




CHALMERS
UNIVERSITY OF TECHNOLOGY



Minskat luftmotstånd på bilar genom automatisk formoptimering

Kandidatarbete inom tillämpad mekanik

Robin Ahmad
Davis Bui
Johan Idoffsson
Khalil Kenaan
Mattias Nilsson
Markus Yechouh

KANDIDATARBETE INOM TILLÄMPAD MEKANIK

**Minskat luftmotstånd på bilar genom
automatisk formoptimering**

Robin Ahmad
Davis Bui
Johan Idoffsson
Khalil Kenaan
Mattias Nilsson
Markus Yechouh

Institutionen för Tillämpad Mekanik
Avdelningen för fordonsteknik och autonoma system
CHALMERS TEKNISKA HÖGSKOLA
Göteborg, Sverige 2017

- © Robin Ahmad, 2017.
- © Davis Bui, 2017.
- © Johan Idoffsson, 2017.
- © Khalil Kenaan, 2017.
- © Mattias Nilsson, 2017.
- © Markus Yechouh, 2017.

Handledare: Emil Ljungskog, Institutionen för Tillämpad Mekanik
Examinator: Prof. Simone Sebben, Institutionen för Tillämpad Mekanik

Kandidatarbete 2017:08
Institutionen för Tillämpad Mekanik
Avdelningen för Fordonsteknik och Autonoma System
Chalmers tekniska högskola
SE - 412 96 Göteborg
Telefon +46 31 772 1000

Omslag: Ytkänsligheten med avseende på luftmotståndskraften $[\frac{N}{m}]$ för den förenklade bilmodellen VRAK (Volvo Research car for Aerodynamic Knowledge).

Typsättning i L^AT_EX
Göteborg, Sverige 2017

Sammanfattning

I dagsläget finns potential för att minska bränsleförbrukningen hos personbilar genom att minska luftmotståndet som ett fordon måste överkomma. Traditionellt sett har vindtunnlar använts vid beräkning av luftmotståndskoefficienten (C_D), men i takt med ökad beräkningskapacitet har datorsimuleringar blivit allt vanligare. Formoptimeringsmetoder bygger idag fortfarande till stor del på manuellt arbete. Denna rapport syftar till att undersöka och utvärdera automatiska formoptimeringsmetoder, med hjälp av den förenklade bilmodellen VRAK (Volvo Research car for Aerodynamic Knowledge), för att minska det manuella arbetet. De automatiska formoptimeringsmetoderna som har behandlats i projektet är gradientbaserad optimering med adjointa fält och surrogatmodellering.

Adjointmetoden implementerades och ytkänslighetsdata togs fram genom att lösa adjointekvationerna. Deformationsnoder placerades i de områden som ansågs lämpliga från analys av ytkänsligheten. Fyra deformationsfall testades där tre av dessa resulterade i ett oförändrat C_D . Valet av nodplaceringar påverkade hur geometrin deformerades. Adjointmetoden har visat sig vara en känslig metod med avseende på konvergens.

Surrogatmodellering tillämpades med hänsyn taget till den adjointa ytkänslighetsdatan. Fyra modeller tränades och extrempunkter i vardera modell togs fram för att finna optimala luftmotståndskoefficienter. Global optimering med surrogatmodeller har visat sig vara en robust formoptimeringsmetod som kan ta fram optimala konfigurationer med stora C_D -ändringar samtidigt som små fel i prediktionerna fås. Optimalt erhöles en minskning av luftmotståndskoefficienten med 8,5 %. En möjlig framtida utveckling är att koppla adjointmetoden och surrogatmodellering i en gemensam automatiserad formoptimeringsprocess.

Nyckelord: adjointmetoden, surrogatmodellering, ytkänslighet, VRAK, luftmotståndskoefficienten (C_D).

Abstract

In the present day there is potential to reduce the fuel consumption of cars by reducing the drag which a vehicle must overcome. Traditionally, wind tunnels have been used to measure the drag coefficient (C_D), but the recent development of computational power has made computer simulations increasingly common. Shape optimization methods still mainly contain manual work. This report aims to explore and evaluate different automatic shape optimization methods. This is done by using the simplified car model VRAK (Volvo Research car for Aerodynamic Knowledge) as a tool to conduct experiments on to decrease the manual work. The optimization methods which have been evaluated in this project are gradient-based optimization using adjoint fields and surrogate modelling.

The adjoint method was implemented and the surface sensitivity data was generated by solving the adjoint equations. Control points were placed in the areas which were considered appropriate from the analysis of the surface sensitivity. Four cases of deformation were tested where three of them resulted in an unchanged C_D . The deformation of the geometry was dependent on the placement of the control points. The adjoint method was proven to be a sensitive method due to issues regarding convergence.

Surrogate modelling was applied with respect to the adjoint surface sensitivity data. Four models were trained and optimal geometries were generated to minimize drag. Global optimization with surrogate models was proven to be a robust method which can generate optimal configurations with large changes in C_D while the predicted errors are kept small. The most successful case resulted in an 8,5 % reduction in drag. A possible future area of development is to connect the adjoint method and surrogate modelling into a single automated shape optimization process.

Keywords: adjoint method, surrogate modelling, surface sensitivity, VRAK, drag coefficient (C_D).

Förord

Projektet minskat luftmotstånd på bilar genom automatisk formoptimering löper över vårterminen 2017 på Chalmers tekniska högskola. Samtliga projektmedlemmar är studenter från tredje året på civilingenjörsprogrammet i maskinteknik. Valet att utföra ett kandidatarbete inom fordonsaerodynamik grundar sig på ett intresse för strömningsmekanik och dess tillämpningar.

Vi vill börja med att tacka vår handledare Emil Ljungskog för all den vägledning och de konstruktiva synpunkter vi har fått under projektets gång. Vi vill även tacka vår examinator Professor Simone Sebben för möjligheten att utföra projektet. Slutligen tackar vi Institutionen för Tillämpad mekanik för tillhandahållande av resurser.

Nomenklatur

Förkortningar

ANSA	Programvara för preprocessing
CFD	Computational Fluid Dynamics
DOE	Design Of Experiments
GMRES	Generalized Minimal Residual Method
IDW	Inverse Distance Weighting
PID	Property ID
RANS	Reynolds Tidsmedelvärderade-Navier-Stokes-Ekvationer
RBF	Radial Basis Function
STAR-CCM+	Programvara för CFD-beräkningar
VRAK	Volvo Research Car For Aerodynamic Knowledge

Grekiska symboler

Λ	Adjointa fältet
λ	Viktfunktion RBF
Φ	Basfunktion RBF
ρ	Densitet [$\frac{kg}{m^3}$]
σ	Standardavvikelse
τ_w	Skjuvspänning [$\frac{N}{m^2}$]
ε	Formparameter RBF

Romerska symboler

\bar{C}_D	Medelvärderad luftmotståndskoefficient [-]
ΔC_D	Skillnad i luftmotståndskoefficient [-]
\hat{v}	Interpolerade värdet IDW [-]

\mathbf{A}	Matris innehållande basfunktioner
\mathbf{w}	Flödesvariabler
A	Bilens frontalarea [m^2]
b	Vindtunnelns bredd [m]
c	Medelavståndet mellan samplingspunkter i modell för basfunktioner
C_D	Luftmotståndskoefficient [-]
d	Avstånd till prediktionspunkt i IDW-modellen [m]
F_D	Luftmotståndskraft [N]
h	Vindtunnelns höjd [m]
L	Kostnadsfunktion
l	Vindtunnelns längd [m]
m	Antal designparametrar i modell för framtagning av samplingsstorlek
P_D	Effekt [$\frac{J}{s}$]
p_s	Yttryck [$\frac{N}{m^2}$]
r	Radie [m]
t	Tiden [s]
V	Hastighet [$\frac{m}{s}$]
W	Energi [J]

Innehållsförteckning

Sammanfattning	iv
Abstract	v
Förord	vii
Nomenklatur	ix
Innehållsförteckning	xiii
1 Inledning	1
1.1 Bakgrund	1
1.2 Syfte	2
1.3 Avgränsningar	2
2 Teori	3
2.1 Fordonsaerodynamik	3
2.1.1 Luftmotstånd	3
2.2 Finita volymmetoden	5
2.2.1 Meshtyper	5
2.3 Formoptimeringsmetodik	6
2.3.1 Gradientbaserad optimering med adjointa fält	6
2.3.1.1 Lösning av det adjointa fältet	6
2.3.1.2 Konvergenskriterier	7
2.3.2 Optimering med surrogatmodeller	7
2.3.2.1 Latin Hypercube sampling	7
2.3.3 Interpolationsmetoder	8
2.3.3.1 Artificiella neurala nätverk	8
2.3.3.2 Kriging	9
2.3.3.3 Radiella basfunktioner	10
2.3.3.4 Avståndsviktning	11
2.4 Morphing	11
2.5 Partikelsvärmoptimering	11
3 Metod	13
3.1 Förbearbetning i ANSA	13
3.1.1 Rensning av VRAK	14
3.1.2 Uppdelning av PID:s	14

3.2	Förbearbetning i STAR-CCM+	14
3.2.1	Uppsättning av vindtunneln	15
3.2.2	Meshgenerering	15
3.3	Fysikaliska modeller	16
3.4	Adjointmetoden	17
3.4.1	Genomförande av adjointberäkningar	17
3.4.2	Meshning i STAR-CCM+	18
3.4.3	Koppling till kostnadsfunktionen	18
3.4.4	Lösning av adjointa fält	19
3.4.5	Placering av deformationsnoder	19
3.4.6	Deformation av geometrin	20
3.5	Surrogatmodeller	21
3.5.1	Parametrisering och generering av indatamodeller	21
3.5.1.1	Utdragning av taket	22
3.5.1.2	Krökning av bakre sida	23
3.5.1.3	Den främre stötfångaren	24
3.5.2	Meshning i STAR-CCM+	24
3.5.3	Generering av surrogatmodeller	24
3.5.3.1	Det neurala nätverket	24
3.5.3.2	Övriga interpolationsmetoder	25
3.5.4	Validering av surrogatmodeller	25
3.5.5	Optimering med PSO	25
4	Resultat	27
4.1	Adjoint	27
4.1.1	GMRES-metoderna	27
4.1.2	Resultat av ytkänsligheten	27
4.1.3	Efter deformation	29
4.1.4	Ändring av C_D	30
4.2	Surrogatmodeller	31
4.2.1	Resultat från sampling	31
4.2.2	Konvergens för PSO	31
4.2.3	Korrelationen mellan designparametrarna och luftmotståndskoefficienten	32
4.2.4	Feluppskattning för interpolerade värden	34
4.2.5	Optimal konfiguration	36
4.2.5.1	Visuell jämförelse mellan optimal konfigura- tion för RBF och den ursprungliga geometrin	37

5	Diskussion	41
5.1	Adjoint	41
5.1.1	Lösning av det adjointa fältet	41
5.1.2	Placering av noder	42
5.1.3	Ändring av C_D	42
5.2	Surrogatmodeller	42
5.2.1	Metoden i sin helhet	42
5.2.2	Användning av ytkänslighetsdata	43
5.2.3	Valet av mängden samplingspunkter	43
5.2.4	Optimering med PSO	44
5.2.5	Utvärdering av surrogatmodeller	44
5.2.5.1	Extrapolering av samplingspunkter	45
6	Slutsats	47
6.1	Framtida rekommendationer	47
A	Residualer	I
B	Optimala geometrier	I

1. Inledning

I detta avsnitt introduceras projektet. En bakgrund till problemet inleder följt av syfte och avgränsningar.

1.1 Bakgrund

För att minska utsläppen av växthusgaser antog den Europeiska Unionen år 2009 en lagstiftning för att uppnå sitt mål om 20% minskade utsläpp (jämfört med 1990 års nivåer) till år 2020 [1]. Med ökande miljökrav på utsläpp från personbilar finns ett högt ekonomiskt tryck i bilindustrin för att sänka bränsleförbrukningen hos fordonen. I dagsläget finns fortfarande stor potential för att minska bränsleförbrukningen genom att minska luftmotståndet som en bil måste överkomma [2]. Det är därför av stort intresse att förbättra fordonets aerodynamiska egenskaper.

I takt med ökad beräkningskapacitet har CFD-simuleringar blivit ett viktigt verktyg för att effektivisera, korta ledtiderna och sänka kostnaderna i utvecklingsarbetet. Genom att analysera simuleringsresultat kan geometrier förbättras innan kostsamma och tidskrävande prototyper byggs och testas i vindtunnel. Som resultat av detta blir processen både snabbare och billigare när färre fysiska modeller behöver verifieras [3].

Traditionellt sker designoptimering manuellt genom att förbättringar av geometrin föreslås baserat på resultat från simuleringar och experiment. Detta är en iterativ process vilket ofta lämpar sig bättre för datorer.

Om formoptimeringen skulle kunna automatiseras kan arbetsgången effektiviseras avsevärt. Genom att upprepat låta datorn köra simuleringen och utföra designförändringar baserat på analys av simuleringsresultaten kan en optimerad geometri erhållas. Dessutom kan den automatiska formoptimeringen utvärdera flera designparametrar på kort tid vilket skulle innebära en minskad mängd manuellt arbete i processen. Automatisk formoptimering är idag ett forskningsintensivt område med potential att bidra med lösningar till flera av industrins utmaningar. Exempel på när automatiseringen av formoptimering i industriella sammanhang har skett är vid utveckling av transoniska vingar [4] samt vid utveckling av nya Audi Q5 [5].

1.2 Syfte

Syftet med detta kandidatarbete är att undersöka och utvärdera olika formoptimeringsmetoder. Detta görs med hjälp av en dator för att automatiskt kunna göra förbättringsförslag på den förenklade bilmodellen VRAK (Volvo Research car for Aerodynamic Knowledge). De olika formoptimeringsmetoderna som skall undersökas är

- gradientbaserad formoptimering med adjointa fält
- surrogatmodellering via artificiella neurala nätverk, kriging, radiella basfunktioner (*Radial Basis Function*) och avståndsviktning (*Inverse Distance Weighting*).

Till följd av tidigt lagd litteraturstudie vid projektets start fattades beslutet om att undersöka hur god konvergens kan erhållas för adjointlösaren. Vidare skall beteendet hos adjointverktygen samt nodplacering undersökas för att få en uppfattning om hur deformationen påverkas.

Vid utvärdering av surrogatmodeller skall möjligheterna för integration av ytkänslighetsdata vid konstruktion av deformationslådor undersökas. Vidare skall optimala konfigurationer tas fram med respektive surrogatmodell genom partikelsvrmoptimering. Geometrierna skall tillsammans med felet i uppskattningen för respektive surrogatmodell användas för att göra en jämförande studie och dra slutsatser om metoderna.

1.3 Avgränsningar

Till följd av projektarbetets begränsade tillgångar och metodernas komplexitet görs följande avgränsningar. Slutsatser kommer att dras från jämförelser mellan resultaten och referensberäkningar. Vidare kommer inga fysiska prototyper byggas för att validera simuleringarna i en vindtunnel.

Eftersom projektet syftar till att undersöka och utvärdera formoptimeringsmetoder och dess användbarhet, snarare än att ta fram en optimal bilform, kommer ingen meshstudie att genomföras.

Vid användning av surrogatmodellering används endast en variant av vardera modell. Ingen vikt läggs vid att testa olika inställningar i modellerna mot varandra.

2. Teori

I detta kapitel behandlas den bakomliggande teorin i projektet. Inledningsvis ges en kortfattad introduktion till fordonsaerodynamik och den aerodynamiska luftmotståndskoefficienten C_D . Sedan följer ett projektspecifikt avsnitt om automatisk formoptimeringsmetodik. Detta avsnitt inleds med gradient-baserad formoptimering med hjälp av adjointa fält. Vidare följs avsnittet av de studerade formoptimeringsmetoderna baserade på statistisk försöksplanering med surrogatmodellering. Modellerna som tas upp är artificiella neurala nätverk, kriging, radiella basfunktioner och avståndsviktning.

2.1 Fordonsaerodynamik

När ett fordon färdas genom luft uppkommer motståndskrafter som måste överkommas. Fordonets bränsleförbrukning ökar signifikant med ökande luftmotstånd som är proportionellt mot dess frontalarea och kvadraten på fordonets hastighet [6]. För att kunna minska bränsleförbrukning genom minskat luftmotstånd måste fordonets aerodynamiska egenskaper undersökas.

2.1.1 Luftmotstånd

Motståndskrafter på ett fordon uppkommer till följd av den relativa rörelsen mellan fordonet och det strömmande medium som fordonet färdas i. Luftmotståndskraften F_D på ett fordon härleds genom integration av det totala trycket och skjuvspänningen över hela bilkroppens yta [6] enligt

$$F_D = \int_A dF_D = \int_A (-p_s + \tau_w) \hat{n}_x dA, \quad (2.1)$$

där p_s och τ_w är tryck respektive skjuvspänningar. Indexet x representerar fordonets färdriktning. Vidare kan ur detta en mer allmän form av luftmotståndskraften F_D skrivas

$$F_D = \frac{1}{2} C_D \rho A V^2 \Leftrightarrow C_D = \frac{2F_D}{\rho A V^2} \quad (2.2)$$

Här är V den relativa hastigheten mellan fordonet och luften i fordonets rörelseriktning med densiteten ρ . C_D är den dimensionslösa aerodynamiska luftmotståndskoefficienten som syftas till att minimeras vid optimering av fordonets aerodynamiska prestanda. Tabell 2.1 visar luftmotståndskoefficienten för några olika bilmodeller.


Tabell 2.1: Exempel på olika bilmodellers luftmotståndskoefficienter

C_D	Fordon	Årtal
0,54	Mercedes Benz G-Class	1979 [7]
0,31	Volvo V50	2004 [8]
0,39	Dodge Durango	2004 [9]
0,37	Volkswagen Tiguan	2008 [8]
0,29	Volvo V60	2014 [10]
0,33	Volvo XC90	2016 [11]

Effekten P_D som behövs för att överkomma den aerodynamiska luftmotståndskraften kan härledas från definitionen av effekt

$$P_D = \frac{W}{t} = F_D V = \frac{1}{2} C_D \rho A V^3 \quad (2.3)$$

där W är den energimängd som omvandlas under tiden t . I figur 2.1 visas en jämförelse mellan effekt för att övervinna rullmotstånd respektive luftmotstånd, där rullmotståndet utgörs av friktionsförluster.




Figur 2.1: Effekten för att övervinna rullmotstånd och luftmotstånd som funktion av hastigheten. Parametervärden är valda efter typiska personbilar.

2.2 Finita volymmetoden

Finita volymmetoden är en av de vanligaste numeriska diskretiseringsmetoderna för att lösa partiella differentialekvationer i moderna *CFD* (*Computational fluid dynamics*)-program. Denna numeriska diskretiseringsmetod vilar på Navier-Stokes ekvationer i kombination med antaganden och förenklingar tillsammans med en turbulensmodell. Finita volymmetoden utgår från att lösningsdomänen delas in i ett finit antal icke-överlappade kontrollvolymmer, så kallade element eller celler, som utgör volymsmeshen. Differentialformen av de styrande ekvationerna som beskriver flödet runt fordonet integreras över varje kontrollvolym där den sökta storheten beräknas i centrum av varje element. Genom att interpolera mellan elementens centroider löses i sin tur ekvationerna över hela domänen. Detta är en iterativ process som fortsätter tills konvergens uppnås [12]. Lösningen av strömningsfältet kallas primärlösning då den innehåller information om de primära variablerna, hastighet och tryck. Programvaror som löser strömningsfältet kallas för primärlösare.

2.2.1 Meshtyper

Vid generering av en volymsmesh så kan olika elementtyper användas. Dessa elementtyper är tetra-, hexa-, och polyhedralceller. Elementtyperna definieras av hur många sidor de har. Tetrahedralceller har fyra sidor, hexahedralceller har sex sidor och polyhedralceller har ett godtyckligt antal sidor. Förutom de beskrivna elementtyperna så används även en undergrupp av polyhedralceller som kallas prismor. Prismor används för att lösa upp gränsskikt nära geometrins yta. Figur 2.2 visar de olika elementtyperna.



Figur 2.2: Från vänster till höger: tetrahedral, hexahedral, polyhedral och prisma [13].

2.3 Formoptimeringsmetodik

I detta avsnitt tas den bakomliggande teorin till formoptimeringsmetoderna upp.

2.3.1 Gradientbaserad optimering med adjointa fält

Gradientbaserad optimering med hjälp av adjointa fält är en relativt ny metod i industrin. Optimeringsmetoden introducerades av Lions och Pironneau under 1970-talet [14]. Användningen av adjointmetoden uppmärksammades år 1998 vid en publicering om implementering av metoden på tvådimensionella vingprofiler av Jameson. Gradientbaserade optimeringsmetoder kräver en kontinuerlig målfunktion och konvergerar till en lokal extrempunkt [15]. Till en början var adjointmetoden ett etablerat koncept inom statiken men implementerades senare i strömningsmekaniken.

Adjointmetoden bygger på uppställning och lösning av ett minimeringsproblem utifrån de partiella differentialekvationerna som styr strömningsfältet. Den önskade målfunktionen definieras, förlängs med tillståndsekvationerna och deriveras. På så sätt erhålls adjointekvationerna som huvudsakligen skiljer sig från de ursprungliga differentialekvationerna med en ny term [16]. Eftersom tillståndsekvationerna innehåller termer beroende av geometrin tar metoden hänsyn till gradienter med avseende på objektets designvariabler [14]. För en mer detaljerad härledning av adjointekvationerna hänvisas till Karpouzas et al. [16].

Genom att lösa adjointekvationerna fås målfunktionens ytkänslighetsdata i varje punkt i strömningsfältet från den nya termen. Känslighetsdatan talar om hur målfunktionen ändras med avseende på förändring i geometrin. I formoptimeringsproblem används sedan känsligheten som indata till ett deformationsverktyg som utför förändringar på modellen [16].

2.3.1.1 Lösning av det adjointa fältet

Lösning av det adjointa fältet grundar sig på ett flertal ekvationer. Det mest centrala är ekvationssystemet (2.4), vilket behöver lösas för att erhålla det adjointa fältet Λ [17]:

$$\left[\frac{\partial}{\partial \mathbf{w}} \mathbf{R} \right]^T \cdot \Lambda = \frac{\partial L^T}{\partial \mathbf{w}}, \quad (2.4)$$

där $\left[\frac{\partial}{\partial \mathbf{w}} \mathbf{R}\right]$ är känsligheten av flödesresidualerna med avseende på flödesvariablerna, vilket exakt representerar andra ordningens jacobian av flödesekvationerna. L är kostnadsfunktionen som skall optimeras. $\frac{\partial L}{\partial \mathbf{w}}$ är derivatan av kostnadsfunktionens känslighet med avseende på flödesvariabler, \mathbf{w} . $\Lambda^T \sim \frac{\partial L}{\partial \mathbf{R}}$ är ett uttryck för känsligheten för kostnadsfunktionen med avseende på flödesresidualerna \mathbf{R} .

2.3.1.2 Konvergenskriterier

Vid optimering med adjointa fält är det av stor vikt att simuleringen uppnår god konvergens. Idealt bör residualerna konvergeras till maskinprecision då de adjointafälten grundar sig på deriverade kvantiteter, vilket vidare resulterar i att de numeriska avvikelserna minimeras [18]. Primärlösningen bör först ställas upp med de rätta fysikaliska modellerna, randvillkoren och lösningsparametrarna för det egna fallet. När primärlösningen har konvergerat till en god nivå kan konvergens till maskinprecision uppnås genom att frysa turbulensmodellen. Detta görs för att undvika de instationära effekter som annars kan erhållas med turbulensmodellen.


2.3.2 Optimering med surrogatmodeller

Vid traditionell optimering med *design of experiments*, DOE, utförs en lång rad simuleringar för hitta en optimal kombination av parametrar som uppfyller målfunktionen. Detta kan vara mycket tidskrävande och beräknings tungt om en noggrann lösningsrymd skall erhållas. En metod som kan användas för att reducera ledtiden är att introducera en surrogatmodell. Med surrogatmodellering, även kallat responsystemmodellering, beräknas en approximation av den verkliga responsen av ett system. Metoden är ett statistiskt verktyg som används inom optimeringssammanhang och bygger på empirisk data. Genom att göra ett begränsat antal simuleringar där de valda parametrarna har spridits ut på ett lämpligt sätt i lösningsrymden kan en approximativ representation av hela den verkliga lösningsrymden beräknas.

2.3.2.1 Latin Hypercube sampling

För att skapa en lösningsrymd som representerar verkligheten på bästa sätt behöver den beräknade indatan med tillhörande utdata väljas på ett lämpligt sätt. En statistisk metod som används för att sprida ut indatan maximalt kallas för Latin Hypercube Sampling (LHS). Givet önskat antal noder och parametrar som bestämmer dimensionen på lösningsrymden så kan metoden

användas för att maximera det minimala avståndet mellan varje nod. Om n parametrar används hamnar noderna i ett n -dimensionellt rum. Figur 2.3 illustrerar hur en generering av testpunkter kan se ut i ett tvådimensionellt fall där två parametrar har använts för att ta fram fem punkter. En nod skall förekomma i varje kolonn och på varje rad i det uppdelade rutnätet. MATLABs inbyggda funktion `lhsdesign.m` har använts med viss modifikation för att skapa detta exempel.



Figur 2.3: Latin hypercube sampling med fem mätpunkter i två dimensioner

2.3.3 Interpolationsmetoder


Att interpolera en funktion innebär att man utgående från en diskret mängd kända datapunkter beräknar nya funktionsvärden i okända punkter. Hur processen går till skiljer sig från metod till metod. Nedan följer den teori som täcker projekts studerade interpolationsmetoder.

2.3.3.1 Artificiella neurala nätverk

Artificiella neurala nätverk (ANN) är en metod som introducerades på 1980-talet. Användningen har ökat kraftigt sedan dess och förekommer i en mängd olika branscher och sammanhang då den är mycket mångsidig. Metoden lämpar sig för användning när stora mängder indata är svåra eller tidskrävande att generera och kan innehålla mätbrus. Med en robust modell

kan god och meningsfull data extraheras. Neurala nätverk har visat sig vara bättre än liknande metoder på att fånga icke-linjäriteter i Lösningssrymden enligt Song et al. [19].

Figur 2.4 illustrerar hur ett neuralt nätverk är uppbyggt. Indata presenteras för ett första lager med noder. Varje nod i detta lager är kopplad till en egen parameter. Dessa noder är sedan kopplade till ett dolt lager av andra noder. Dessa noder kan i sin tur vara kopplade till fler lager dolda noder innan de slutligen kopplar till ett yttre lager där utdata kan hämtas. För att nätverket skall få någon mening måste det tränas genom att exponeras för kombinationer av redan känd in- och utdata. På så vis kan nätverket skapa en bild av vad det skall representera och lägga vikter på varje koppling mellan två noder.



Figur 2.4: Schematisk bild av ett neuralt nätverk

2.3.3.2 Kriging

Kriging är en statistisk interpoleringsmetod som först användes i gruvindustrin och geostatistiken. Metoden syftade till att uppskatta fördelningen av guld i marken i Sydafrika med endast ett fåtal borrhål [20]. Sedan dess har kriging implementerats på flera andra områden. Okända funktionsvärden approximeras i en vald punkt genom att beräkna ett viktat medelvärde av tidi-

gare kända funktionsvärden i punktens närhet. Det viktade medelvärdet relaterar kovariansen mellan de kända funktionsvärdena och deras avstånd till punkten. På så sätt interpoleras funktionsvärden med en normalfördelning baserad på kovarianser istället för med exempelvis styckvisa polynom.

2.3.3.3 Radiella basfunktioner

Radiella basfunktioner (RBF) är en metod som introducerades av R.L Hardy år 1968. Metoden grundar sig på basfunktioner som är beroende av det euklidiska avståndet från den punkt där funktionsvärdet skall beräknas till varje given nod. Formeln för RBF ges av

$$s(\mathbf{x}) = \sum_{j=1}^n \lambda_j \Phi(\|\mathbf{x} - \mathbf{x}_j\|), \quad (2.5)$$

där λ_j är en viktfunktion som regleras beroende av den valda radiella basfunktionen $\Phi(r)$ för något $r \geq 0$, $r = \|\mathbf{x} - \mathbf{x}_j\|$. Ekvation (2.5) leder till det symmetriska linjära systemet

$$\mathbf{f} = \mathbf{A}\boldsymbol{\lambda}, \quad (2.6)$$

där \mathbf{A} är en matris och definieras som $a_{j,k} = \Phi(\|\mathbf{x}_k - \mathbf{x}_j\|)$. Basfunktionen $\Phi(r)$ kan ansättas på olika sätt beroende på vilken variant av RBF som man vill ha. Tabell 2.2 presenterar några varianter av $\Phi(r)$

Tabell 2.2: Typer av RBF

Basfunktion	Definition
<i>Slät, global</i>	
Multikvadratisk	$\sqrt{1 + (\varepsilon r)^2}$
Inverterad multikvadratisk	$\frac{1}{\sqrt{1 + (\varepsilon r)^2}}$
Inverterad kvadratisk	$\frac{1}{1 + (\varepsilon r)^2}$
Gaussisk	$e^{(-\varepsilon r)^2}$
<i>Delvis slät, global</i>	
Kubisk	$ r ^3$
"Spline-funktion"	$r^2 \ln r $

där ε är en formparameter som kontrollera funktionens plattthet [21].

RBF används bland annat inom kartografi och vid numeriska lösningar av partiella differentialekvationer. Fördelen med RBF är att metoden inte blir

mer komplicerad när antalet dimensionerna av interpolationen ökar. Nackdelen är att vid lösning av (2.6) med många punkter kan beräkningskostnaden bli stor [22].

2.3.3.4 Avståndsviktning

Grundprincipen för avståndsviktning, eller *Inverse Distance Weighting* (IDW), har sitt ursprung från Toblers lag, även kallad geografins första lag [23]:

”Allting är relaterat till allt annat men näraliggande enheter är mer relaterade till varandra än till dem som ligger längre bort”

Metoden bygger på antagandet att närliggande datapunkter är mer korrelerade än datapunkter längre bort inom dess definitionsområde. Detta är en relativt flexibel interpoleringsmetod då det går att anpassa vissa inställningar efter godtycke. Inställningarna gör det möjligt för användaren att begränsa sina datapunkter för interpolering samt bestämmande av signifikansen för datapunkter i domänen [24]. Den vanligaste formeln för interpoleringsmetoden ges av

$$\hat{v} = \frac{\sum_{i=1}^n \frac{1}{d_i^p} v_i}{\sum_{i=1}^n \frac{1}{d_i^p}}, \quad (2.7)$$

där \hat{v} är det värde som interpolerats fram och v_i de datapunkter som bygger upp databasen. Vidare är d_1, \dots, d_n avstånden från de datapunkterna till den interpolerade datapunkten n .

2.4 Morphing

Begreppet morphing syftar till deformation av en geometri. I programvaror där morphing är tillgängligt utförs deformationer genom att inledningsvis definiera de områden i geometrin som skall tillåtas en formändring. Genom att sedan ansätta punkter varifrån deformationerna skall följa kan en formändring ske. Vid morphing deformeras även meshen vilket kan innebära att meshkvaliteten sänks. Vid för stora deformationer kan därför en ny meshgenerering vara nödvändig för att upprätthålla önskad meshkvalité.

2.5 Partikelsvärmoptimering

Partikelsvärmoptimering (PSO) är ett beräkningsverktyg som används vid optimeringsproblem som grundar sig i en iterativ process [25]. Genom att

introducera en bestämd mängd partiklar i Lösningsrymden kan både en global och lokal sökning göras för att finna exempelvis globala maximum eller minimum. Metoden kräver ej att gradienten av målfunktionen behöver vara känd. Processen bygger på att lösningen till målfunktionen beräknas i varje punkt där en partikel befinner sig. För varje iteration flyttas alla partiklar mot den punkt där målfunktionen har sitt optimala värde. Vissa partiklar tillåts även en viss extra slumpmässig förflyttning. De två stegen, att beräkna optima och flytta partiklar, upprepas tills målfunktionens värde har konvergerat till önskad nivå.


Metoden grundar sig i beteendet som kan ses hos exempelvis fågelflockar som letar efter mat. Varje fågel söker individuellt lokalt medan flocken som helhet söker globalt över ett större område. När en fågel upptäcker en källa till föda dras resten av flocken mot denna individ.

3. Metod


Metodkapitlet inleds med en genomgång av generellt förberedande arbete i förbearbetningsverktyget ANSA och CFD-mjukvaran STAR-CCM+. Sedan redovisas arbetsgången för adjointmetoden och surrogatmodeller i separata delavsnitt. Då bilgeometrin är symmetrisk kring mittenplanet görs alla simuleringar i denna rapport på en halv bil för att spara beräkningskraft.

3.1 Förbearbetning i ANSA


Den givna bilmodellen VRAK bearbetades i förbearbetningsverktyget ANSA innan den användes vid simulering. Modellen före bearbetning visas i figur 3.1.



Figur 3.1: Volvo Research car for Aerodynamic Knowledge (VRAK)



(a) Frontvy



(b) Sidovy


Figur 3.2: Front- och sidovy på VRAK

3.1.1 Rensning av VRAK

Primärlösaren och meshgenereringen i STAR-CCM+ kräver att modellens yta är sluten, det vill säga att den inte har några hål. Dessutom krävs att geometrin är korrekt orienterad och att den inte överlappar sig själv. ANSA användes därför inledningsvis för att rensa VRAK-modellen på geometrifel som kan störa meshgenereringen i STAR-CCM+. Små elementytor slogs ihop med närliggande för att skapa gemensamma ytor. Områden som behövde bearbetas var dels skärmarna runt hjulhusen, som innehöll hål, samt överlappande radieövergångar i samma område.

3.1.2 Uppdelning av PID:s

VRAK delades upp i områden kallade *part IDs* (PID:s) för att få större frihet i hur randvillkoren sedan appliceras i STAR-CCM+ vid användning av adjointmodulen. Figur 3.3 visar hur geometrin med tillhörande PID:s såg ut.



Figur 3.3: Isometrisk- och bakre vy på VRAK med tillhörande PID:s

3.2 Förbearbetning i STAR-CCM+

När modellen förberetts i ANSA genererades en ytmesh som exporterades till programvaran STAR-CCM+. Kvalitén på ytmeshen var inte avgörande för beräkningsresultaten då ett nytt volymnät genererades för ändamålet. Däremot var ytmeshen tvungen att vara av tillräcklig kvalitet för att representera alla detaljer i geometrin.


3.2.1 Uppsättning av vindtunneln

En vindtunnel skapades i STAR-CCM+ och randvillkoren på ytorna valdes enligt tabell 3.1

Tabell 3.1: Randvillkor för vindtunneln

Rand	Randvillkor
VRÅK	<i>Wall</i>
Vindtunnel inlopp	<i>Velocity inlet</i>
Vindtunnel utlopp	<i>Pressure outlet</i>
Vindtunnel tak	<i>Slip-wall</i>
Vindtunnel golv	<i>Moving wall</i>
Vindtunnel vägg	<i>Slip-wall</i>
Symmetrirand	<i>Symmetry</i>

Längden (l), bredden (b) och höjden (h) valdes enligt figur 3.4.




Figur 3.4: Vindtunneln använd vid simuleringar i STAR-CCM+.

3.2.2 Meshgenerering

Med domänen definierad kunde volymmeshen genereras. Olika hög upplösning behövs vid olika områden i volymdomänen. Därför är det önskvärt att dela upp volymen så att elementstorleken i volymmeshen kan varieras i olika regioner. På så sätt sparas även beräkningstid då den finaste elementstorleken inte används i hela domänen. Detta gjordes genom att definiera områden i vindtunneln med hjälp av lådor där cellstorleken kunde avvika från meshens basstorlek. Lådorna som användes visas i figur 3.5. Grundstorleken på

elementen i vindtunneln valdes till 0,4 m och minskades i förfiningslådorna. I den mindre lådan kring vaken användes 0,015 m som grundstorlek och i den större lådan som täckte hela bilen samt vaken användes 0,03 m. Förfining definieras även på olika delar av modellens ytor. Över motorhuven, vindrutan, hjulhusen, däckens, längs undersidan och längs den bakre delen av bilen där högre upplösning krävs användes en finare mesh än på bilens sida och tak.



Figur 3.5: Förfiningslådor använda vid meshning i STAR-CCM+.

3.3 Fysikaliska modeller

Olika fysikaliska modeller infördes för att kunna undersöka och utvärdera de automatiska formoptimeringsmetoderna, se tabell 3.2. Vid simulering av fordonet användes friströmshastigheten 140 km/h (38,89 m/s). Vid denna hastighet kan densiteten antas vara konstant och flödet inkompressibelt. Vidare användes *Coupled Flow* för att lösa tryck-, och hastighetsfälten samtidigt istället för att först lösa hastighetsfältet och använda resultatet för att beräkna tryckfältet. Slutligen användes *Reynolds-averaged Navier-Stokes (RANS)* som kräver en turbulensmodell för att sluta ekvationssystemet [6]. Här valdes *realizable $k - \varepsilon$ Turbulence modell* som inom CFD är en av de mest frekvent använda turbulensmodellerna då den är robust mindre beräkningstung.

Tabell 3.2: Införda fysikaliska modeller

Fysikaliska modeller
Incompressible flow
Coupled Flow
K- ε Turbulence
Reynolds-Averaged Navier-Stokes
Steady flow
Turbulent

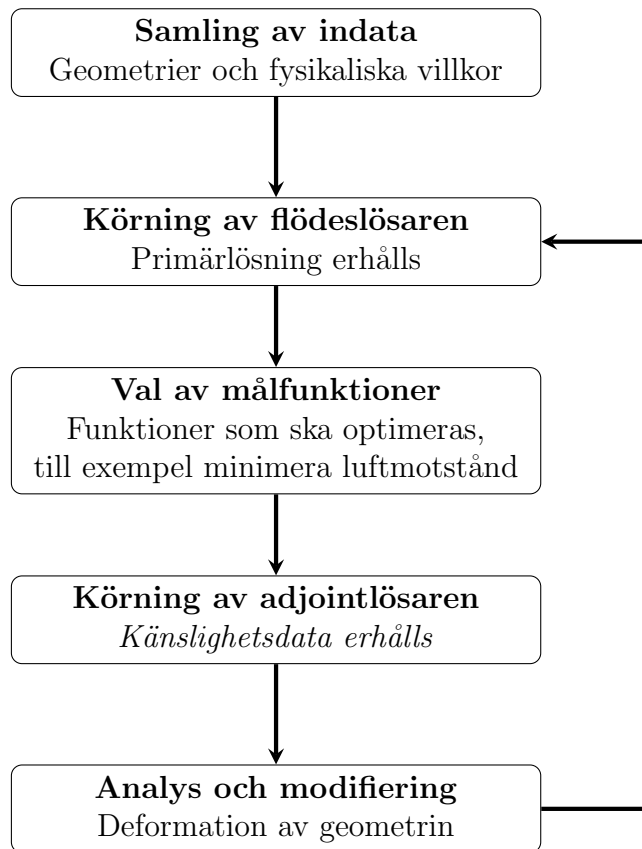
3.4 Adjointmetoden

I följande avsnitt beskrivs arbetsgången vid användning av adjointmetoden.

3.4.1 Genomförande av adjointberäkningar

I konventionella flödesberäkningar med adjointlösare grundas lösningsgången i en iterativ process. I denna studie genomfördes enbart en iteration.

Inledningsvis samlades och importerades indata om flödessystemet såsom randvillkor samt geometrin för att en simulering skulle kunna köras. Vid implementering av adjointmetoden i STAR-CCM+ kördes inledningsvis en simulering av primärlösningen i flödeslösaren för att erhålla flödesfältet. Därefter löstes adjointekvationerna för att erhålla ytkänslighetsdata. Deformationsnoder placerades i de områden som ansågs lämpliga från analys av ytkänsligheten. Efter deformationen kördes primärlösningen igen för att slutligen erhålla ett nytt C_D -värde. Se figur 3.6 för en schematisk bild av adjointmetoden.



Figur 3.6: Flödesschema över adjointmetoden

3.4.2 Meshning i STAR-CCM+

Vid användning av adjointlösaren rekommenderar Orr [26] att ett polyhedralnät används för att uppnå konvergens. Här användes ett polyhedralnät med 15,6 miljoner celler.

3.4.3 Koppling till kostnadsfunktionen

När primärlösningen konvergerat skapades en luftmotståndskraftsrapport som länkades till kostnadsfunktionen för att erhålla ett optimeringsproblem samt adjointekvationerna. Kostnadsfunktionen representerade det huvudsakliga målet med simuleringen, att minimera luftmotståndskraften. Adjointekvationerna löstes sedan med hjälp av adjointlösaren.

3.4.4 Lösning av adjointa fält

Att få adjointlösaren att konvergera är svårt då komplexiteten för att lösa adjointekvationerna ökar med cellantalet [27]. Med en påslagen turbulensmodell fås kontinuerliga störningar i residualerna. Turbulensmodellen frystes för att kunna konvergera primärlösningen till maskinprecision. För att lösa det adjointa fältet användes *Generalized minimal residual method (GMRES) Flexible* och *Generalized minimal residual method (GMRES) Restarted*. Dessa två metoder finns som valbara inställningar i adjointlösaren. De centrala inställningarna för dessa två metoder är dimensioner av krylovrum och antalet defektkorrigeringsiterationer. Ökning av dimensioner av krylovrum förbättrar GMRES-metodernas konvergens och robusthet. Defektkorrigeringsiterationer syftar till att jämna ut felet för varje iteration [17]. Nedan presenteras de olika fall som testades:

- 15 dimensioner av krylovrum och en defektkorrigeringsiteration
- 50 dimensioner av krylovrum och tre defektkorrigeringsiterationer
- 100 dimensioner av krylovrum och tio defektkorrigeringsiterationer

För GMRES-flexible testades även 100 dimensioner av krylovrum och tre defektkorrigeringsiterationer.


3.4.5 Placering av deformationsnoder

Ytkänsligheten beräknades på geometrin för att avgöra vilka områden som skulle deformeras. Deformationsnoder placerades sedan på dessa områden för att koppla känslighetsdatan till förändring av geometrin. Noderna placerades vid VRAK-modellens bakre del på grund av resultatet som erhöles från ytkänsligheten, se figur 3.7 för nodplaceringar.


Tester gjordes med olika antal noder placerade direkt på ytan samt en bit från geometrin. För att se hur antalet noder och deras avstånd från geometrin påverkar deformationen testades fyra olika fall med skalfaktorn 1e-04. Skalfaktorn bestämmer storleken på deformationen. Antalet noder är räknat för en halv bil, kluven i symmetriplanet.

- (a) 38 noder med 0,2 meters avstånd, placerade på geometrin. Se figur 3.7a
- (b) 295 noder med 0,06 meters avstånd, placerade på geometrin. Se figur 3.7b


- (c) 40 noder med 0,2 meters avstånd, placerade 0,03 meter från geometrin. Se figur 3.7c
- (d) 311 noder med 0,06 meters avstånd, placerade 0,03 meter från geometrin. Se figur 3.7d




(a) 38 noder med 0,2 meters avstånd, placerade på geometrin.



(b) 295 noder med 0,06 meters avstånd, placerade på geometrin.



(c) 40 noder med 0,2 meters avstånd, placerade 0,03 meter från geometrin.



(d) 311 noder med 0,06 meters avstånd, placerade 0,03 meter från geometrin.

Figur 3.7: Olika nodplaceringar som testades för deformation

3.4.6 Deformation av geometrin


Efter placering av noder på geometrin beräknades nätkänsligheten för att erhålla en vektor vid varje nod. Dessa vektorer visar i vilken riktning geometrin kommer att deformeras. Därefter testades fyra olika fall av deformation med skalfaktorer $1e-04$, $1e-06$, $1e-08$ och $1e-10$ för modellen med 40 noder placerade 0,03 m från geometrin. Slutligen kördes primärlösningen och ett nytt värde på C_D erhöles.

3.5 Surrogatmodeller

Följande avsnitt går igenom den använda metoden vid surrogatmodellering.

3.5.1 Parametrisering och generering av indatamodeller

Tre separata områden valdes att studeras och deformerades baserat på resultaten från ytkänslighetsdata för adjointberäkningarna. Dessa områden var den bakre delen av taket, den bakre delen av sidan samt den främre stötfångaren. ANSA användes för att deformera bilgeometrin. Modulen *morphing* utnyttjades för att placera lådor runt bilen för att definiera de områden där deformation var tillåtet, se figur 3.8.



Figur 3.8: Morphingboxar placerade på de tre områden där deformation tilläts. Boxarna i den bakre delen av bilen sammanfaller.

De tre områdena parametriserades genom att tillåta en- och tvådimensionella förskjutningar av utvalda noder i varje deformationslåda. Tabell 3.5.1 visar

hur stora deformationer som tilläts för varje parameter.

Tabell 3.3: Dimensionsgränser för designparametrarna

Designparameter	Maximalt deformerad [mm]
Takförlängning	200
Främre stötfångare	85
Krökning av bakre sida	130


Song et al. [19] föreslår att

$$N = 2^m \quad (3.1)$$

datapunkter skall användas där m är antalet dimensioner i Lösningsrymden. Med tre parametrar fås då tre dimensioner varpå LHS användes för att generera åtta stycken konfigurationer inom designparametrarnas givna intervall. De maximala deformationerna valdes något större än vad som är praktiskt användbart med hypotesen att modellernas approximation är dålig nära Lösningsrymdens kanter.

3.5.1.1 Utdragning av taket


Den bakre delen av taket drogs ut bakåt genom att placera en låda i detta område. Genom att sätta in de maximalt tillåtna deformationerna fick modellen en mer kantig profil. I figur 3.9 ses konturen av den maximalt deformerade modellen. Den blåa konturen går genom modellens symmetriplan.



Figur 3.9: I figuren ses den odeformerade modellen i grönt tillsammans med konturen av den maximalt tillåtna deformationen i blått.


3.5.1.2 Krökning av bakre sida

En låda placerades runt den bakre sidan av modellen för att få ett skarpare hörn. Förskjutning tilläts endast i modellens längsled. Figur 3.10 visar konturen av den deformerade modellen. Den blåa konturen visar ett snitt i horisontalplanet på 0,85 meters höjd från marken.




Figur 3.10: I figuren ses den odeformerade modellen i grönt tillsammans med konturen av den maximalt tillåtna deformationen i blått.

Figur 3.11 visar en isometrisk vy av den bakre sidan. Även här visas den odeformerade modellen i grönt och den deformerade i blått.



(a) Odeformerad




(b) Maximal deformation

Figur 3.11: Figuren visar en jämförelse mellan en odeformerad bakre sida i grönt och en maximalt deformerad bakre sida i blått.

3.5.1.3 Den främre stötfångaren

Den främre stötfångaren tilläts förskjutas utåt och nedåt i ett linjärt förhållande på 10:3 för att bättre täcka det främre hjulet. Figur 3.12 visar konturen av den deformerade modellen. Den blåa konturen visar ett snitt i frontalplanet, med normal i fordonets färdriktning, 0,4 meter från den främre hjulaxeln.



Figur 3.12: I figuren ses den odeformerade modellen i grönt tillsammans med konturen av den maximalt tillåtna deformationen i blått.

3.5.2 Meshning i STAR-CCM+

Till skillnad från vid användning av adjointmodulen i STAR-CCM+ användes istället hexahedralceller i detta fall. Grundstorleken på elementen i vindtunneln valdes i enighet med tidigare generering. Dimensionen på vindtunneln och förfiningslådorna valdes lika som i det tidigare fallet. Alla konfigurationer av deformationer meshades med samma inställningar.

3.5.3 Generering av surrogatmodeller

Surrogatmodeller skapades med avseende att minimera C_D . Åtta simuleringar genomfördes på designerna givna av LHS för att skapa lösningsrymden. Lösningsrymden användes senare till att generera och träna de fyra surrogatmodellerna.

3.5.3.1 Det neurala nätverket

För att konstruera det neurala nätverket användes applikationen *Neural Net Fitting* i MATLAB:s toolbox *Neural Network Toolbox 10.0*.

Utformning av nätverket Nätverket utformades efter resultat från Song et al. [19] där man kom fram till att det lämpar sig att använda 1.5-2 gånger fler gömda noder än designparametrar. Sex dolda noder valdes att användas i utformningen av nätverket.

Träning Träningen av nätverket skedde i MATLAB där följande utformning av data användes för att träna nätverket. Sex samplingpunkter användes till träning, en punkt till testning och en till validering. Levenberg-Marquardts bakpropageringsmetod användes som träningsmetod.

3.5.3.2 Övriga interpolationsmetoder

För kriginginterpolationen användes Pythonbiblioteket PyKriging [28] för att skapa och träna modellen. För RBF [29] och IDW [30] användes funktionsfiler importerade till MATLAB från MathWorks hemsida. Exponenten p i modellen för IDW valdes till 2. Basfunktionerna $\Phi(r)$ till RBF valdes som gaussiska funktioner enligt

$$\Phi(r) = e^{-\frac{r^2}{2c^2}}, \quad (3.2)$$

där $c = 59$ ansattes som det medelvärderade avståndet mellan de åtta simuleringarna i lösningsrymden.

3.5.4 Validering av surrogatmodeller

Fyra valideringssimuleringar genomfördes med nya parameterkombinationer för att testa hur bra surrogatmodellerna predikterade okända luftmotståndskoefficienter. Parameterkombinationerna valdes för hand med syfte att täcka de områden av lösningsrymden som saknade tidigare genererade punkter via LHS. Valideringspunkterna användes sedan för att kontrollera lösningsrymden genom att beräkna skillnaden mellan det faktiska simulerade värdet och responsvärdet för motsvarande parameterkombination.

3.5.5 Optimering med PSO

En kod för partikelsvärmoptimering implementerades i MATLAB för att finna globala minimum i surrogatmodellerna. 50 respektive 200 partiklar användes vilka tilläts förflyttas till dess att det relativa felet vid en ny generation var mindre än $1e-5$. Koden för PSO användes senare som ett verktyg för att undersöka om surrogatmodellerna konvergerade. Två olika storlekar

på populationen av partiklar användes för att underöka om den mindre populationen av de två fann den globala minimipunkten.

Med hjälp av PSO-algoritmen togs optimala konfigurationer av designparametrar fram för respektive metod. Två lösningar gjordes för respektive metod. En som täckte hela Lösningsrymden och en där 20 % kapades bort från den övre och under gränsen för vardera parameter. Denna åtgärd togs för att undersöka om minimipunkter fanns i den inre delen av Lösningsrymden, dolda av stort avvikande predikterade värden i den yttre delen av Lösningasrymden.

4. Resultat

Följande kapitel presenterar alla framtagna resultat från beräkningar på referenslösningen, adjoint och surrogatmodeller. Kapitlet inleds med framtagna resultat från adjointmetoden följt av det resultat som erhöles från surrogatmodelleringen.

4.1 Adjoint

I följande stycke presenteras resultaten från adjointmetoden. Först presenteras hur konvergens för adjointlösaren kunde uppnås genom GMRES-inställningarna. Därefter presenteras resultatet för ytkänsligheten och slutligen visas hur placering av noder påverkade deformationen samt C_D .

4.1.1 GMRES-metoderna

Med inställningen *15 dimensioner av krylovrum och en defektkorrigeringsiteration* kunde inte GMRES-flexible eller GMRES-restarted lösa det adjointa fältet.


För GMRES-restarted, med *50 dimensioner av krylovrum och tre defektkorrigeringsiterationer*, började residualerna minska men lyckades inte uppnå någon konvergens och slutade med ett fluktuerande beteende. Med samma inställningar för GMRES-flexible kunde inte heller någon konvergens erhållas.

Med *100 dimensioner av krylovrum och tio defektkorrigeringsiterationer* erhöles konvergens för båda GMRES-metoderna. Det krävdes ungefär 800 coretimmar och fyra iterationer samt 2000 coretimmar och tolv iterationer för att erhålla konvergens för GMRES-flexible respektive GMRES-restarted. För GMRES-flexible med *100 inre iterationer och tre defektkorrigeringsiterationer* krävdes ungefär 800 coretimmar respektive sex iterationer för konvergens. Se bilaga A för residualplottar.


4.1.2 Resultat av ytkänsligheten

Med hjälp av ytkänslighetsfunktionen i STAR-CCM+ kan kritiska områden på VRAK-modellen identifieras. För att uppnå ett minskat luftmotstånd ska röda områden förskjutas utåt medan blå områden förskjutas inåt längs ytans


normal. De kritiska områdena låg framför allt runt den bakre delen av taket och runt den bakre delen av sidorna vilket kan ses i figur 4.1. Detta var en bidragande faktor till att deformationsnoderna placerades i dessa områden. För att enklare kunna identifiera de kritiska områdena jämnades färgen ut med en *Sensitivity smoothing factor* på 0,5.




(a) Ytkänsligheten med avseende på luftmotståndskraften $[\frac{N}{m}]$



(b) Frontvy på ytkänsligheten



(c) Bakre vy på ytkänsligheten



(d) Sidovy på ytkänsligheten


Figur 4.1: Figurerna visar ytkänsligheten för iso-, front-, bakre-, och sidovyn.

4.1.3 Efter deformation


Av fall (a) och (b), då noder placeras på geometrin, resulterar 38 noder i en slätare deformation medan 295 noder gav en bucklig deformation vilket kan ses i figur 4.2a respektive 4.2b. På liknande sätt kan i fall (c) och (d), då noder placeras 0,03 m från geometrin, noteras att fler noder resulterar i en buckligare deformation vilket kan ses i figur 4.2c respektive 4.2d.




(a) Efter deformation med 38 noder placerade på geometrin med 0,2 m mellan noderna.



(b) Efter deformation med 295 noder placerade på geometrin med 0,06 m mellan noderna.



(c) Efter deformation med 40 noder placerade 0,03 m från geometrin och 0,2 m mellan noderna.



(d) Efter deformation med 311 noder placerade 0,03 m från geometrin med 0,06 m mellan noderna.

Figur 4.2: Resultat efter deformation med fyra fall av nodplaceringar

I figur 4.3 visas den odeformerade modellen med den deformerade modellens kontur i orange för fallet med 40 noder placerade 0,03 m från geometrin och 0,2 m mellan noderna.



Figur 4.3: Toppvy av den odeformerade modellen och den deformerade modellens kontur i ett horisontellt snitt 1,28 m över marken.

4.1.4 Ändring av C_D

Innan en deformation av VRAK utfördes hade referensmodellen ett C_D -värde på 0,288. De olika skalfaktorer som testades resulterade i ändringar av C_D som kan ses i tabell 4.1.

Tabell 4.1: Tabellen visar C_D -värden efter fyra olika skalfaktorer av deformation

Skalfaktor	C_D	ΔC_D
1e-04	0,289	0,001
1e-06	0,288	0
1e-08	0,288	0
1e-10	0,288	0

Från tabellen kan man utläsa att tre av deformationsfallen gav en oförändrad luftmotståndskoefficient.

4.2 Surrogatmodeller

I följande stycke presenteras resultaten av optimering med surrogatmodeller. Först visas framräknade luftmotståndskoefficienter för de åtta samplingpunkterna. Sedan görs en genomgång av korrelationen mellan designparametrarna. Slutligen visas det uppskattade felet i modellernas approximationer samt de optimala konfigurationernas prestanda.

4.2.1 Resultat från sampling

Efter att ha kört de åtta samplingssimuleringarna erhöles följande resultat. Tabell 4.2 visar de åtta parameterkonfigurationerna med tillhörande C_D . Beräknade värden, \bar{C}_D , är medelvärderade över de sista 1500 iterationerna efter konvergens erhållits. Vid den tredje körningen uppvisade modellen en svängande vak med en amplitud hos C_D på 0,005. Den odeformerade modellen gav ett C_D på 0,294. Tre decimaler har använts genomgående genom hela resultatavsnittet. Standardavvikelser, σ , under 0,0005 avrundas därmed till 0.

Tabell 4.2: Tabellen visar framräknade luftmotståndskoefficienter efter simulering av åtta parameterkonfigurationer


Konfiguration	Tak [mm]	Bakre sida [mm]	Stötfångare [mm]	\bar{C}_D	σ
1.	130,8	7,1	38,6	0,307	0
2.	185,3	45	73,1	0,306	0
3.	113,4	61	3,6	0,286	0,001
4.	97	102,9	44,2	0,281	0
5.	5,9	84,5	25	0,273	0
6.	66,6	76,5	79,9	0,290	0
7.	172	125,9	18,7	0,284	0
8.	31,4	16,8	57,6	0,285	0

4.2.2 Konvergens för PSO

Genom att upprepa träningen av respektive surrogatmodell flertalet gånger erhöles alltid samma optimala parameterkombination. Detta gäller även för olika storlek på populationen av partiklar vid optimeringen. Detta visar både att surrogatmodellerna konvergerar samtidigt som globala minimum hittas vid sökning.


4.2.3 Korrelationen mellan designparametrarna och luftmotståndskoefficienten

I figur 4.4 kan korrelationskoefficienterna ses mellan designparametrarna och luftmotståndskoefficienten. Enligt resultatet ger en positiv utdragning av taket och den främre stötfångaren en ökning av luftmotståndskoefficienten medan en utdragning av den bakre sidan en minskning. En utdragning av taket ger dock en större inverkan än hos stötfångaren. Koefficienten ger en helhetsbild av hur korrelationen ser ut men den kan ändå dölja positiva respektive negativa lokala bidrag. Modellen för koefficienterna antar linjära förhållanden mellan parametrarna och luftmotståndskoefficienten.




Figur 4.4: Korrelationskoefficienter mellan designparametrar och C_D


För att få en mer heltäckande bild av hur designparametrarna påverkar C_D användes konturplottar där två designparametrar ställs mot varandra i taget. Detta reducerar problemet från ett tredimensionellt problem till tre tvådimensionella problem som är enklare att visualisera. Från figur 4.5, 4.6 och 4.7 kan man utläsa att det finns ett minimum för luftmotståndskoefficienten hos den främre stötfångaren vid en utdragning på 20-30 mm. Denna minimipunkt kan ej utläsas ur figur 4.4. Konturplottarna bygger på interpolerade kubiska polynom. Inga djupare slutsatser skall dras ur dessa konturplottar. De används endast som ett verktyg för att få en ungefärlig uppfattning om hur beteendet ser ut.



Figur 4.5: Konturplot som visar korrelationen mellan deformation av tak och bakre sida.



Figur 4.6: Konturplot som visar korrelationen mellan deformation av tak och främre stötfångare.



Figur 4.7: Konturplot som visar korrelationen mellan deformation av bakre sida och främre stötfångare.

4.2.4 Feluppskattning för interpolerade värden

I tabell 4.3 presenteras de av simuleringarna framräknade luftmotståndskoefficienterna för de fyra verifieringsgeometrierna. I tabell 4.4 - 4.7 visas sedan felet i predikteringen hos respektive surrogatmodell.

Tabell 4.3: Tabellen visar framräknade luftmotståndskoefficienter efter simulering av fyra verifieringskonfigurationer

Verifieringspunkt	Tak [mm]	Bakre sida [mm]	Stötfångare [mm]	C_D	σ
1.	100	40	60	0,294	0
2.	50	120	20	0,271	0,003
3.	160	100	60	0,288	0
4.	50	40	20	0,283	0,004

Tabell 4.4: Predikterade luftmotståndskoefficienter och storleken på felet jämfört med referensvärden, 0,294, för det neurala nätverket. Medelvärde längst ner är det medelvärderade felet i tabellens högra kolonn.

Verifieringspunkt	C_D	ΔC_D
1.	0,294	0
2.	0,270	0,001
3.	0,296	0,008
4.	0,278	0,005
medelvärde:		0,004

Tabell 4.5: Predikterade luftmotståndskoefficienter och storleken på felet jämfört med referensvärden, 0,294, för kriginginterpolation. Medelvärde längst ner är det medelvärderade felet i tabellens högra kolonn.

Verifieringspunkt	C_D	ΔC_D
1.	0,298	0,004
2.	0,272	0,001
3.	0,292	0,004
4.	0,280	0,003
medelvärde:		0,003

Tabell 4.6: Predikterade luftmotståndskoefficienter och storleken på felet jämfört med referensvärden, 0,294, för RBF-interpolation. Medelvärde längst ner är det medelvärderade felet i tabellens högra kolonn.

Verifieringspunkt	C_D	ΔC_D
1.	0,297	0,003
2.	0,271	0
3.	0,291	0,003
4.	0,282	0,001
medelvärde:		0,002

Tabell 4.7: Predikterade luftmotståndskoefficienter och storleken på felet jämfört med referensvärden, 0,294, för IDW-interpolation. Medelvärde längst ner är det medelvärdet för felet i tabellens högra kolonn.

Verifieringspunkt	C_D	ΔC_D
1.	0,292	0,002
2.	0,283	0,012
3.	0,290	0,002
4.	0,286	0,003
medelvärde:		0,005

4.2.5 Optimal konfiguration

Tabell 4.8 visar ansedd optimal konfiguration av designparametrar för respektive surrogatmodell. Alla surrogatmodeller visar på lägre C_D hos den optimala konfigurationer än vid beräknade samplingspunkter förutom IDW. Denna modell ger ett lägsta C_D som befinner i sig väldigt nära den femte samplingspunkten.

Tabell 4.8: Optimala konfigurationer för vardera surrogatmodell framtagna med PSO med predikterat C_D

Surrogatmodell	Tak [mm]	Bakre sida [mm]	Framskärm [mm]	C_D
NN	59,90	130 (max)	0 (min)	0,266
Kriging	46,60	118,64	0 (min)	0,270
RBF	0 (min)	130 (max)	0 (min)	0,262
IDW	5,94	84,48	24,98	0,273


Genom att klippa bort 20% av max- och minvärden från modellerna fås liknande resultat för respektive modell. De parametervärden som antingen ligger på max eller min gör även det efter trimningen av lösningsrymden. Från de sista simuleringarna erhöles resultatet som presenteras i tabell 4.9. ΔC_D är minskningen av luftmotståndskoefficienten hos simuleringarna jämfört med referenslösningen. Endast de tre första surrogatmodellerna lät köras om då data redan fanns till den fjärde modellen, IDW. De stora standardavvikelseerna för det neurala nätverket, kriging och RBF beror på en svängande vak. Felet har beräknats mellan det predikterade värdet för respektive modell och medelvärdet från simulering.

Tabell 4.9: Simulerat C_D för optimala konfigurationer för vardera surrogatmodell samt skillnaden, ΔC_D , från referensvärdet på 0,294

Surrogatmodell	Fel i uppskattningen	C_D	σ	ΔC_D
NN	(-) 0,005	0,271	0,004	0,023
Kriging	0	0,270	0,002	0,024
RBF	(-) 0,007	0,269	0,002	0,025
IDW	0	0,273	0	0,021

4.2.5.1 Visuell jämförelse mellan optimal konfiguration för RBF och den ursprungliga geometrin


Det lägsta värdet på C_D erhöles med RBF-metoden. I figur 4.8 - 4.10 visas en jämförelse mellan den odeformerade modellen i grönt och optimerade modellen i blått. För övriga metoders optimala geometrier se bilaga B. Notera att taket och den främre stötfångaren är odeformerade i den optimala geometrin vilket även kan ses i tabell 4.8.



Figur 4.8: Frontvy av den odeformerade modellen och den deformerade modellens kontur i ett vertikalt snitt 0,4 m från bilens framkant. Den främre stötfångaren deformerades ej.




Figur 4.9: Toppvy av den odeformerade modellen och den deformerade modellens kontur i ett horisontellt snitt 0,85 m över marken. Den bakre sidan deformerades maximalt.



Figur 4.10: Sidovy av den odeformerade modellen och den deformerade modellens kontur i ett vertikalt snitt genom bilens centerlinje. Taket deformerades ej.

Figur 4.11 visar den integrerade luftmotståndskoefficienten för de optimala konfigurationerna för de fyra interpolationsmetoderna. Från figuren kan man utläsa att IDW ger ett högre C_D på den främre delen av bilkroppen men då den bakre delen av bilkroppen är deformerad blir den totala integrationen lägre än referensen. Att funktionsvärdet minskar vid det främre hjulhuset

och förardörren visar att detta är områden med negativa bidrag till luftmotståndskoefficienten.



Figur 4.11: Grafen visar den integrerade luftmotståndskoefficienten över bilens längd för de optimala konfigurationerna hos de fyra interpolationsmetoderna och en odeformerad referens.

5. Diskussion

I det här kapitlet diskuteras resultaten av adjointmetoden och surrogatmodellerna.

5.1 Adjoint

Följande avsnitt omfattar den diskussion som följer av adjointmetoden.

5.1.1 Lösning av det adjointa fältet

Av de sju testade fallen med olika antal dimensioner av krylovrum och defektkorrigeringsiterationer uppnåddes konvergens med *100 dimensioner av krylovrum och tio defektkorrigeringsiterationer* för både GMRES-flexible och GMRES-restarted samt med *100 dimensioner av krylovrum och tre defektkorrigeringsiterationer* för GMRES-flexible. Av de två fallen med GMRES-flexible som lyckas konvergera skilde sig endast antal defektkorrigeringsiterationer, där fallet med *tio defektkorrigeringsiterationer* erhöll konvergens två iterationer före fallet med *tre defektkorrigeringsiterationer*. Ökat antal defektkorrigeringsiterationer bidrar därmed till en snabbare konvergens.

Det kan även noteras att fler dimensioner av krylovrum resulterar i konvergens till maskinprecision för GMRES-flexible med *100 dimensioner av krylovrum och tre defektkorrigeringsiterationer* medan användning av GMRES-flexible med *50 dimensioner av krylovrum och tre defektkorrigeringsiterationer* inte resulterar i någon konvergens. Fler dimensioner av krylovrum ger alltså en stabilare och robustare konvergens. Hur beroendet ser ut mellan de två parametrarna är i detta stadiet oklart. Inga direkta riktlinjer finns för hur man bör gå tillväga, utan processen baseras på en iterativ process för att hitta lämpliga inställningar.

Vid implementeringen av adjointmetoden uppstod svårigheter vid lösning av det adjointa fältet. Kvalitetskrav ställs på primärlösningen, eftersom den har en stor inverkan på tillförlitligheten för adjointlösningen. Antagandet om fryst turbulens medför att inga adjointturbulensekvationer behöver lösas vilket förenklar adjointberäkningarna. Detta bidrar till en stabil grund för adjointlösningen. Konvergenssvårigheter är i dagsläget vanliga vid användning av adjointmetoden då stora bilföretag som Audi stöter på samma svårigheter vid lösning av det adjointa fältet [27].

5.1.2 Placering av noder

Skillnader i deformationen observerades vara beroende på hur deformation-noderna placerades. Noder som var placerade glest utanför geometrin gav en jämnare deformation medan noder som låg tätare och direkt på geometrin gav en mer ojämn yta. Oavsett placering av noder lyckades dock inga minskningar av C_D erhållas med hjälp av deformationsverktyget i STAR-CCM+. Om detta beror på att bilgeometrin var dåligt anpassad för verktyget eller om verktyget i sig är instabilt är okänt.

Ytkänsligheten visar att vissa områden på bilgeometrin bör deformeras väldigt lokalt, speciellt runt den bakre delen av sidan samt taket. Orsaken till detta är okänd men dessa områden behöver beaktas. Med för få noder kan dessa områden missas och med för många noder blir deformationen för ojämn. En avvägning behöver göras mellan att få en mjukare deformation med risken att kritiska områden negligeras och en mer detaljerad deformation med risken att deformationerna blir ojämna.

5.1.3 Ändring av C_D

De tre deformationerna med skalfaktorerna 1e-06, 1e-08 samt 1e-10 gav oförändrade luftmotståndskoefficienter. Detta tyder på att deformationerna som genomfördes för vardera fall var för små för att ha någon betydlig påverkan. Den största deformationen med en skalfaktor på 1e-04 gav dock ett ökat C_D . Detta skulle kunna bero på att den lokala minimipunkten, som adjointmetoden försöker finna, passerar. Om så är fallet bör minimipunkten ligga mellan skalfaktorerna 1e-04 och 1e-06. Dock är ökningen av C_D så liten att den i sammanhanget blir obetydlig. En ökning med 0,001 skulle lika gärna kunna bero på numeriska fel eller brus i simuleringarna.

5.2 Surrogatmodeller

Följande avsnitt omfattar den diskussion som följer av de använda surrogatmodellerna.

5.2.1 Metoden i sin helhet

Genom att ha testat och undersökt de fyra surrogatmodellerna har luftmotståndskoefficienten lyckats reduceras. Den maximala sänkningen av C_D

erhölls med RBF-metoden och uppgick till 0,025, vilket motsvarar en sänkning på 8,5 % jämfört med referenslösningen. Huruvida de av interpolationsmetoderna rekommenderade deformationerna är något som skulle vara intressant för en konstruktör att ta inspiration ifrån är svårt att säga. Det är mer än en förbättring av den aerodynamiska prestandan, såsom estetiskt tilltalande design, som behöver beaktas.

Alla ingående steg och metoder har visat sig vara mycket snabba. Att skära ner på antalet simuleringar som uppkommer till följd av en traditionell DOE kan reducera den totala åtgångna tiden för formoptimeringsprocessen. Det som har visat sig vara mest tidskrävande är uppställningen av deformationslådor i ANSA. Detta kräver fortfarande ett visst manuellt arbete. Med deformationslådorna på plats kan övriga steg i processen kopplas och automatiseras helt.

5.2.2 Användning av ytkänslighetsdata

De tre separata områden som valdes att deformera baserades på resultaten från ytkänslighetsdatan. Ytkänsligheten användes således för att få förslag på var modellen har förbättringspotential ur ett aerodynamiskt perspektiv.

I varje deformationslåda bestämdes intervall för designparametrarna samt riktning för deformation. Sedan gjordes en global optimering över hela den definierade lösningsrymden med hjälp av surrogatmodellerna. På så vis kombineras informationen i känslighetsdatan med den globala optimeringen i surrogatmodellerna.

Det är intressant att både tak och främre stötfångare visade sig ge negativa bidrag till luftmotståndskoefficienten. Detta kan ses i samplingspunkt ett och två samt i korrelationskoefficienterna. Om deformationer hade tillåtits i båda riktningarna kanske en ytterligare sänkning av C_D kunde ha erhållits.

5.2.3 Valet av mängden samplingspunkter

Från litteraturstudien togs beslutet att utgå från rekommendationer från Song et al. [19] att åtta samplingspunkter bör användas när tre parametrar skall optimeras. Det har visat sig att samtliga modeller predikterar lösningen för en given parameterkombination bättre i lösningsrymdens mitt än vid utkanterna. Detta resultat överensstämmer med teorin. Att interpolera funktionsvärden ger ett mindre fel i prediktionen än en extrapolering utanför det konvexa området inneslutet av samplingspunkterna. Detta har

kringgått till viss del genom att tillåta för stora deformationer av bilmodellen. Om Lösningsrymden sträcker sig utanför vad som är rimliga omkonstruktioner ges bra prediktioner av mindre deformationer inom det inneslutna området.

5.2.4 Optimering med PSO

Att använda PSO som en optimeringsalgoritm har visat sig ge goda resultat på kort tid. Med den givna partikelsvärmstorleken på 50 individer lyckades den optimala punkten i Lösningsrymden erhållas vid samtliga försök. Detta kan bero på att en för stor population valdes. Eftersom algoritmen är så snabb, med ett erhållet resultat inom endast några sekunder, har det dock visat sig att det inte gör något om populationen är överdimensionerad.

5.2.5 Utvärdering av surrogatmodeller

När surrogatmodellerna tränades uppvisade ingen av dem konvergensproblem och samma resultat erhöles vid varje träning vilket visar på robusthet i metoderna. Samtliga modeller gav ett fel i interpolationen nära användtolerans när dessa jämfördes med de fyra verifieringspunkterna. Att standardavvikelsen blir så stor för det neurala nätverket, kriging och RBF beror på att vaken blir instabil då den bakre sidan dras ut för mycket.

För respektive optimal punkt gav både det neurala nätverket och RBF relativt stora fel i de predikterade värdena jämfört med krigingmetoden. RBF gav däremot den deformation som resulterade i lägst C_D och hade även lägst medelvärderat fel vid prediktering i verifieringspunkterna. Verifieringspunkterna ligger närmare det konvexa området inneslutet av samplingspunkterna än den optimala punkten som ligger på Lösningsrymdens gräns. Detta kan innebära att RBF extrapolerar dåligt nära Lösningsrymdens kanter.

Från figur 4.5 - 4.7 verkar det som att IDW borde ge den bästa prediktionen av luftmotståndskoefficienten. Denna prediktion befinner sig i den lokala minimipunkt som kan ses vid den femte samplingspunkten. Dock gav IDW både det sämsta predikterade optimala värdet och störst medelvärderat fel i verifieringspunkterna. Detta skulle kunna bero på de inställningar som valts att använda vid implementering av denna metod. Ingen undersökning har genomförts för att minimera felet i prediktionerna genom att i efterhand ändra variabler i interpolationsmetoderna.

Det neurala nätverket, kriging och RBF predikterade optimala punkter skilda från de åtta samplingspunkterna. Simuleringar verifierade att de optimala punkterna för respektive modell gav ett lägre C_D än referensmodellen vilket visar att metoderna uppnår sitt syfte.

5.2.5.1 Extrapolering av samplingspunkter

RBF, det neurala nätverket och kriging visar att några av deformationerna bör vara designparametrarnas största eller minsta värden. Detta tyder på att ytterligare förbättring kan fås genom att deformera utanför angivna intervall. Vid deformation utanför intervallen kan dock surrogatmodellernas extrapolering vara opålitlig. Följden skulle bli återvändande till att testa olika punkter genom DOE vilket är mer tidskrävande. Då även för stora deformationer redan har tillåtits bör därför deformationer utanför lösningsrymden inte göras. Om det önskas att utöka lösningsrymden bör nya datapunkter genereras med hjälp av LHS och simuleringar köras för att sedan träna modellerna på nytt.

6. Slutsats

Syftet med detta kandidatarbete har varit att undersöka och utvärdera olika formoptimeringsmetoder för problem inom aerodynamik. Slutsatser har kunnat dras från de framtagna resultaten i form av figurer och simulerade värden.

Adjointmetoden har visat sig ha konvergenssvårigheter vilket indikerar att metoden är känslig för störningar. Olika placering av deformationsnoderna påverkade hur jämnt modellen deformeras. Det tillhörande deformationsverktyget i STAR-CCM+ var dock svårhanterligt och gav inga önskade resultat i form av minskat C_D .

Optimering med surrogatmodeller har framstått som en robust formoptimeringsmetod som kan ta fram optimala konfigurationer där stora C_D -ändringar med små fel i prediktionerna erhålls. Från ytkänslighetsanalysen kan värdefulla slutsatser dras om hur geometrin skall deformeras. Formoptimeringsmetoden visade sig vara en blandning av manuellt och automatiskt arbete. Mest tidskrävande var det manuella arbetet som var nödvändigt vid uppställning av deformationslådor på bilmodellen. Däremot har det automatiska arbetet visat sig vara väldigt snabbt. Från denna studie är det svårt att avgöra vilken av surrogatmodellerna som fungerat bäst.

6.1 Framtida rekommendationer

Det finns potential för utveckling av adjointmetoden i sin helhet. Vid framtida utvärdering av deformationsverktyget i STAR-CCM+ kan fler respektive färre noder på olika områden testas för att studera utfallet av dessa. Vidare kan andra dimensioner av krylovrum och antal defektkorrigeringsiterationer studeras för en fortsatt konvergensstudie.

Optimering med surrogatmodeller på bilmodellen VRAK har visat sig vara en lovande metod med potential till vidare förbättring. Genom att öka antalet samplingspunkter och erhålla en större databas kan vidare undersökningar kring förbättring av noggrannheten i resultaten utföras. Fler interpolationsmetoder kan introduceras för att erhålla en större jämförandestudie mellan modellerna. Det skulle också vara intressant att optimera med andra, alternativt flera, designparametrar för att undersöka hur felet och noggrannheten varierar.

Att tillåta deformationer endast i en riktning från referensmodellen visade sig ge negativa bidrag till luftmotståndskoefficienten för två av designparametrarna. För att vidare undersöka hur C_D beror av en geometriändring bör deformationer i flera dimensioner tillåtas.

Adjointmetoden och surrogatmodellering skulle i en framtida studie kunna kombineras med avseende på deras optimeringskaraktäristik. I ett första utvecklingsstadium kan adjointmetoden användas för att ta fram ytkänslighetsdatan för valet av placering av deformationslådorna. Därefter kan lösningsrymden genereras och surrogatmodeller skapas, varpå modellerna kan användas för global optimering. Slutligen kan adjointmetoden användas igen för att förfinas modellen lokalt på detaljnivå med en lokal optimering. Det sista steget förutsätter att deformationsverktyget uppfyller sitt syfte. En lyckad implementering kan resultera i att styrkor utnyttjas, men även att svagheter undviks från respektive metod. Om alla ingående steg kan kopplas i en gemensam automatiserad formoptimeringsprocess finns potential till minskat manuellt arbete.

Källförteckning


- [1] D.-G. for Climate Action. (2017). 2020 climate energy package, Tillgänglig: https://ec.europa.eu/clima/policies/strategies/2020_en.
- [2] R. Barnard, *Road Vehicle Aerodynamic Design*, ser. 3rd Revised edition (January 27, 2010). Mechaero Publishing, 2009, ISBN: 978-0954073473.
- [3] R. Löhner, O. Soto, och C. Yang, “An adjointbased design methodology for cfd problems,” *International Journal of Numerical Methods for Heat & Fluid Flow*, vol. 14, s. 734–759, 2004. DOI: 10.1108/09615530410544292.
- [4] B. L. Hinchliffe och N. Qin, “Using surface sensitivity from mesh adjoint for transonic wing drag reduction,” 2017. DOI: 10.2514/1.J055319.
- [5] T. Blacha och M. Islam, “The aeryodynamic development of the new audi q5,” 2017. DOI: 10.4271/2017-01-1522.
- [6] F. M. White, *Fluid Mechanics*, ser. 7th Revised edition (April 1, 2011). McGraw Hill Higher Education, 2009, ISBN: 9780071311212.
- [7] M. Benz. (2015). Tekniska data för g-klass terrängbil, Tillgänglig: http://www.mercedes-benz.se/content/sweden/mpc/mpc_sweden_website/sv/home_mpc/passengercars/home/new_cars/models/g-class/_w463_crosscountry/facts_/technicaldata/models.html.
- [8] Autoevolution. (2016). Volvo v50, Tillgänglig: <https://www.autoevolution.com>.
- [9] P. Zal. (2009). 2004 dodge durango slt 4wd 5.7l v-8 (model since mid-year 2003 for north america u.s.) specifications performance data review, Tillgänglig: http://www.automobile-catalog.com/car/2004/690080/dodge_durango_slt_4wd_5_7l_v-8.html.
- [10] Carfolio. (2014). 2014 volvo v60 d4 technical specifications, Tillgänglig: <http://www.carfolio.com/specifications/models/car/?car=392150>.
- [11] A. TK. (2017). 2016 volvo xc90 dimensions, Tillgänglig: <http://autotk.com/dimensions/volvo/xc90/2016/>.
- [12] CFD-online. (2012). Finite volume, Tillgänglig: https://www.cfd-online.com/Wiki/Finite_volume.

- [13] E. Ljungskog och U. Nilsson, “Cfd for underhood modeling development of an efficient method,” Master’s thesis, Chalmers University of Technology, Gothenburg, 2014.
- [14] C. Othmer, “Adjoint methods for car aerodynamics.,” 2014. DOI: 10.1186/2190-5983-4-6.
- [15] E. Helgason, “Development of adjoint-based optimization methods for ducted flows in vehicles,” PhD thesis, Chalmers University of Technology, SE-412 96 Gothenburg, 2015, ISBN: 978-91-7597-150-6.
- [16] G. K. Karpouzas *et al.*, “Adjoint optimization for vehicle external aerodynamics,” Tech. Rep., 2016.
- [17] CD-adapco, *Star-ccm+ user guide*, version 11.06, 2016.
- [18] P. Soldan. (2014). How to help the convergence of the primal solution before applying the adjoint method, Tillgänglig: https://steve.cd-adapco.com/articles/en_US/FAQ/How-to-help-the-convergence-of-the-primal-solution-before-applying-the-Adjoint-method.
- [19] K. Song *et al.*, “Aerodynamic design optimization of rear body shapes of a sedan for drag reduction,” *International Journal of Automotive Technology*, vol. 13, no. 6, s. 905–914, 2012. DOI: 10.1007/s1223901200917.
- [20] A. Forrester, A. Sobester, och A. Keane, *Engineering Design via Surrogate Modelling: A Practical Guide*. Wiley, 2008, ISBN: 978-0-470-06068-1.
- [21] B. Fornberg och C. Piret, “On choosing a radial basis function and a shape parameter when solving a convective pde on a sphere,” *Journal of Computational Physics*, vol. 227, s. 2758–2780, 2008. DOI: 10.1016/j.jcp.2007.11.016.
- [22] G. B. Wright, “Radial basis function interpolation: Numerical and analytical developments,” PhD thesis, University of Colorado, Boulder, Colorado 80309, USA, 2003.
- [23] W. R. Tobler, “A computer movie simulating urban growth in the detroit region,” 1970. DOI: 10.2307/143141.
- [24] G. I. S. (GIS). (2017). Inverse distance weighting (idw) interpolation, Tillgänglig: <http://gisgeography.com/inverse-distance-weighting-idw-interpolation/>.
- [25] MathWorks. (2017). What is particle swarm optimization? Tillgänglig: <https://se.mathworks.com/help/gads/what-is-particle-swarm-optimization.html>.


- [26] T. Orr. (2014). What are the requirements for convergence of an adjoint case? Tillgänglig: https://steve.cd-adapco.com/articles/en_US/FAQ/What-are-the-requirements-for-convergence-of-an-adjoint-case.
- [27] T. Blacha *et al.*, “Application of the adjoint method for vehicle - aerodynamic optimization,” 2016. DOI: 10.4271/2016-01-1615.
- [28] C. Paulson. (2015). The user friendly python kriging toolbox, Tillgänglig: <https://pykriging.com/>.
- [29] A. Chirokov. (2006). Scattered data interpolation and approximation using radial base functions, Tillgänglig: <https://se.mathworks.com/matlabcentral/fileexchange/10056-scattered-data-interpolation-and-approximation-using-radial-base-functions>.
- [30] S. Fatichi. (2012). Inverse distance weighting, Tillgänglig: <https://se.mathworks.com/matlabcentral/fileexchange/24477-inverse-distance-weight>.

A. Residualer


Följande bilaga presenterar residualplottar för adjointlösarens olika inställningar.




Figur A.1: GMRES-flexible 15 dimensioner av krylovrum och en defektkorrigeringsiteration




Figur A.2: GMRES-restarted 15 dimensioner av krylovrum och en defektkorrigeringsiteration




Figur A.3: GMRES-flexible 50 dimensioner av krylovrum och tre defektkorrigeringsiterationer




Figur A.4: GMRES-restarted 50 dimensioner av krylovrum och tre defektkorrigeringsiterationer



Figur A.5: GMRES-flexible *100 dimensioner av krylovrum och tio defektkorrigeringsiterationer*




Figur A.6: GMRES-restarted *100 dimensioner av krylovrum och tio defektkorrigeringsiterationer*




Figur A.7: GMRES-flexible *100 dimensioner av krylovrum och tre defektkorrigeringsiterationer*

B. Optimala geometrier

Följande bilaga presenterar de framtagna optimala geometrikonfigurationerna för det neurala nätverket i magenta, kriging i gult och IDW i rött.



Figur B.1: Frontvy av vertikalt snitt 0,4 m från bilens framkant



Figur B.2: Sidovy med vertikalt snitt genom bilens centerlinje



Figur B.3: Toppvy med horisontellt snitt 0,85 m upp från marken

