019-03-04.
- [22] J. Nilsson, Personlig kommunikation.

A Experiment - Chili con carne

Projektgruppen genomförde ett test som gick ut på att mäta volymandel respektive viktandel för de bönor som finns i en påse chili con carne. Testet utfördes i ett laboratorium på FRS. Resultatet användes sedan för att visa vilken mängd bönor som livsmedelsimitationen ska innehålla vid datainsamlingen.

Genomförande

Volymen för chili con carne-påsen uppmättes genom att sänka ner påsen i en hink med vatten. Chili con carnem pressades nedåt i påsen för att undvika mäta volymen i påsen som upptogs av luft. Volymen togs fram genom att jämföra vattenvolymen innan påsen sänktes ner i vattnet och efter påsen sänkts ner. Volym för bönorna beräknades på samma sätt.

Vid uppvägning av chili con carne-påsen ansågs luften i påsen försumbar. Vikten av bönorna togs fram genom att för hand sortera ut alla bönor från påsen med chili con carne för att sedan väga dem.

Resultat

Resultatet från genomförandet visas i tabell 11.

Tabell 11: *Resultat av experimentell framtagning av bönmängd från chili con carne.*

Beskrivning	Storhet	Enhet
Total volym chili con carne	2,45	liter
Total massa chili con carne	2,38	kg
Volym bönor	0,25	liter
Massa bönor	0,36	kg
Volym/Massa chili con carne	1,03	liter/kg
Volym bönor/Volym chili con carne	10	%
Massa bönor/Massa chili con carne	15	%

B Experiment - Blandning av vatten och stärkelse

En empirisk undersökning genomfördes för säkerställa en blandning som uppfyller de kritiska parametrarna: transparens, densitet och viskositet. Blandningen skulle vara så utspädd som möjligt för att maximera transparensen och minimera viskositeten samtidigt som blandningen måste vara tillräckligt tjock för att börnorna inte ska sjunka till botten. Till sist testades Hållfastheten så att den organiska livsmedelsimitationen klarar av de krav som ställs vid transport i den experimentella uppställningen.

Genomförande

Initialt användes proportionen 1:10 mellan stärkelse och vatten. Experimentet utfördes genom att först hålla upp 1 liter varmvatten och tillsätta en deciliter stärkelse innan omrörning. Omrörning utfördes för att få bort klumparna som bildades från stärkelsen. Processen upprepades för att hitta det förhållande som bäst uppfyller kraven.

Då stärkelsen fått en jämn fördelning i vattnet tillsattes en förutbestämd mängd kidneybönor. Mängden baserades på de volymförhållande och viktförhållande som bestämts tidigare.

För att undersöka hur transparent lösningen var hälldes blandningen i ett siktglas. Därefter positionerades en LED-slinga bakom siktröret för att, på ett tydligt sätt, se börnornas position. En kamera positionerades parallellt på andra sidan siktglaset för att säkerställa detta.

Resultat

I figur 32 visas det erhållna resultatet från testet mellan vatten, stärkelsen och kidneybönorna. Jämförelsen mellan de olika proportionerna var densitet, blandningsförmåga, hur transparent imitationen blev samt börnornas position.

Proportioner mellan stärkelse och vatten							
Tester							
Viktningskala 1-10, där 1 är lägst och 10 högst							
Proportioner	1:10	1:20	1:11	1:115	1:12	1:13	1:14
Densitet	9	1	8	7	6	5	4
Blandningsförmåga	2	9	4	4	5	5	6
Bönornas position	10	1	9	9	8	7	6
Egenskaper vid uppvärmning	Oförändrat	Oförändrat	Oförändrat	Oförändrat	Oförändrat	Oförändrat	Oförändrat
Transparens i siktglas	4	7	5	5	5	5	5

Figur 32: Resultatet från de olika proportionerna som blandades.

Slutsats


Resultatet visar att proportionen mellan vatten och stärkelse bör ligga någonstans i spannet 1:11 - 1:12. Inom detta proportionsspannet behåller börnorna sin position samtidigt som blandningen inte blir för trögflytande. Synligheten hos börnorna som testades i siktröret med hjälp av en LED-slinga var också tillräckligt bra vid proportioner mellan 1:11 och 1:12, bedömde Joakim Nilsson, teknisk expert på FRS [22].

C Bill of material


	Geometri	Design	Tidsuppskattning (skala 1-10)	Hållfastighet (skala 1-10)	Uppskattad kostnad (kronor)	Kommentar
Material som motsvarar mat:						
Plastkylor:	Sfärisk	Färdig	1	7	600 kr/liter	För dyrt
Styrolitkylor:	Sfärisk	Färdig	1	6	30 kr/liter	Dyrt och svårt med dialektriska egenskaperna, bra ur tidsaspekt och hållfastighet
Tvättsvamp (utskuren):	Varierande	Design nödvändig	6	6	10 kr/liter	Billigt, svårt konstruera, tar mycket tid.
Plastskiva (utskuren):	Varierande	Design nödvändig	7	7	144,22kr/liter	Tidskrävande, bra hållfasthet
Frigolit kylor:	Sfärisk	Färdig	1	6	3,69kr/liter	
Plexikylor:	Sfärisk	Färdig	1	9	99kr/liter	
Vita bönor:	Sfärisk & Elliptiska	Färdig	1	3	21 kr/liter	Verklighetsexempel, minimal tidsbörda, billigt
Kidney bönor:	Sfärisk & Elliptiska	Färdig	1	3	25kr/liter	Verklighetsexempel, minimal tidsbörda, billigt, tydlig färg
Stärkelse						
Billigt alternativ	Pulver	Färdig	1		1kr/liter	Billigt men grumligt, tillräckligt bra för att se bönorna
Dyrt alternativ	Pulver	Färdig	1		950kr/liter	Lite gulaktig vid blandning med vatten, näst intill helt transparent
Konserveringsmedel:						
E223	Flytande		1		400 kr/liter	Ett tänkbart alternativ till att blandningen behåller sina egenskaper med tiden
Värmepanna:						
15 liter Bauhouse		Färdig	1		1 695 kr	max temp 75 grader
Värmepanna husvagn		Färdig	7		2000 - 4000 kr	Opraktiskt, dyrt, mycket tidsåtgång
Cirkulationspump:						
Cirkulationspump Jula		Färdig	1		1 299kr	Temp från 2-110 °c. omgivningstemperatur: 0-40 °c. anslutning: 1 1/2", adapter för 1" ingår. bygghöjd: 180 mm
Byggnadskomponenter						
Omkopplare för rör		Färdig	1		20kr	För att koppla ihop tank och rör
Topplöck för tanken		Färdig	2		20kr	Möjlighet att trycksätta, temperaturreglerna innehållet i tanken
Kopparrör 20m		Färdig	2		1 040kr	Golvslina som ska strömmas med vatten, möjliggör temperaturreglering

Figur 33: *Bill of material för projektet.*


D Dielektriska mätningar




Figur 34: ε'_r , ε''_r , samt konduktiviteten σ för kidneybönorna. De olika färgade linjerna korresponderar mot olika mätningar med den dielektriska proben. $\tan(\delta) = \varepsilon''_r/\varepsilon'_r$ är den dielektriska förlusttangenten.



Figur 35: ε'_r , ε''_r , samt konduktiviteten σ för stärkelseblandningen utan salt. $\tan(\delta) = \varepsilon''_r/\varepsilon'_r$ är den dielektriska förlusttangenten.



Figur 36: ε'_r , ε''_r , samt konduktiviteten σ för stärkelseblandningen med 0,75 % salt. $\tan(\delta) = \varepsilon''_r/\varepsilon'_r$ är den dielektriska förlusttangenten.



Figur 37: ε'_r , ε''_r , samt konduktiviteten σ för stärkelseblandningen med 1,5 % salt. $\tan(\delta) = \varepsilon''_r/\varepsilon'_r$ är den dielektriska förlusttangenten.