


Multi-disciplinair ontwerp en multi-objective optimalisatie van een blended-wing-body vliegtuigconfiguratie met behulp van benaderingsmodellen



Marte ten Dam



Multi-disciplinair ontwerp en multi-objective optimalisatie van een blended-wing-body vliegtuigconfiguratie met behulp van benaderingsmodellen

Kernwoorden:

Artificial Neural Network, vleugelprofiel, vliegtuigontwerp, parameterstudie, CAD, CFD, genetisch algoritme, gradiënt methode

Auteur:

Marte ten Dam

Afronding:

Februari 2002

Universiteit:

Universiteit van Amsterdam

Faculteit:

Faculteit der Natuurwetenschappen,
Wiskunde en Informatica

Studierichting:

Informatica

Specialisatie:

Technische Informatica

Afstudeer instelling:

Nationaal Lucht – en
Ruimtevaartlaboratorium (NLR)

Begeleiders:

P.M.A. Sloot (UvA), W.J. Vankan (NLR)

Samenvatting

In multi-disciplinair ontwerp van vliegtuigen wordt veel gebruik gemaakt van numerieke simulaties om eigenschappen en gedrag van het vliegtuig te voorspellen. Zo worden bijvoorbeeld simulaties uitgevoerd van de luchtstromingen rondom het vliegtuig (Computational Fluid Dynamics) en van de vervormingen van het vliegtuig (Computational Structural Mechanics). Dit soort berekeningen zijn over het algemeen erg complex en rekenintensief. Rekentijden van vele uren op supercomputers zoals de NEC-SX-5 van het NLR zijn geen uitzondering.

Dergelijke rekenintensieve evaluaties zijn niet wenselijk als deze evaluaties zeer veelvuldig en/of in kort tijdbestek uitgevoerd moeten worden. Dit is bijvoorbeeld het geval in ontwerptimalisatie studies, bijvoorbeeld bij gebruik van genetisch algoritmen (GA). Er wordt daarom getracht vereenvoudigde en minder rekenintensieve benaderingsmodellen te ontwikkelen van de eigenschappen van een ontwerp waarin men specifiek geïnteresseerd is. Dit gebeurt onder andere met neurale netwerken (artificial neural networks: ANN's). Met behulp van een representatieve dataset van de gewenste multi-disciplinaire eigenschappen van het beschouwde ontwerp, kan een ANN 'getraind' worden tot benaderingsmodel van die eigenschappen. De representatieve dataset kan verkregen worden met (rekenintensieve) numerieke simulatieberekeningen, die hiervoor in veel geringere aantallen en op efficiëntere wijze uitgevoerd kunnen worden dan wanneer zij direct in bijvoorbeeld de ontwerptimalisatie studie uitgevoerd zouden worden.

In deze studie zijn, met behulp van ANN's, benaderingsmodellen gemaakt van een aantal eigenschappen van een blended-wing-body (BWB) vliegtuigconfiguratie. Allereerst is een benaderingsmodel gemaakt van enkele eigenschappen van het 2-D vleugelprofiel van de BWB, waarmee een multi-objective ontwerptimalisatie studie is uitgevoerd. Vervolgens is een benaderingsmodel gemaakt van enkele multi-disciplinaire eigenschappen van de gehele 3-D BWB configuratie. Dit benaderingsmodel is toegepast in een multi-objective optimalisatie studie waarin aërodynamische-, mechanische- en besturingseigenschappen van de BWB gelijktijdig geoptimaliseerd zijn. De resulterende set van geoptimaliseerde ontwerpen, het zogenaamde Pareto front, bestaat uit enkele tientallen Pareto-optimale, oftewel "niet-gedomineerde", ontwerpen, welke allen voor tenminste één eigenschap beter zijn dan het referentie BWB ontwerp.



Inhoudsopgave

1	Inleiding	6
2	Multi-objective optimalisatie	8
2.1	Single-objective versus multi-objective optimalisatie	8
2.2	Multi-objective optimalisatiemethoden	9
2.2.1	Gradiënt gebaseerde optimalisatie methoden (GM)	9
2.2.2	Genetische algoritmen (GA)	11
2.3	Multi-objective optimalisatie van enkele 2-D analytische functies	11
2.3.1	Eenvoudige analytische testfunctie	11
2.3.2	Complexe analytische testfunctie	13
2.4	Resultaten GM versus GA	15
2.5	Conclusie	16
3	Neurale netwerken	18
3.1	Wat zijn neurale netwerken?	18
3.2	Hidden layers en nodes	18
3.3	Kwaliteit van ANN benaderingsfuncties	19
3.4	Outputs van het ANN	20
4	Vleugelprofiel ontwerp optimalisatie studie	22
4.1	Geometrische parametrisatie van het vleugelprofiel	23
4.1.1	Lineaire deformatie van het standaard RAE2822 profiel (PAR1)	23
4.1.2	Parametrische wortelfuncties (PAR2)	23
4.1.3	Bezier curves (PAR3)	24
4.2	Beoordeling van de verschillende parametrische functies	24
4.2.1	Benadering van het RAE2822 profiel	25
4.2.2	Effectiviteit en benodigd aantal parameters	26
4.2.3	Geometrische vrijheid	28
4.2.4	Conclusies	28
4.3	Doelfuncties	28
4.4	Parameter studie	29
4.4.1	Parameterranges	29
4.4.2	Invloed van afzonderlijke parameters op Cl/Cd	30
4.4.3	Invloed van twee parameters op de doelfuncties	31
4.4.4	Invloed van alle parameters op de doelfuncties	32



4.4.5	Conclusies	33
4.5	Vleugelprofiel optimalisatie met twee variabele parameters	33
4.5.1	ANN instellingen	33
4.5.2	GM optimalisatie	34
4.5.3	Resultaten GM versus GA	35
4.5.4	Verificatie van ANN benadering in optimalisatie	35
4.6	Vleugelprofiel optimalisatie met vijf variabele parameters	36
4.6.1	ANN instellingen	36
4.6.2	GM optimalisatie	37
4.6.3	Resultaten GM versus GA	37
4.6.4	Verificatie van ANN benadering in optimalisatie	38
4.7	Conclusies	38
5	Multi-disciplinaire ontwerp optimalisatie van een BWB vliegtuigconfiguratie	39
5.1	Referentie BWB geometrie	39
5.2	Geometrische parametrisatie	39
5.3	Software tools	40
5.3.1	ICAD	41
5.3.2	Endomo en Deftop	41
5.3.3	Engrid	42
5.3.4	Ensolv	43
5.4	ANN instellingen	44
5.5	BWB optimalisaties	44
5.5.1	GM optimalisatie	45
5.5.2	GA optimalisatie	46
5.5.3	Resultaten GM versus GA	47
5.6	Verificatie van ANN benadering in optimalisatie	48
6	Algemene conclusies en discussie	50
	Literatuur	51
	Appendix A Condor versus Runonhosts	52
	A.1 Werking Myrunonhosts	53
	Appendix B Ensolv invoer voor CFD berekeningen	55

(55 pagina's totaal)

1 Inleiding

Met de toename van de rekencapaciteit door de verbeteringen in hard- en software van de laatste jaren is ook het gebruik van rekenintensieve simulatiegereedschappen, zoals Computational Fluid Dynamics (CFD) en Computational Structural Mechanics (CSM) programma's, toegenomen. Naast het steeds nauwkeuriger berekenen van bepaalde eigenschappen van een ontwerp met behulp van deze gereedschappen, wordt het ook steeds realistischer om deze berekeningen veelvuldig en binnen geautomatiseerde procedures uit te voeren. Een voorbeeld van zo'n geautomatiseerde procedure is een automatisch ontwerpoptimalisatie proces waarbinnen een simulatiegereedschap gebruikt wordt voor de evaluatie van de eigenschappen van het te optimaliseren ontwerp.

Voor de automatische optimalisatie van een ontwerp is een doelfunctie nodig waarmee het gewenste gedrag van een ontwerp gekwantificeerd wordt. In het algemeen is het echter onmogelijk om dit gewenste gedrag adequaat te kwantificeren met een enkele doelfunctie. Dit is met name het geval indien er sprake is van multi-disciplinair ontwerp, i.e. meer dan één discipline is noodzakelijk om de essentiële eigenschappen van een ontwerp te evalueren, zoals typisch de disciplines aërodynamica en mechanica in de vliegtuigbouw. Er bestaan dan over het algemeen per discipline een of meerdere onafhankelijke eigenschappen die elk afzonderlijk geanalyseerd, gekwantificeerd en geoptimaliseerd dienen te worden. Het proces waarin de verschillende eigenschappen gelijktijdig en onafhankelijk van elkaar geoptimaliseerd worden tot een zogenaamd Pareto front, wordt *multi-objective optimalisatie* genoemd. In een dergelijke aanpak kunnen *genetische* of *evolutionaire* algoritmen voor de optimalisatie effectief ingezet worden. Een kritisch aspect van het gebruik van dit soort algoritmen is dat tijdens de optimalisatie de rekenintensieve numerieke simulaties van het gedrag van het ontwerp zeer veelvuldig uitgevoerd moeten worden. Hierdoor kunnen praktische drempelwaarden van reketijden van automatische rekenprocessen – bijvoorbeeld ca. 20 uur voor “nacht-jobs”, of ca. 60 uur voor “weekend-jobs” – bereikt worden. Om de reketijden voor omvangrijke problemen te beperken kan gebruik gemaakt worden van vereenvoudigde en minder rekenintensieve benaderingsmodellen van alle of enkele van de beschouwde multi-disciplinaire eigenschappen van het ontwerp. Door vervolgens een combinatie van nauwkeurige doch rekenintensieve numerieke simulaties en onnauwkeurige doch efficiënte evaluaties met benaderingsmodellen toe te passen in de optimalisatie van het ontwerp, kan een gewenste afstemming tussen nauwkeurigheid en rekensnelheid verkregen worden.

In deze studie zal worden nagegaan in hoeverre benaderingsmodellen op basis van neurale netwerken (artificial neural networks: ANN's) geschikt zijn om multi-disciplinaire eigenschappen van een blended-wing-body (BWB) vliegtuigconfiguratie te representeren ten behoeve van multi-objective optimalisatie. Allereerst is een benaderingsmodel gemaakt van enkele eigenschappen van het 2-D vleugelprofiel van de BWB, waarmee een multi-objective



ontwerptimalisatie studie is uitgevoerd [3]. Vervolgens is een benaderingsmodel gemaakt van enkele multi-disciplinaire eigenschappen van de gehele 3-D BWB configuratie. Dit benaderingsmodel is toegepast in een multi-objective optimalisatie studie waarin aërodynamische-, mechanische- en besturingseigenschappen van de BWB gelijktijdig geoptimaliseerd zijn.

2 Multi-objective optimalisatie

In het ontwerpproces van bepaalde producten kunnen numerieke simulaties helpen om het beste ontwerp in de ruimte van alle mogelijke ontwerpen te vinden. Tijdens dit proces moet natuurlijk aan alle eisen worden voldaan, maar zal ook een aantal eigenschappen van het ontwerp geoptimaliseerd dienen te worden. Voor de automatische optimalisatie van een ontwerp is een doelfunctie nodig waarmee het gewenste gedrag van een ontwerp gekwantificeerd wordt. In het algemeen is het echter onmogelijk om dit gewenste gedrag adequaat te kwantificeren met één enkele doelfunctie. Dit is bijvoorbeeld het geval indien er sprake is van een multi-disciplinair ontwerp, i.e. de eigenschappen uit verschillende disciplines zijn noodzakelijk om de essentiële karakteristieken van een ontwerp te evalueren. De optimalisatie van een ontwerp waarvan verschillende eigenschappen gekwantificeerd worden door meerdere doelfuncties heet multi-objective optimalisatie.

2.1 Single-objective versus multi-objective optimalisatie

In single-objective optimalisatie is er slechts één enkele doelfunctie die geoptimaliseerd dient te worden. In dergelijke optimalisaties kan eenvoudigweg worden gezocht naar het optimum van deze doelfunctie. In multi-objective optimalisatie zijn er meerdere, onderling niet-lineair afhankelijke doelfuncties die geoptimaliseerd dienen te worden. Hier wordt met optimalisatie overigens impliciet minimalisatie verondersteld. Deze doelfuncties zijn vaak tegenstrijdig en het is in het algemeen niet mogelijk om één ontwerp te vinden dat optimaal is voor alle doelfuncties. Daarom wordt in dergelijke optimalisaties gezocht naar het zogenaamde Pareto optimum. Voor een multi-objective ontwerpprobleem geldt dat een geldig ontwerppunt, uitgedrukt in de parameter ruimte als: $\bar{x}^* \in F$, Pareto optimaal is indien voor elk ander geldig ontwerppunt $\bar{x} \in F$ geldt:

$$f_i(\bar{x}) = f_i(\bar{x}^*), i = 1, \dots, n$$


of voor minimaal één waarde van i :

$$f_i(\bar{x}) > f_i(\bar{x}^*)$$

waar f_i de i -de doelfunctie (of “objective”) representeert, n het totaal aantal doelfuncties is en F de deelruimte met alle geldige ontwerpen in de parameter ruimte representeert.

Voor multi-dimensionale parameter ruimten, welke zeer gangbaar zijn in ontwerpopimalisatie, levert deze Pareto optimum definitie zelden één enkel punt op, doch zal in het algemeen resulteren in een set van zogenaamd “niet-gedomineerde” punten. Deze set punten ligt doorgaans op de rand van de doelfunctie-deelruimte van geldige ontwerpen en wordt daarom met Pareto front aangeduid.

Met andere woorden, het Pareto front bestaat uit alle geldige ontwerpen voor welke geldt dat er geen ander geldig ontwerp bestaat met betere functiewaarden in *alle* doelfunctie richtingen, zie figuur 1.



Figuur 1: Voorbeeld Pareto optimale punten (zwart) bij multi-objective minimalisatie van de doelfuncties 1 en 2.

2.2 Multi-objective optimalisatiemethoden


Voor multi-objective optimalisatie kunnen verschillende soorten optimalisatie algoritmen gebruikt worden. Twee van deze algoritmen zijn in deze studie toegepast: gradiënt gebaseerde methoden (GM) en genetische algoritmen (GA).

2.2.1 Gradiënt gebaseerde optimalisatie methoden (GM)

In gradiënt gebaseerde methoden wordt een doelfunctie iteratief verbeterd in de richting van de beste verbetering. Hierbij wordt gebruik gemaakt van de afgeleide (gradiënt) van de doelfunctie naar de ontwerpparameters. Nadeel van deze methoden is onder andere dat het gaat om lokale optimalisaties. Voordeel is dat deze methoden met een gering aantal doelfunctie evaluaties het optimum van de doelfunctie kunnen vinden, en dat constraints effectief verwerkt kunnen worden. Bij het gebruik van deze methoden in multi-objective optimalisaties worden doelfuncties en constraints afwisselend toegepast teneinde zoveel mogelijk minima voor alle doelfuncties te vinden. Er zijn verschillende technieken waarmee op basis van GM methoden multi-objective optimalisaties uitgevoerd kunnen worden:

- Constrained objectives: In deze variant worden er constraints op op één na alle doelfuncties gelegd en wordt in de vrije doelfunctierichting geoptimaliseerd. De volgende constraints zijn mogelijk:
 - gelijkheidsconstraint: doelfunctie moet gelijk zijn aan een vaste waarde
 - enkele ongelijkheidsconstraint: doelfunctie heeft onder- of bovengrens
 - dubbele ongelijkheidsconstraint: doelfunctie heeft onder- en bovengrens


De mogelijkheden zijn geïllustreerd in figuur 2.



Figuur 2: Optimalisatie richting Pareto front (rode lijn) met gelijkheidsconstraint (links), enkele ongelijkheidsconstraint (midden) en dubbele ongelijkheidsconstraint (rechts).

Alle mogelijkheden zijn in principe terug te voeren op een dubbele ongelijkheidsconstraint bij gebruik van oneindige of juist zeer smalle grenzen

- **Weighted Sum:** De Weighted Sum strategie converteert het multi-objective probleem bestaande uit het minimaliseren van een vector in een scalair probleem door het construeren van een gewogen som van alle doelfuncties. Het probleem kan vervolgens geoptimaliseerd worden met behulp van een standaard niet-geconstraint optimalisatie algoritme. De gewichten definiëren de richtingscoëfficiënt van de scalaire doelfunctie. Tijdens optimalisatie wordt gezocht naar het raakpunt van de scalaire doelfunctie met het Pareto front. Vanuit één startpunt kunnen door gebruik te maken van verschillende gewichten combinaties meerdere Pareto punten gevonden worden, zie figuur 3.



Figuur 3: Resulterende Pareto punten behorende bij analytische doelfuncties (1) na Weighted Sum optimalisatie vanuit één startpunt met verschillende gewichten combinaties.

- **Minimax:** In deze variant wordt de worst-case waarde van een verzameling multi-variabele functies geminimaliseerd, waarbij gestart wordt met een initiële schatting. Hierbij kunnen constraints worden toegepast. De doelfuncties moeten continu zijn en er worden alleen locale oplossingen gevonden. Zie ook [7].

In deze studie wordt de constrained objective variant met gelijkheidsconstraints gebruikt tijdens optimalisatie om zoveel mogelijk controle te houden over het aantal Pareto punten en de ligging hiervan.

2.2.2 Genetische algoritmen (GA)

Genetische of evolutionaire algoritmen zijn zoektechnieken geïnspireerd door de biologische evolutie theorie. Het algoritme start met een populatie van willekeurige ontwerpen en door middel van reconstructie methoden worden iteratief generaties met betere populaties geconstrueerd. In deze studie wordt gebruik gemaakt van een MOEA programma [5] waarmee multi-objective optimalisaties met behulp van GA uitgevoerd kunnen worden.

2.3 Multi-objective optimalisatie van enkele 2-D analytische functies


De gebruikte optimalisatie methoden GM en GA zijn beide in staat om een Pareto front te bepalen. Bij de bepaling van welke methode meer geschikt is moet niet alleen gekeken worden naar de kwaliteit van de gevonden Pareto punten, maar ook naar het benodigde aantal functie evaluaties om tot het gewenste resultaat te komen. Het aantal functie evaluaties kan van belang zijn als deze evaluaties rekenintensieve ontwerp evaluaties omvatten. Om de bruikbaarheid en de kwaliteit van beide methoden te testen voor multi-objective optimalisatie, wordt begonnen met het optimaliseren van illustratieve analytische functies.

2.3.1 Eenvoudige analytische testfunctie

De volgende eenvoudige analytische functies (1) worden als doelfuncties gebruikt om de multi-objective optimalisatie methoden te testen en te illustreren. Beide doelfuncties dienen in dit voorbeeld te worden geminimaliseerd. Er wordt dus gezocht naar het Pareto front.

$$\left. \begin{aligned} z_1 &= r \times \cos(\phi) \\ z_2 &= r \times \sin(\phi) \end{aligned} \right\} 0 \leq r \leq 1; \quad -\pi \leq \phi < \pi \quad (1)$$

Figuur 4 toont de doelfuncties als functie van r (straal) en ϕ (hoek) in de parameter ruimte (r, ϕ). In de parameter ruimte is het moeilijk te bepalen waar het Pareto front zich bevindt. Om hier inzicht in te krijgen toont figuur 4 een aantal mogelijke punten in de doelfunctie ruimte. In deze ruimte is het bij deze doelfuncties mogelijk de exacte ligging van het Pareto front te bepalen, in figuur 4 aangegeven met de rode lijn.




Figuur 4: Analytische 2-D doelfuncties (1) gepresenteerd in parameter ruimte: $z_1 = r \times \cos(\phi)$ (links) en $z_2 = r \times \sin(\phi)$ (midden) en mogelijke (z_1, z_2) waarden in de doelfunctie ruimte (rechts). De rode lijn illustreert de ligging van het Pareto front.

De punten die dit Pareto front beschrijven hebben allemaal de parameterwaarden $r = 1$ en $-\pi \leq \phi \leq -\frac{\pi}{2}$. Een dergelijke exacte bepaling van de ligging van het Pareto front is in het algemeen echter niet mogelijk.

Zowel het GM als het GA zijn toegepast om deze doelfuncties te optimaliseren. In beide optimalisatie methoden is begonnen met een verzameling punten die dient als beginschatting van de GM en GA optimalisaties. In de GM optimalisatie worden deze punten één voor één geoptimaliseerd in beide doelfunctie richtingen en in de GA optimalisatie worden vanuit deze initiële populatie iteratief 50 generaties met verbeterde populaties geconstrueerd. In de GM optimalisatie wordt dus telkens één doelfunctie met een gelijkheidsconstraint op (ongeveer) een vaste waarde gehouden, terwijl de andere doelfunctie geminimaliseerd wordt (figuur 5).

Figuur 5 toont de resultaten van de GM en GA optimalisaties.



Figuur 5: Initiële populatie voor GM en GA multi-objective optimalisatie runs (links) en illustratie van de herhaalde constrained objective minimalisatie van de GM tool (midden) voor de analytische test case. Het resulterende Pareto front van zowel de GM als de GA runs (rechts).


De gevonden niet gedomineerde punten van het Pareto front, na GM en GA optimalisatie, hebben allemaal de parameterwaarden $r = 1$ en $-\pi \leq \phi \leq -\frac{\pi}{2}$ en bevinden zich dus op het exacte Pareto front. Het benodigde aantal functie evaluaties in GM en GA om tot deze resultaten te komen is respectievelijk ongeveer 2500 en 1700.

2.3.2 Complexe analytische testfunctie

Om de kwaliteit van beide optimalisatie methoden te testen voor iets complexere doelfuncties, worden de volgende functies (2) gebruikt.

$$\begin{aligned}
 z_1 &= \frac{\sin(r_1)}{r_1}; \quad r_1 = \sqrt{x^2 + y^2}; \quad (x, y) \in \mathfrak{R} \\
 z_2 &= 2 - \frac{\sin(r_1 \times 2)}{r_1}; \quad r_1 = \sqrt{x^2 + y^2}; \quad (x, y) \in \mathfrak{R} \\
 z_3 &= 2 - \frac{\sin(r_2)}{r_2}; \quad r_2 = \sqrt{(x-2)^2 + (y-2)^2}; \quad (x, y) \in \mathfrak{R}
 \end{aligned} \tag{2}$$


Figuur 6 toont deze doelfuncties als functie van x en y in de parameter ruimte (x,y) .



Figuur 6: Analytische 2-D doelfuncties (2) gepresenteerd in parameter ruimte: z_1 (links) z_2 (midden) en z_3 (rechts).


Er worden multi-objective minimalisaties uitgevoerd met GM en GA op de functie combinaties: *functie1*: $f_1 = (z_1, z_2)$ en *functie2*: $f_2 = (z_1, z_3)$.

Figuur 7 toont beide functies in de doelfunctie ruimte. Ook is aangegeven met de rode lijn waar het Pareto front zich bevindt.



Figuur 7: Mogelijke (z_1, z_2) en (z_1, z_3) waarden in de doelfunctie ruimte: f_1 (links) en f_2 (rechts) De rode lijn illustreert de ligging van het Pareto front.


De startpunten waarmee in beide multi-objective optimalisaties begonnen wordt, zijn een aantal (ongeveer 50) punten uit een verzameling min of meer willekeurig gegenereerde functiewaarden. In het GA worden 50 generaties berekend.



Figuur 8: Mogelijke (z_1, z_2) waarden van f_1 in de doelfunctie ruimte en initiële populatie voor GM en GA multi-objective optimalisatie runs (links). Het resulterende Pareto front van zowel de GM als de GA runs (midden) met de bijbehorende parameter waarden (rechts).

De resultaten na optimalisatie met behulp van GM en GA voor f_1 zijn te zien in figuur 8. Doordat de punten in de doelfunctie ruimte allen op een lijn liggen en het GM alleen langs de richting van de assen optimaliseert, is het aantal gevonden Pareto punten na optimalisatie met GM veel kleiner dan met het GA (respectievelijk 8 en 50). Het benodigde aantal functie evaluaties in GM en GA om tot deze resultaten te komen is respectievelijk ongeveer 300 en 4000.

Figuur 9 toont de GM en GA resultaten voor f_2 . Het aantal benodigde functie evaluaties in het GM in dit geval is erg groot, bijna 10.000, door het grote aantal startpunten. Voor GA optimalisatie is dit aantal ongeveer 3600. Omdat de punten in de doelfunctie ruimte van f_2 niet op een lijn liggen, zoals bij f_1 het geval is, wordt het aantal Pareto punten dat gevonden wordt in de GM optimalisatie hierdoor niet beperkt. Het aantal Pareto punten is nu in zowel de GM als de GA optimalisaties afhankelijk van het aantal startpunten en de gewenste spreiding tussen de Pareto punten.



Figuur 9: Mogelijke (z_1, z_3) waarden van f_2 in de doelfunctie ruimte en initiële populatie voor GM en GA multi-objective optimalisatie runs (links). Het resulterende Pareto front van zowel de GM als de GA runs (midden) met de bijbehorende parameter waarden (rechts).

2.4 Resultaten GM versus GA

Uit de middelste afbeeldingen van de figuren 8 en 9 blijkt dat de door beide multi-objective optimalisatie methoden gevonden verzamelingen van niet gedomineerde punten bij benadering tot hetzelfde Pareto front behoren. Er kan gesteld worden dat zowel GM als GA in staat zijn om goede Pareto fronten te bepalen.

Het aantal Pareto punten dat gevonden wordt, is in GM erg afhankelijk van het aantal startpunten en de te optimaliseren doelfuncties. Zo worden er bij optimalisatie van f_1 met GM slechts een klein aantal Pareto punten gevonden, doordat de doelfuncties in de doelfunctie ruimte op een lijn liggen en GM alleen optimaliseert in de richting van de assen. Het gevonden aantal Pareto punten in GA is voornamelijk afhankelijk van de grootte van de initiële populatie.

De spreiding van de gevonden punten op het Pareto front in GM is voornamelijk afhankelijk van de gekozen startpunten en de ingestelde minimale afstand tussen de Pareto punten. In GA wordt de spreiding beïnvloed door een aantal instellingen. De volgende methoden kunnen in GA wel of niet gebruikt worden tijdens de optimalisatie:

- Niching: Methode waarmee de afstand (in doelfunctie of parameter ruimte) tussen verschillende Pareto punten geregeld kan worden, om ‘samenklonteren’ van Pareto punten te voorkomen.
- Mating: Methode waarmee de afstand (in doelfunctie of parameter ruimte) tussen de individuen die geselecteerd worden voor cross-over (‘paring’) geregeld kan worden, om verschillende individuen in de populatie te behouden.

De benadering van het ‘analytische’ Pareto front is voor beide optimalisatie methoden goed. De bijbehorende inputwaarden vertonen echter verschillende eigenschappen, zoals uit de rechter afbeeldingen van de figuren 8 en 9 blijkt. Dit heeft de volgende oorzaken:

- In geval van ‘vlakke doelfuncties’ (kleine gradiënten) in de buurt van het Pareto front, kan het GA wel een goed Pareto front vinden, maar zal de spreiding van de Pareto punten in de parameter ruimte groter zijn dan voor het GM
- Punten die naast elkaar liggen in de doelfunctie ruimte liggen niet per definitie ook naast elkaar in de parameter ruimte.
- In het GA wordt slechts een klein aantal generaties berekend. Meer generaties zou het Pareto front misschien net iets meer optimaliseren, waardoor ook de inputwaarden van beide methoden meer overeenkomen.

Behalve de kwaliteit van de gevonden Pareto punten, is ook een indicatie van het benodigde aantal functie evaluaties van belang. In het GM is het benodigde aantal functie evaluaties voornamelijk afhankelijk van het aantal en van de ligging van de startpunten. In het GA wordt dit aantal voornamelijk bepaald door de populatie grootte en het aantal generaties. Natuurlijk hebben de te optimaliseren doelfuncties hier ook invloed op.

2.5 Conclusie

Er is gebleken dat beide multi-objective optimalisatie methoden in staat zijn om vergelijkbaar goede Pareto fronten te bepalen. Het aantal Pareto punten, de spreiding hiervan en het aantal benodigde functie evaluaties in GM en GA is afhankelijk van de instellingen en de te optimaliseren doelfuncties.

De spreiding in de parameter ruimte van de, door het GA gevonden, Pareto punten is voornamelijk te verklaren door de ‘vlakke doelfuncties’ rond het Pareto front. In ontwerp optimalisatiestudies hoeft dit echter geen probleem te zijn. Er kan namelijk blijken dat geheel andere ontwerp parameters een zo goed als optimaal ontwerp kunnen opleveren.

Onafhankelijk van de instellingen is in beide optimalisatie methoden het benodigde aantal functie evaluaties, dat noodzakelijk is alvorens een gewenst resultaat bereikt wordt, relatief groot (typisch enkele duizenden). In de studie met analytische functies is dit geen onoverkomelijk probleem aangezien het evalueren van een functie weinig rekentijd vergt. Het wordt echter een probleem als de functie evaluaties veel tijd in beslag gaan nemen, zoals typisch het geval is bij ontwerpoptimalisatie, als de doelfunctie afhangt van bijvoorbeeld resultaten van CFD sommen.

In de vervolg studie, waarbij vleugelprofielen en later BWB's geoptimaliseerd worden, is het doen van CFD sommen de methode om de doelfuncties, die gebaseerd zijn op bepaalde ontwerpeigenschappen, te berekenen. Als gevolg van het grote aantal benodigde evaluaties voor de GM en GA multi-objective optimalisaties, zijn de doelfunctie evaluaties op basis van CFD sommen niet haalbaar en moet er een vereenvoudiging toegepast worden om de evaluaties te versnellen. In deze studie wordt gebruik gemaakt van benaderingsmodellen van de ontwerpeigenschappen op basis van neurale netwerken (ANN). In het optimalisatie proces



worden nu geen exacte CFD sommen gedaan om de doelfunctie waarden te berekenen, maar benaderingen hiervan met behulp van een ANN. Deze netwerk evaluaties zijn vele malen sneller uit te voeren dan de CFD sommen (enkele seconden vs. tientallen minuten).

Alvorens in te gaan op de optimalisatie studies van de vleugelprofielen en BWB's, worden eerst in het volgende hoofdstuk enkele achtergronden en eigenschappen van ANN's kort behandeld.

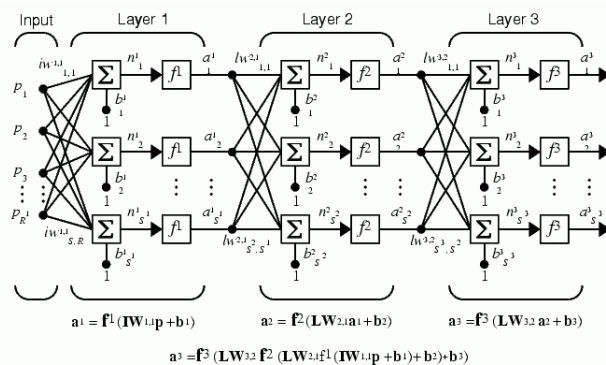
3 Neurale netwerken

In de uiteindelijke optimalisaties van vleugelprofiel en blended-wing-body zal gebruik gemaakt worden van benaderingsmodellen op basis van neurale netwerken. Dit hoofdstuk geeft een beknopt overzicht van de voor dit onderzoek relevante eigenschappen van neurale netwerken. Naar deze eigenschappen is een studie gedaan met behulp van analytische functies. In het gehele onderzoek is gebruik gemaakt van de Neural Network Toolbox van Matlab [8]. Verdere informatie over neurale netwerken is te vinden in [4], [8] en [13].

3.1 Wat zijn neurale netwerken?

Neurale netwerken, ofwel Artificial Neural Networks (ANN's), zijn gebaseerd op het biologische neurale systeem, i.e. de hersenen. Vandaar ook het woord artificial: een ANN is een kunstmatig neuraal systeem. Een ANN maakt gebruik van bepaalde principes die ook in de hersenen gehanteerd worden. Een neuraal netwerk moet worden getraind: het moet leren om te doen wat ervan verlangd wordt.

Een ANN bestaat uit een input layer, hidden layers en een output layer. Hidden layers bestaan uit hidden nodes (figuur 10). Een hidden node is een transitie functie. Door het toekennen van gewichten aan de transitie functies is het netwerk in staat om bij een bepaalde invoer de uitvoer te bepalen. Het trainen van een ANN komt overeen met het aanpassen van de gewichten van de verschillende transitie functies zodanig dat de in- en uitvoer trainingswaarden zo goed mogelijk benaderd worden.




Figuur 10: Voorbeeld Artificieel Neuraal Netwerk (ANN), met een input-, een hidden - en een output layer (respectievelijk Layer 1, 2 en 3).

3.2 Hidden layers en nodes

Hidden layers en nodes leveren connecties in het ANN op. Hoe hoger het aantal connecties in het ANN, hoe meer data en rekestijd er nodig is om het ANN te trainen. In het algemeen bepaald de gekromdheid van de functie het minimaal benodigde aantal hidden nodes. Met slechts één hidden layer kan elke willekeurige functie worden benaderd [4], maar de vraag is of

het gebruik van twee hidden layers voordeliger is uit het oogpunt van het aantal connecties in het netwerk. Dit is onderzocht voor eenvoudige sinusfuncties met verschillend aantal periodes.

Voor elke sinusfunctie is bij een variërend aantal hidden nodes in de eerste layer bepaald wat het minimaal benodigde aantal hidden nodes in de tweede layer is om de sinusfuncties met een fout kleiner dan 10^{-5} te kunnen benaderen. Het aantal connecties in het netwerk volgt hier direct uit. Figuur 11 toont het minimaal benodigde aantal connecties bij een vast aantal hidden nodes in de eerste layer. Nul hidden nodes in de eerste layer is een netwerk met slechts één hidden layer.




Figuur 11: Grafiek waarin voor verschillende sinusfuncties bij een variërend aantal hidden nodes in de eerste layer het minimaal benodigde aantal connecties staat vermeld.

Uit figuur 11 blijkt dat het aantal connecties benodigd om een sinusfunctie te kunnen benaderen met behulp van een ANN, minimaal is bij het gebruik van nul hidden nodes in de eerste layer oftewel één hidden layer in het netwerk.

3.3 Kwaliteit van ANN benaderingsfuncties


In het vervolg van de studie wordt een ANN getraind en vervolgens gebruikt om doelfuncties te benaderen. Met het oog op het bepalen van de trainingsrange is het interessant te weten of een ANN alleen in staat is om binnen het trainingsgebied de doelfunctie te benaderen (interpolatie) of en in hoeverre ook daarbuiten (extrapolatie). Om dit te onderzoeken is een aantal analytische testfuncties gebuikt. Voor de benadering van deze functies zijn ANN's met verschillend aantal hidden nodes getraind in de range van 0 tot 2π . Vervolgens is het getrainde ANN gebruikt om de analytische functies te benaderen voor andere waarden dan de trainingswaarden en buiten de trainingsrange.

Figuur 12 toont de gebruikte analytische functies en illustreert de range van trainingswaarden die gebruikt is voor de training van het ANN.



Figuur 12: Illustratie van de analytische functies f_1 (links), f_2 (midden) en f_3 (rechts) en de trainingsranges die gebruikt zijn in het onderzoek naar de mogelijkheden van ANN's om te extrapoleren..

De fout in de benadering van de verschillende analytische functies met behulp van de getrainde ANN's is geïllustreerd in figuur 13.



Figuur 13: Illustratie van de fout in de benadering, binnen en buiten de trainingsrange, van de analytische functies f_1 (links), f_2 (midden) en f_3 (rechts) uit figuur 12 met behulp van ANN's.

Uit figuur 13 blijkt dat het ANN in staat is om binnen de trainingsrange de analytische functies met een kleine fout te benaderen (interpolatie). Buiten de trainingsrange is de fout in de benadering veel groter, maar nog het kleinst bij het gebruik van een minimaal aantal hidden nodes. In het algemeen kan geconcludeerd worden dat extrapolatie de beste resultaten oplevert als het gekozen aantal hidden nodes laag is. De kwaliteit van deze beste resultaten is erg afhankelijk van de onderliggende functie, hoe gladder hoe beter. Aangezien het, zeker bij een onbekende functie, niet mogelijk is de nauwkeurigheid van de geëxtrapolerde resultaten in te schatten, is het dus erg belangrijk de input trainingsranges zo goed mogelijk te bepalen, zodat extrapolatie minimaal nodig is.


3.4 Outputs van het ANN

Aangezien in de BWB studie het verkrijgen van een voldoende grote dataset voor de training van het ANN kritisch is ten aanzien van de rekenkosten, is het wenselijk de deze dataset zoveel mogelijk te beperken. Met dit doel is onderzocht of het voordeliger is om één ANN met meerdere outputs te trainen of meerdere ANN's met slechts één output. Er is hiertoe een teststudie gedaan met analytische functies. De benaderde functies zijn $\sin(x)$ en $\sin(3x)$, waarbij

in alle ANN's een minimaal benodigd aantal hidden nodes gebruikt is. Er is bepaald wat de minimale benodigde hoeveelheid trainingsdata is om de analytische functies te benaderen met twee afzonderlijke ANN's en met één gecombineerd ANN met twee outputs. Als nauwkeurigheid van de benadering is een fout (mean squared error – de gemiddelde kwadratische fout van ANN output ten opzichte van de trainingswaarden) van maximaal 10^{-5} toegestaan. Tabel 1 en figuur 14 tonen de resultaten:

	1 periode		2 periodes		3 periodes	
	#hidden nodes	benodigde #trainingsdata	#hidden nodes	benodigde #trainingsdata	#hidden nodes	benodigde #trainingsdata
ANN1-output =sin(x)	3	20	5	36	7	46
ANN2-output =sin(3x)	6	40	11	86	17	128
ANN3-output 1=sin(x)	7	34	13	66	18	110
ANN3-output 2=sin(3x)						

Tabel 1: Minimale hoeveelheid trainingsdata voor de verschillende ANN's (ANN1 en ANN2 met elk 1 output; ANN3 met 2 outputs) benodigd om de analytische functies ($\sin(x)$ en $\sin(3x)$) gedurende respectievelijk 1, 2 en 3 periodes met een maximale fout van 10^{-5} te kunnen benaderen.




Figuur 14: Illustratie van het minimaal benodigde aantal hidden nodes (links) en trainingsdata (rechts) om met de verschillende ANN's de analytische functies gedurende respectievelijk 1, 2 en 3 periodes met een maximale fout van 10^{-5} te benaderen.

Uit figuur 14 blijkt dat, ondanks meer hidden nodes, er minder trainingsdata nodig is voor de training van één netwerk met meerdere outputs dan voor meerdere netwerken met slechts één output. In het vervolg van de studie zal slechts één netwerk gebruikt worden met meerdere outputs. Een ander voordeel van het gebruik van slechts één netwerk is dat er ook maar één netwerk getraind hoeft te worden.

4 Vleugelprofiel ontwerp optimalisatie studie

Om de complexiteit van de analyses en de rektijden van de simulaties in de BWB ontwerpstudie te beperken, is eerst een ontwerptimalisatie uitgevoerd van een 2-D benadering van de 3-D BWB configuratie. De aërodynamisch meest relevante 2-D benadering van de BWB is het zogenaamde vleugelprofiel van de BWB. Een vleugelprofiel is een dwarsdoorsnede van een vleugel in het x-z vlak (vlak loodrecht op de vleugel-span-richting; figuur 15).



Figuur 15: Illustratie van de aërodynamisch meest relevante 2-D benadering van de BWB: het vleugelprofiel

Een vleugelprofiel kan gedefinieerd worden als een reeks (x,z) -coördinaten, en wordt meestal geschaald in de x-richting. Deze reeks kan gegenereerd worden met behulp van parametrische analytische functies, zodat hiermee geometrisch geparametriseerde vleugelprofielen beschreven kunnen worden. Deze parametrische functies kunnen met een beperkt aantal parameters een grote verzameling profielen beschrijven en zijn daardoor goed te gebruiken voor geometrische ontwerp variaties en optimalisatie.


In een aërodynamische ontwerp optimalisatie studie van een vleugelprofiel, wordt de geometrie zodanig gevarieerd dat de aërodynamische eigenschappen zoveel mogelijk automatisch geoptimaliseerd worden. Deze aërodynamische eigenschappen kunnen benaderd worden met behulp van een benaderingsmodel, bijvoorbeeld op basis van een ANN. Dit benaderingsmodel dient echter eerst getraind te worden met ‘echte’ data van de aërodynamische eigenschappen, bijvoorbeeld verkregen uit een parameterstudie met CFD berekeningen. In een dergelijke optimalisatie studie worden in grote lijnen de volgende stappen achtereenvolgens uitgevoerd:

1. Bepalen van geschikte geparametriseerde geometrische beschrijving van het vleugelprofiel
2. Bepalen van geschikte parameterranges voor gekozen parametrisatie
3. Definiëren van parameterstudie: welke parameters, welke waarden, welke resultaten
4. Genereren van invoer voor de CFD berekeningen (i.e. grid, randvoorwaarden etc.) voor elk ontwerp punt
5. Uitvoeren van CFD berekeningen

6. Trainen van ANN met behulp van dataset verkregen uit CFD berekeningen
7. Uitvoeren van optimalisaties met het ANN benaderingsmodel

4.1 Geometrische parametrisatie van het vleugelprofiel

Er is een verkennende studie uitgevoerd, waarin een drietal verschillende parametrische functies voor de beschrijving van de vleugelprofiel geometrie geëvalueerd zijn. De criteria die geëvalueerd zijn, zijn de kwaliteit van de benadering van het RAE2822 profiel (zie figuur 16), het minimale aantal parameters dat nodig is om een goede benadering hiervan te bereiken en de mogelijke geometrische variatie van de gegenereerde profielen.



Figuur 16: Standaard RAE2822 'test-profiel'

4.1.1 Lineaire deformatie van het standaard RAE2822 profiel (PAR1)

Een zeer eenvoudige parametrisatie is door uit te gaan van het standaard RAE2822 profiel (zie figuur 16) en hiervan de z-coördinaat te vermenigvuldigen met de parameterwaarde, zie functie (3).

$$\begin{aligned} Z_{low}(x) &= p_1 \cdot Z_{low_RAE}(x) \\ Z_{upp}(x) &= p_2 \cdot Z_{upp_RAE}(x) \end{aligned} \quad (3)$$

X representeert hier de X-coördinaat en Z de Z-coördinaat van het profiel. Een tweetal parameters, p1 en p2, wordt gebruikt voor de vermenigvuldiging van de onderkant (p1) en de bovenkant (p2) van het standaard RAE2822 profiel.

4.1.2 Parametrische wortelfuncties (PAR2)

Een beschrijving gebruik makend van wortelfuncties is gebruikt in de studie van S. de Kleermaeker [2]. Een hieraan verwante beschrijving is hier gebruikt, zie functie (4).

$$Z_{low} = \sum_{i=1}^m a_i \cdot (X^{i-0.5} - X^{m+0.5})$$

$$Z_{upp} = \sum_{i=1}^n b_i \cdot (X^{i-0.5} - X^{n+0.5})$$
(4)

Hierin zijn a en b de parameter arrays die het profiel beschrijven en zijn m en n het aantal elementen in deze arrays. De parameter arrays a en b kunnen van willekeurige lengte zijn. X representeert de X-coördinaat en Z de Z-coördinaat van het profiel.

4.1.3 Bezier curves (PAR3)


Een parametrisatie met Bezier curves [1] is gebaseerd op een polygoon, gedefinieerd door een aantal controle punten (b_i), die door de Bezier curve ‘gevolgd’ worden. De beschrijving van deze parametrisatie staat in functie (5).

$$0 \leq t \leq 1$$

$$p(t) = \sum_{i=0}^n b_i \gamma_i^n(t)$$

$$\gamma_i^n(t) = \binom{n}{i} (1-t)^{n-i} t^i$$
(5)

Hierin is n de graad van de Bezier curve. Deze is één minder dan de graad van de definiërende polygoon. Figuur 17 toont een, met deze parametrisatie beschreven, vleugelprofiel. Hierin is de stippellijn de polygoon die gedefinieerd wordt door de controle punten en de dichte lijn de bijbehorende Bezier curve (het vleugelprofiel).



Figuur 17: Vleugelprofiel beschreven door Bezier curves. De stippellijn is de beschrijvende polygoon.

4.2 Beoordeling van de verschillende parametrische functies

Voor het vervolg van de studie is het noodzakelijk dat de gekozen parametrisatie aan een aantal eigenschappen voldoet. Deze eigenschappen worden in de volgende paragrafen behandeld.

4.2.1 Benadering van het RAE2822 profiel

Aangezien het RAE2822 profiel een profiel is waar al veel onderzoek naar is gedaan en waarvan resultaten bekend zijn, is een eerste vereiste voor de gekozen parametrisatie dat dit profiel goed benaderd kan worden. Voor de verschillende parametrisaties is gezocht naar de beste parameter waarden voor de benadering van het RAE2822 profiel. Hiertoe wordt de fout in de benadering van het RAE2822 profiel geminimaliseerd (6), gebruik makend van ‘fminsearch’ uit de Optimization Toolbox van Matlab.

$$\min_{\vec{p}} f_{obj}(\vec{p})$$

$$f_{out} : \varepsilon = \sum_{i=1}^n ((Z_{upp_par}(x_i) - Z_{upp_RAE}(x_i))^2 + (Z_{upp_par}(x_i) - Z_{upp_RAE}(x_i))^2) \quad (6)$$

$$f_{obj} = \varepsilon$$


De resultaten voor de verschillende parametrisaties worden hieronder beschreven.

PAR1

Bij parametrisatie met behulp van PAR1 is het triviaal wat de meeste ideale parameters zijn om het standaard RAE2822 profiel te benaderen: $p_1=p_2=1$ en de fout is 0.

PAR2

In PAR2 is het mogelijk een willekeurig aantal parameters te gebruiken. Doel is zo weinig mogelijk parameters te gebruiken, waarbij het standaard RAE2822 profiel nog voldoende goed benaderd kan worden. Om het aantal benodigde parameters te bepalen is voor zowel het onder- als het bovenprofiel onderzocht wat de kleinst mogelijke kwadratische fout is in de benadering van het RAE2822 profiel bij verschillend aantal parameters. De grafieken in figuur 18 tonen de resultaten.



Figuur 18: Kleinste kwadratische fout in de benadering van het RAE2822 profiel met behulp van parametrisatie PAR2 en verschillend aantal parameters.



Voor de beschrijving van het onderprofiel blijkt het gebruik van meer dan 3 parameters geen significante verbetering op te leveren. Voor het bovenprofiel heeft het gebruik van meer dan 2 parameters weinig invloed. In het vervolg van de studie zal het onderprofiel daarom beschreven worden met 3 parameters en het bovenprofiel met 2 parameters. Een verklaring voor het feit dat er voor de beschrijving van het onderprofiel meer parameters nodig zijn, is dat het RAE2822-onderprofiel een buigpunt bevat.

Na optimalisatie blijken de volgende parameter arrays a en b de kleinste fout in de benadering van het RAE2822 profiel te geven.

$$a = [-0.1130 \quad -0.1484 \quad 0.6751]$$

$$b = [0.1271 \quad -0.0359]$$

De bijbehorende fout is: $6.1095 \cdot 10^{-5}$

PAR3

Ook bij het gebruik van Bezier curves moet het minimaal aantal benodigde parameters bepaald worden. Bij het gebruik van Bezier curves is bekend dat het aantal extremen dat de curve kan bevatten één minder is dan het aantal controle punten. Aangezien het RAE2822-bovenprofiel slechts één extreme bevat, zijn voor de parametrische beschrijving van het bovenprofiel twee parameters (b_{upp}) gebruikt. Het RAE2822-onderprofiel bevat 2 extremen en dus zijn voor de parametrische beschrijving van het onderprofiel drie parameters (b_{low}) gebruikt.

De controle punten (parameter waarden) die de kleinste fout in de benadering van het RAE2822 profiel geven zijn:

$$b_{low} = \begin{bmatrix} (-0.0124, -0.0462) \\ (0.5502, -0.1267) \\ (0.6117, 0.0098) \end{bmatrix}, \quad b_{upp} = \begin{bmatrix} (-0.0101, 0.0382) \\ (0.4431, 0.1193) \end{bmatrix}$$

De bijbehorende fout is: $2.8968 \cdot 10^{-5}$

Met alle parametrisaties is het dus mogelijk een vleugelprofiel te beschrijven dat voldoende overeenkomt met het standaard RAE2822 profiel.

4.2.2 Effectiviteit en benodigd aantal parameters

Behalve dat met de gekozen parametrisatie het standaard RAE2822 profiel benaderd moet kunnen worden, zijn er nog een aantal eigenschappen waaraan de geometrisch

geparametriseerde beschrijving van het vleugelprofiel in deze optimalisatie studie moet voldoen:

- a. Het aantal benodigde parameters moet bij voorkeur zo klein mogelijk zijn
- b. Voor de leading edge van het profiel ($x=0$) moet gelden: $\left(\frac{\delta z}{\delta x}\right) = \infty$
- c. Het profiel moet continu en differentieerbaar zijn, behalve in de trailing edge van het profiel ($x=1$)
- d. Boven- en onderprofiel mogen elkaar niet snijden en moeten beide van trailing edge (1,0) naar leading edge (0,0) lopen

Voor alledrie de parametrisaties is onderzocht of aan deze voorwaarden kan worden voldaan:

- ad. a. Een klein aantal parameters is noodzakelijk, omdat hiermee tijdens optimalisatie de zoekruimte waarin naar goede parameters wordt gezocht, beperkt blijft. Bij PAR1 is het aantal parameters 2 en bij PAR2 is het aantal parameters 5. Bij PAR3 is het aantal controle punten 5, maar elk controle punt wordt beschreven door zowel een x- als een z-coördinaat. Er zijn dus eigenlijk 10 parameters. Dit is ongunstig voor een goede parametrisatie.
- ad. b. Uit voorgaande onderzoeken is gebleken dat een airfoil een ‘platte’ verticale leading edge moet hebben. Ook de vleugelprofielen beschreven door een van de parametrisaties moeten hieraan voldoen. Voor de profielbeschrijvingen moet het volgende gelden:

$$\lim_{x \downarrow 0} \left(\frac{\delta z_{low}}{\delta x} \right) = -\infty$$

$$\lim_{x \downarrow 0} \left(\frac{\delta z_{upp}}{\delta x} \right) = +\infty$$

Bij PAR1 is dit automatisch het geval aangezien de, met deze parametrisatie beschreven, profielen allen lijken op het RAE2822 profiel, welke aan deze voorwaarde voldoet. Voor PAR2 is dit aangetoond in (7) en (8) onder de voorwaarde $a_1 < 0$ en $b_1 > 0$.

$$Z_{low} = \sum_{i=1}^m a_i \cdot (X^{i-0.5} - X^{m+0.5})$$

$$\frac{\delta z_{low}}{\delta x} = \sum_{i=1}^m a_i \cdot ((i-0.5) \cdot x^{i-1.5} - (m+0.5) \cdot x^{m+0.5}) \Rightarrow \lim_{x \downarrow 0} \left(\frac{\delta z_{low}}{\delta x} \right) = 0.5 \cdot a_1 \cdot x^{-0.5} \quad (7)$$

$$\lim_{x \downarrow 0} \left(\frac{\delta z_{low}}{\delta x} \right) = -\infty \text{ als } a_1 < 0$$

$$Z_{upp} = \sum_{i=1}^n b_i \cdot (X^{i-0.5} - X^{n+0.5})$$

$$\frac{\delta z_{upp}}{\delta x} = \sum_{i=1}^n b_i \cdot ((i-0.5) \cdot x^{i-1.5} - (n+0.5) \cdot x^{n+0.5}) \Rightarrow \lim_{x \downarrow 0} \left(\frac{\delta z_{upp}}{\delta x} \right) = 0.5 \cdot b_1 \cdot x^{-0.5} \quad (8)$$

$$\lim_{x \downarrow 0} \left(\frac{\delta z_{upp}}{\delta x} \right) = \infty \text{ als } b_1 > 0$$

Voor profielen beschreven met PAR3 is een platte leading edge niet te garanderen.

ad. c. PAR1 en PAR2 voldoen aan de eisen van continuïteit en differentieerbaarheid. De differentieerbaarheid in de leading edge van PAR3 is niet te garanderen.

ad. d. Voor elk profiel moet gelden: $Z_{upp} - Z_{low} \geq 0$. Elk nieuw profiel dat met een van de drie parametrisaties wordt beschreven moet hierop gecontroleerd worden.

4.2.3 Geometrische vrijheid

De geometrisch geparametriseerde beschrijving van het vleugelprofiel moet een zo groot mogelijke vrijheid hebben in de geometrische variatie van de profielen. Een grote vrijheid is gewenst, omdat van tevoren niet bekend is hoe een goed profiel eruit ziet. Bij PAR1 is deze vrijheid te beperkt, aangezien elk profiel lijkt op het standaard RAE2822 profiel. Bij PAR2 en PAR3 is deze vrijheid bij het gekozen aantal parameters voldoende.

4.2.4 Conclusies

Uit voorgaande paragrafen blijkt dat PAR2 de meest geschikte parametrisatie is om de vleugelprofielen mee te beschrijven. De voornaamste redenen zijn dat PAR1 een te beperkte geometrische vrijheid heeft en bij PAR3 een te groot aantal parameters nodig is en een platte leading edge en de differentieerbaarheid niet te garanderen zijn. In het vervolg van de optimalisatie studie is PAR2 gebruikt voor het beschrijven van de vleugelprofielen.

4.3 Doelfuncties

De aërodynamische eigenschappen van de vleugelprofielen, zoals die worden beschreven met PAR2, zijn met behulp van CFD berekeningen bepaald. De volgende CFD resultaten zijn in het vervolg van deze voorstudie gebruikt:

lift coëfficiënt (Cl)	dimensieloze coëfficiënt van de resulterende opwaartse kracht
drag coëfficiënt (Cd)	dimensieloze coëfficiënt van de resulterende weerstandskracht

In de optimalisatie van het vleugelprofiel dienen Cl en Cd geoptimaliseerd te worden. Dit komt overeen met het maximaliseren van de doelfunctie Cl/Cd. Aangezien in de BWB-studie het uiteindelijke doel is een multi-disciplinair en multi-objective optimalisatie te doen, is in de voorstudie een tweede te optimaliseren doelfunctie uit een andere discipline gekozen. Deze

doelfunctie is het oppervlak (Surface) van het vleugelprofiel, welke gemaximaliseerd dient te worden. De oppervlakte is gekozen, omdat deze in de eerste plaats makkelijk te benaderen is en in de tweede plaats een maat is voor het tankvolume in de 3-D vleugel.

4.4 Parameter studie

De parameter studie voor de parameters gebruikt in PAR2 bestaat uit het bepalen van de parameterranges, het bepalen van de invloed van de verschillende parameters op de doelfuncties en het bepalen of de ranges geschikt zijn voor het vervolg van de optimalisatie studie.

4.4.1 Parameterranges

De functies in (9) gelden voor de bepaling van de z-waarden als $m=3$ en $n=2$:

$$\begin{aligned} Z_{low} &= (a_1 + a_2 \cdot x + a_3 \cdot x^2 - (a_1 + a_2 + a_3) \cdot x^3) \cdot \sqrt{x} \\ Z_{upp} &= (b_1 + b_2 \cdot x - (b_1 + b_2) \cdot x^2) \cdot \sqrt{x} \end{aligned} \quad (9)$$

Het RAE2822 profiel is een profiel waar al veel experimenteel (windtunnel) en numeriek onderzoek naar is gedaan. Dit profiel wordt in deze studie als referentie profiel beschouwd. Om deze reden zijn de parameterranges rondom de parameters, die de benadering van het RAE2822 profiel representeren, bepaald. De parameterranges zijn gekozen volgens (10).

$$\begin{aligned} p_i &= \hat{p}_i \pm \delta p_i \\ \delta p_i &= 0.5 \cdot \hat{p}_i \end{aligned} \quad (10)$$

Hierin is \hat{p}_i de waarde van de betreffende parameter om het RAE2822 profiel te representeren en beschrijft δp_i de range rondom \hat{p}_i . Bij een gebruikte stapgrootte (Δ) van $\frac{1}{4}$ van de range waarin een parameter varieert kunnen $5^5=3125$ verschillende vleugelprofielen beschreven worden. Tabel 2 toont de \hat{p}_i en δp_i waarden, de onder – en bovengrenzen en de bijbehorende Δ voor de parameter arrays a en b.

p_i	\hat{p}_i	δp_i	ondergrens	bovengrens	Δ
a1	-0.1130	-0.0565	-0.1695	-0.0565	0.02825
a2	-0.1484	-0.0742	-0.2226	-0.0742	0.0371
a3	0.6751	1.01265	0.33755	1.01265	0.168775
b1	0.1271	0.19065	0.06355	0.19065	0.031775
b2	-0.0359	-0.01795	-0.05385	-0.01795	0.008975

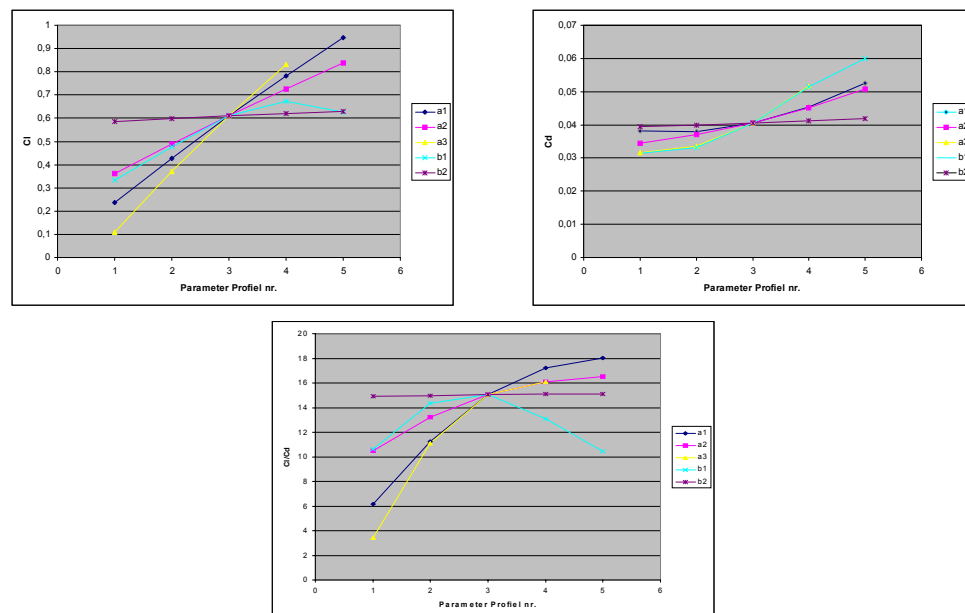
Tabel 2: \hat{p}_i en δp_i waarden, de onder – en bovengrenzen en de bijbehorende Δ voor de parameter arrays a en b.

Aangezien een profiel geen negatieve dikte mag hebben, zijn alle profielen hierop gecontroleerd. Na controle blijven er van de 3125 profielen nog 2199 over waarvoor CFD

berekeningen gedaan zijn. De CFD berekeningen worden in parallel op een cluster van werkstations uitgevoerd onder kruisvlucht vliegcondities met een $\text{Alpha} = 2.8$, $\text{Mach} = 0.73$, $\text{Re} = 6.5 \cdot 10^6$ en met het Cebeci-Smith turbulentiemodel (zie ter illustratie de Ensolv [9] invoer voor de vleugelprofiel CFD berekeningen in Appendix B).

4.4.2 Invloed van afzonderlijke parameters op Cl/Cd

Om de invloed van de verschillende parameters op de doelfunctie Cl/Cd te onderzoeken is elke parameter afzonderlijk gevarieerd binnen de gedefinieerde range en zijn de overige parameters constant gehouden aan de benaderingswaarden van het RAE2822 profiel. Figuur 19 toont de invloed op Cl en Cd afzonderlijk en op de doelfunctie Cl/Cd.




Figuur 19: Afzonderlijke invloed van de gebruikte parameters op Cl (linksboven), Cd (rechtsboven) en Cl/Cd (onder) bij een beschrijving van de vleugelprofielen met behulp van PAR2.

Uit de grafieken uit figuur 19 blijkt het volgende:

1. De parameters a1 en a3 hebben de meeste invloed op Cl/Cd.
2. De invloed van a3 en b1 op Cd is ongeveer gelijk.
3. De invloed van parameter b2 binnen de gedefinieerde range op Cl en Cd (en dus op Cl/Cd) is minimaal. De grafieken lopen zo goed als horizontaal.
4. Voor parameter a3 is bij het laatste profiel (nr. 5) geen bijbehorende Cl en Cd waarde gegeven. De reden hiervoor is dat het bijbehorende profiel incorrect en dus afgekeurd is.

Figuur 19 toont de invloed van de verschillende parameters op de doelfunctie als deze gevarieerd worden binnen de gedefinieerde range. Nu is onderzocht wat de invloed van de verschillende parameters is in een bredere range. De parameters zijn gevarieerd tussen -0.5 en

0.5 (alleen de range van a_3 loopt tot 0.7). Opnieuw zijn de overige parameters constant gehouden aan de benaderingswaarden van het RAE2822 profiel. De invloed op Cl/Cd van de verschillende parameters in een bredere range is te zien in figuur 20. In de figuur staan voor de verschillende parameters ook de benaderingswaarden van het RAE2822 profiel afgebeeld.




Figuur 20: Afzonderlijke invloed van de gebruikte parameters in een bredere range op Cl/Cd bij een beschrijving van de vleugelprofielen met behulp van PAR2. De kruisjes (IdealeParms) tonen de parameterwaarden voor de benadering van het RAE2822 profiel.

Uit figuur 20 blijkt:

1. Een aantal profielen in de onderzochte range worden afgekeurd.
2. De benaderingswaarden van het RAE2822 profiel van de verschillende parameters (in figuur 20 aangegeven met IdealeParms) zijn allemaal te vinden rond het maximum van de grafieken. De vastgestelde parameterranges zijn dus correct gekozen, aangezien deze zich rondom de benaderingswaarden en dus maxima van de grafieken bevinden.

4.4.3 Invloed van twee parameters op de doelfuncties

Er is onderzocht wat de invloed is van de verschillende parameters op de doelfunctie Cl/Cd als er slechts één parameter variabel is en de overige parameters constant gehouden worden. Nu is onderzocht wat de invloed is van twee variabele parameters binnen de gekozen parameterranges op beide doelfuncties. Uit de vorige paragraaf is gebleken dat de parameters a_1 en a_3 de meeste invloed hebben op de doelfunctie Cl/Cd . Deze parameters worden variabel gekozen en figuur 21 toont de invloed van deze parameters op beide doelfuncties in parameter ruimte en in doelfunctie ruimte. De overige parameters zijn weer constant gehouden aan de benaderingswaarden van het RAE2822 profiel.



Figuur 21: Invloed van de parameters a_1 en a_3 op de doelfuncties Cl/Cd (links) en $Surface$ (midden) gepresenteerd in parameter ruimte en in doelfunctie ruimte (rechts).


Uit de parameter ruimte grafieken uit figuur 21 blijkt:

1. In het gebied met grote a_1 en a_3 waarden worden ongeldige profielen gegenereerd. De doelfuncties zijn hier gelijk aan nul.
2. Beide doelfuncties vertonen een vrij glad verloop.
3. De doelfunctie Cl/Cd neemt toe naarmate de a_1 en a_3 parameterwaarden toenemen.
4. De doelfunctie $Surface$ neemt toe naarmate de a_1 en a_3 parameterwaarden afnemen.

Uit de punten 3 en 4 blijkt dat de invloed van de parameters a_1 en a_3 op de doelfuncties tegenstrijdig is. Optimalisatie van beide doelfuncties komt dus niet overeen met het zoeken naar het maximum van beide doelfuncties, maar met het zoeken naar het Pareto front. Dit blijkt ook uit de doelfunctie ruimte grafiek uit figuur 21 waarin beide doelfuncties tegen elkaar zijn uitgezet. Naarmate de $Surface$ toeneemt, neemt Cl/Cd af.

4.4.4 Invloed van alle parameters op de doelfuncties

Er is onderzocht wat de invloed van de twee meest invloedrijke parameters is op de doelfuncties, maar uiteindelijk zal het vleugelprofiel geoptimaliseerd worden waarbij alle parameters variabel zijn. Als alle parameters variabel zijn, kunnen de 2199 geldige vleugelprofielen worden beschreven. De invloed van deze variaties op de doelfuncties is door de omvang niet in parameter ruimte te illustreren. Figuur 22 illustreert de invloed op de doelfuncties in de doelfunctie ruimte.



Figuur 22: Invloed van alle parameters op de doelfuncties Cl/Cd en Surface gepresenteerd in de doelfunctie ruimte. Ook de ligging van het RAE2822 profiel is aangegeven.

Ook bij het variëren van alle parameters blijkt uit figuur 22 dat een optimaal parameterprofiel niet zowel een maximale Cl/Cd als een maximale Surface kan hebben.

De waarden behorende bij het RAE2822 profiel zijn:

Surface= 0.078057

$Cl/Cd = 15.29851$

Dit punt staat aangegeven in figuur 22 en blijkt, als er slechts naar deze twee doelfuncties gekeken wordt, niet Pareto-optimaal te zijn: het punt bevindt zich niet op het Pareto front.

4.4.5 Conclusies

Uit de parameter studie voor de beschrijving van vleugelprofielen met PAR2 is het volgende gebleken:

1. De gedefinieerde parameterranges zijn correct.
2. De parameters a_1 en a_3 hebben de meeste invloed op de doelfuncties.
3. De doelfuncties zijn tegenstrijdig en er bestaat niet slechts één optimaal vleugelprofiel.
4. Het RAE2822 profiel is bij het gebruik van deze doelfuncties niet optimaal.

4.5 Vleugelprofiel optimalisatie met twee variabele parameters

De eerder verkregen resultaten zijn gebruikt voor de optimalisatie van de vleugelprofielen. In eerste instantie is met de resultaten van de profielen met de twee variabele parameters (a_1 en a_3) een ANN getraind en geoptimaliseerd. Vervolgens is dit gedaan voor de profielen waarbij alle parameters variabel zijn.

4.5.1 ANN instellingen

De doelfunctie waarden behorende bij de verschillende parameterprofielen is gebruikt om het ANN te trainen. Voor de training van het neurale netwerk met twee inputs (a_1 en a_3) en twee outputs (Cl/Cd en Surface) zijn de volgende instellingen gebruikt:

Soort netwerk: Feed Forward, Back propagation

Trainingsmethode: Levenberg-Marquardt

Aantal hidden layers: 1

Aantal hidden nodes: 5

Transfer functie hidden layer: Log-Sigmoid


Transfer functie output layer: Lineair

Van de 331 verschillende parameterprofielen zijn er 200 gebruikt voor de training, 75 voor de validatie en 50 voor de controle. De training van het netwerk is gedaan met genormaliseerde in- en output. Na training heeft het ANN een gemiddelde kwadratische fout in de orde 10^{-5} om de onderliggende functie te benaderen. Het netwerk is dus in staat om de functie te benaderen.

Het getrainde netwerk is nu in staat om de doelfuncties (Cl/Cd en Surface) bij een willekeurig parameterprofiel te benaderen. Doel is een zo goed mogelijk profiel te genereren. Een optimaal profiel zou een maximale Surface en een maximale Cl/Cd hebben, maar zoals gebleken zijn dit tegenstrijdige doelfuncties. Tijdens optimalisatie is het Pareto front bepaald. Alle op het Pareto front liggende profielen zijn Pareto-optimaal.

4.5.2 GM optimalisatie

In de GM optimalisatie zijn de Pareto punten uit de trainingsset gebruikt als startpunten. Deze worden geoptimaliseerd gebruik makend van 'fminsearch' uit de Optimization Toolbox van Matlab [7]. In de optimalisatie is de zoekruimte beperkt door de parameterwaarden. Dit omdat niet bekend is hoe het netwerk reageert ver buiten de gebruikte parameterranges. Het Pareto front is gezocht binnen de opgegeven grenzen voor elke parameter. Figuur 23 toont het Pareto front bij het gebruik van grenzen die 10 procent buiten de parameterranges liggen en het Pareto front zonder het gebruik van grenzen. Ook is de ligging van het RAE2822 profiel aangegeven. De rechter grafiek toont de bijbehorende parameter waarden.




Figuur 23: GM vleugelprofiel optimalisatie resultaten met twee variabele ontwerp parameters met en zonder begrenzing van de parameters in de doelfunctie ruimte (links) en in de parameter ruimte (rechts). De pijl illustreert de ligging van het RAE2822 profiel.

Uit figuur 23 blijkt dat het benaderde Pareto front zonder dat de parameters begrensd zijn, vooral bij grotere Surface waarden, beter is dan het benaderde Pareto front waarbij de parameters wel begrensd zijn. Er zou dus geconcludeerd kunnen worden dat de gebruikte parameterranges niet optimaal zijn. Echter in het gebied rond het RAE2822 profiel ligt het Pareto front wel binnen de parameterranges. Verder is niet duidelijk in hoeverre het neurale netwerk bij deze extreme extrapolatie in staat is de doelfuncties correct te benaderen.

4.5.3 Resultaten GM versus GA

Ook het GA is gebuikt om te optimaliseren. Een vergelijking van de GM resultaten met de GA resultaten staat in figuur 24. In beide optimalisaties zijn de parameters begrensd.




Figuur 24: Vergelijking van GM en GA vleugelprofiel optimalisatie resultaten met twee variabele ontwerp parameters en 10% grenzen op de parameters in de doelfunctie ruimte (links) en in parameter ruimte (rechts).

Beide methoden vinden vergelijkbare Pareto punten in de doelfunctie ruimte. In de parameter ruimte vertonen de GA Pareto punten een grotere spreiding. Deze spreiding kan ontstaan door vlakke doelfuncties in de buurt van het Pareto front.

4.5.4 Verificatie van ANN benadering in optimalisatie

De nauwkeurigheid van de ANN benadering van de Pareto punten wordt geverifieerd door het uitvoeren van nauwkeurige CFD berekeningen voor deze punten. Figuur 25 toont een vergelijking tussen de ANN benadering en de nauwkeurige CFD resultaten voor de begrensde en onbegrensde GM Pareto punten.



Figuur 25: Vergelijking van de ANN benaderingen en nauwkeurige CFD berekeningen van de GM Pareto punten met 10% grenzen (links) en zonder grenzen (rechts) op de parameters.

Voor de begrensde Pareto punten komen de CFD resultaten goed overeen met de gevonden benaderingen door het ANN. Zonder de opgegeven grenzen is het ANN vooral bij grote Surface waarden niet meer in staat om de doelfuncties goed te benaderen. Dit komt door een te grote extrapolatie.

4.6 Vleugelprofiel optimalisatie met vijf variabele parameters

Na de optimalisatie met twee variabele parameters zijn nu alle vijf de ontwerp parameters variabel. De genomen stappen zijn gelijk aan die bij twee variabele parameters.

4.6.1 ANN instellingen

Voor de training van het neurale netwerk met vijf inputs en twee outputs zijn de volgende instellingen gebruikt:

Soort netwerk: Feed Forward, Backpropagation

Trainingsmethode: Levenberg-Marquardt

Aantal hidden layers: 1

Aantal hidden nodes: 10


Transfer functie hidden layer: Log-Sigmoid

Transfer functie output layer: Lineair

Van de 2199 verschillende parameterprofielen zijn er 750 gebruikt voor de training, 350 voor de validatie en 225 voor de controle. De training van het netwerk is gedaan met genormaliseerde in- en output. Na training heeft het neurale netwerk een gemiddelde kwadratische fout in de orde 10^{-4} om de onderliggende functie te benaderen. Het netwerk is dus in staat om de functie te benaderen.

4.6.2 GM optimalisatie

Ook bij vijf variabele parameters is het Pareto front bepaald. De Pareto punten uit de trainingsset zijn gebruikt als startpunten. Ook bij deze optimalisaties zijn grenzen voor de parameters opgegeven waarbinnen geoptimaliseerd is. Figuur 26 toont de Pareto fronten bij verschillende parameter grenzen in doelfunctie ruimte. Het percentage geeft aan hoever de grenzen buiten de gebruikte parameter ranges liggen. Ook is in de figuur aangegeven waar het RAE2822 profiel zich bevind.




Figuur 26: GM vleugelprofiel optimalisatie resultaten met vijf variabele ontwerp parameters en verschillende grenzen op de parameters in de doelfunctie ruimte. Ook is de ligging van het RAE2822 profiel aangegeven.

Uit figuur 26 blijkt dat het voor de optimalisaties in het gebied rond het RAE2822 profiel niet uitmaakt welke grenzen gebruikt worden. De trainingsset is in dit gebied erg volledig en de optimalisaties verlopen goed. Dit is waarschijnlijk ook het meest interessante gebied. Bij grote Surface waarden zijn de optimalisatie resultaten heel afhankelijk van de gekozen grenzen. Enkele parameters lopen in dit gebied tegen de grenzen aan.

4.6.3 Resultaten GM versus GA

Voor de optimalisatie van de vleugelprofielen, waarbij 5 parameters variabel zijn, is ook gebruik gemaakt van het GA. Een vergelijking van de GM en GA resultaten in de doelfunctie ruimte met 10% grenzen staat in figuur 27.



Figuur 27: Vergelijking van GM en GA vleugelprofiel optimalisatie resultaten met vijf variabele ontwerp parameters en 10% grenzen op de parameters in de doelfunctie ruimte.

Uit de figuur blijkt dat de GM resultaten beter zijn dan de GA resultaten. Dit is voornamelijk te verklaren door het groter aantal ontwerp parameters in deze optimalisatie. Om met GA optimalisatie kwalitatief vergelijkbare resultaten te verkrijgen is een groter aantal generaties nodig.

4.6.4 Verificatie van ANN benadering in optimalisatie

De nauwkeurigheid van de ANN benadering in de optimalisatie is geverifieerd voor de GM Pareto punten met 10% grenzen. Voor deze punten zijn nauwkeurige CFD berekeningen uitgevoerd en de ANN benadering van deze punten blijkt in het gebied rond het RAE2822 profiel erg nauwkeurig te zijn. In het gebied bij grote Surface waarden, daar waar ook geen goed Pareto front gevonden is, is de benadering minder nauwkeurig.

4.7 Conclusies

Uit de resultaten van de vleugelprofiel optimalisaties met twee of vijf variabele parameters kunnen de volgende conclusies getrokken worden:

- Het standaard RAE2822 profiel is vrij goed, aangezien het vrij dicht bij het Pareto front ligt, maar kan verbeterd worden.
- De doelfuncties in de buurt van het Pareto front zijn vrij glad. Hierdoor is er in de parameter ruimte een vrij grote spreiding in de GA Pareto punten.
- De gebruikte parameterranges zijn niet in de gehele doelfunctie ruimte optimaal. Alleen in het gebied rond het RAE2822 profiel bevindt het Pareto front zich binnen de gebruikte ontwerp parameterranges.
- Bij het gebruik van meerdere variabele ontwerp parameters zijn voor een goede GA optimalisatie meer generaties nodig.

Vleugelprofielen zijn succesvol geoptimaliseerd met GM of GA en het gebruik van ANN benaderingsmodellen. Een soortgelijke optimalisatie studie is gedaan voor blended-wing-body vliegtuigconfiguraties.

5 Multi-disciplinaire ontwerp optimalisatie van een BWB vliegtuigconfiguratie

Om de blended-wing-body optimalisaties te kunnen doen moet eerst de gewenste ontwerpstudie gedefinieerd worden. De hier uitgevoerde ontwerpstudie betreft een oriënterende voorontwerpstudie van de BWB. In deze studie worden bepaalde belangrijke eigenschappen van de BWB geëvalueerd en geoptimaliseerd onder bepaalde vliegcondities. Hierbij worden bepaalde geometrische ontwerpparameters gevarieerd. De geometrische variatie van de BWB wordt gedefinieerd door een geschikte geometrische parametrisatie, een nauwkeurig gedefinieerde referentie BWB geometrie, en variaties van bepaalde wezenlijke parameters ten opzichte van de referentie geometrie.

5.1 Referentie BWB geometrie

De BWB referentie geometrie is een binnen het MOB project [6] nauwkeurig gedefinieerde geometrie die als basis dient voor deze studie.

5.2 Geometrische parametrisatie


In deze BWB voorontwerpstudie zijn de volgende ontwerpparameters gebruikt voor de geometrisch geparametriseerde beschrijving van de BWB's:

Twist: de torsie rond de y-as van de vleugel ten opzichte van de referentie geometrie.

Sweep: de rotatiehoek rond de z-as van de vleugel ten opzichte van de referentie geometrie

Alpha: de invalshoek van de luchtstroming op het vliegtuig.


De opgegeven hoeken voor Twist en Sweep worden, volgens vastgelegde verdeling, verdeeld over de drie delen van de vleugel (inner-wing-inside, inner-wing-outside, outer-wing) en veroorzaken een geometrische verandering. Alpha daarentegen verandert de geometrie niet, maar is een variatie van de invalshoek van de luchtstroming op de gehele geometrie. Figuur 28 illustreert de parameters en de variaties ten opzichte van de referentie geometrie.



Figuur 28: Illustratie van de gebruikte ontwerpparameters twist, sweep, en hoek alpha en de toegepaste variaties (in graden) in de BWB voorontwerpstudie.

Figuur 29 toont de gekozen waarden van Twist en Sweep in de parameter ruimte: 7 waarde voor Twist en 12 waarden voor Sweep. Elk punt vertegenwoordigt dus een andere BWB geometrie.

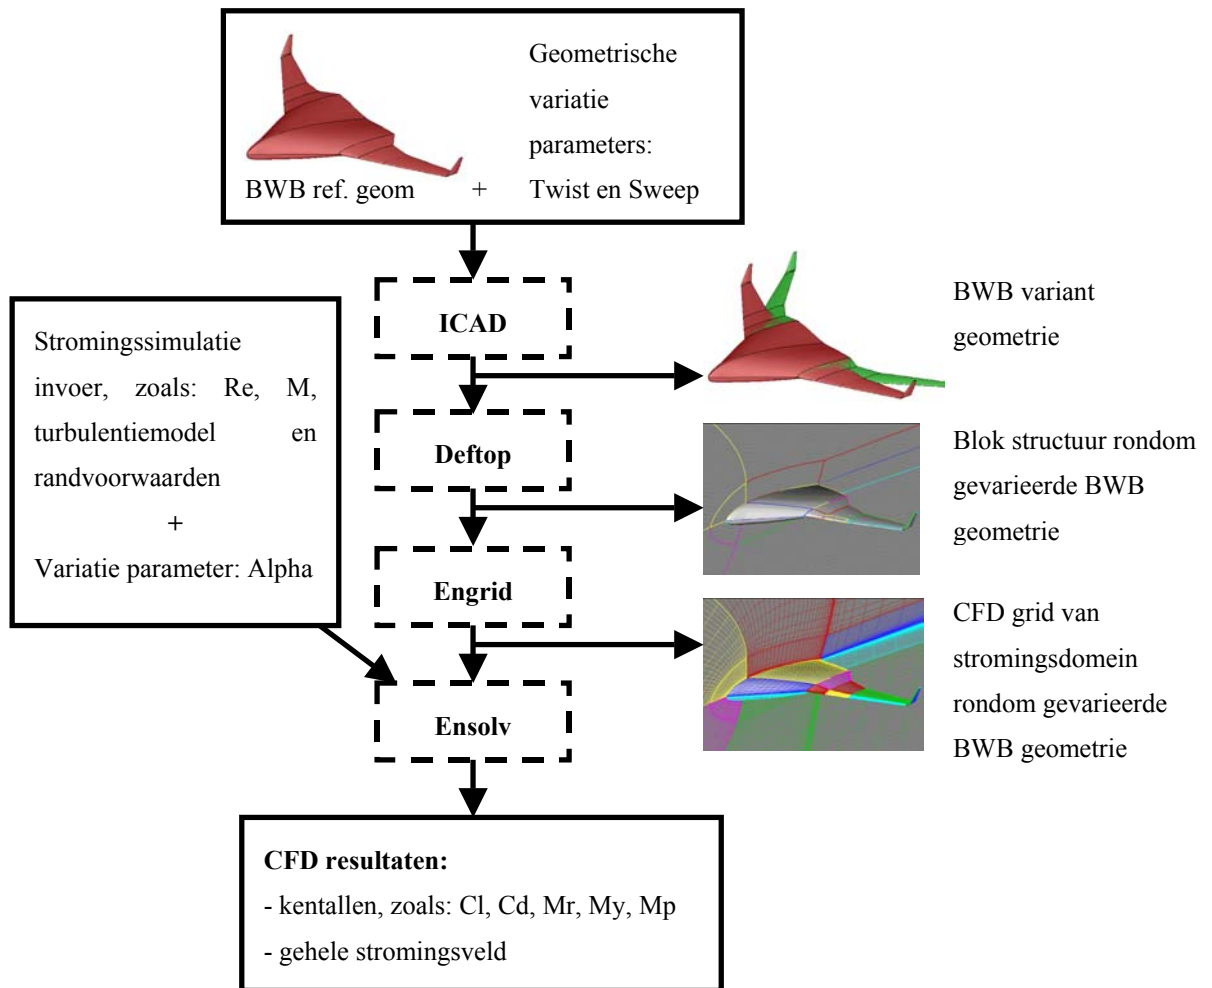
Voor al deze geometrieën worden stromingssimulaties uitgevoerd voor elk van de vier waarden van alpha.



Figuur 29: Illustratie in de parameter ruimte van de gekozen waarden van de ontwerpparameters Twist en Sweep in de BWB voorontwerpstudie.

5.3 Software tools

Het neurale netwerk dat gebruikt wordt tijdens de optimalisatie wordt getraind met de ontwerpparameters en bijbehorende CFD resultaten. Het verkrijgen van deze CFD resultaten vereist een aantal stappen waar verschillende software pakketten bij nodig zijn. Figuur 30 illustreert het proces dat doorlopen wordt om van de ontwerpparameters naar de CFD resultaten te komen. In het MOB project [6] is een zogenaamde computational design engine (CDE) ontwikkeld waarmee eenvoudige toegang tot de ontwerp en analyse tools voor BWB ontwerp mogelijk is [11, 12]. Het SPINeware middleware systeem [14] is hierbij gebruikt voor de ontwikkeling van een uniforme netwerktransparante werkomgeving [10].



Figuur 30: Illustratie van het rekenproces, zoals uitgevoerd in de BWB voorontwerpstudie.

De volgende paragrafen geven een beknopte beschrijving van de verschillende software pakketten en de instellingen zoals deze in de BWB studie gebruikt zijn.


5.3.1 ICAD

ICAD is een CAD pakket dat wordt gebruikt voor de berekening van de BWB geometrieën bij de verschillende parameter instellingen (Twist en Sweep). Deze berekeningen worden uitgevoerd op een server van de TU Delft.

5.3.2 Endomo en Deftop

De gevarieerde 3-D BWB geometrie uit ICAD wordt gebruikt om het stromingsdomein rondom de BWB exact om deze geometrie heen te passen. Hiertoe is het stromingsdomein rondom de referentie BWB geometrie eerst eenmalig handmatig met de “domain modeler” Endomo in een aantal 3-D blokken verdeeld. Vanwege de symmetrie van de BWB in het x-z vlak gebeurt dit

slechts rondom de halve geometrie. Deze referentie blokstructuur wordt vervolgens met het programma Deftop automatisch gedeformeerd zodat deze precies rondom de veranderde geometrie past. Figuur 31 toont een deel van de blokstructuur rondom de referentie BWB geometrie, welke in totaal 32 blokken bevat.




Figuur 31: Blokstructuur rondom BWB geometrie.

5.3.3 Engrid

Aan de hand van de blokstructuur rondom de BWB en een aantal grid instellingsparameters genereert de CFD grid generator Engrid een grid in het stromingsdomein rondom de BWB. Engrid is onderdeel van het NLR CFD systeem Enflow. De nauwkeurigheid van het grid rondom een geometrie kan met behulp van grid parameters ingesteld worden. Met de gekozen instellingen wordt een fijn grid (level 3) gegenereerd waarmee nauwkeurige CFD berekeningen gedaan kunnen worden. Deze nauwkeurige CFD berekeningen blijken te rekenintensief en te tijdrovend te zijn. Om deze reden wordt het grid getransformeerd naar een grover niveau (level 2). In elke dimensie wordt zo het aantal cellen gehalveerd.

Voor de BWB geometrieën is, bij de gekozen instellingen, het totaal aantal cellen in het fijne grid (level 3) gelijk aan 552960. In het grovere grid (level 2) is het aantal cellen 69120 (figuur 32).




Figuur 32: CFD grid (level 2) rondom BWB geometrie.

5.3.4 Ensolv

Met het grid rondom de BWB geometrie, wordt het NLR CFD pakket Ensolv gebruikt voor de berekening van de oplossing van de Navier Stokes vergelijkingen. Deze CFD berekeningen worden uitgevoerd op starre ongetrimde BWB geometrieën in kruisvlucht. Op deze manier zijn de resultaten het best met elkaar te vergelijken. Alle CFD berekeningen worden in parallel uitgevoerd voor een bepaalde alpha en onder kruisvlucht vliegcondities met Mach = 0.85, Re = $82.0 \cdot 10^6$ en met het k- ω turbulentiemodel (zie ter illustratie de Ensolv [9] invoer voor de BWB CFD berekeningen in Appendix B).

De BWB referentie geometrie wordt 1000 iteraties doorgerekend en de stromingsoplossing hiervan wordt gebruikt als beginschatting voor de CFD berekening van alle variant geometrieën. Resultaten van het druk coëfficiënt veld volgend uit de CFD berekeningen van de referentie BWB in kruisvlucht zijn gegeven in figuur 33. De variant geometrieën worden vanuit die beginschatting nog eens 200 iteraties verder doorgerekend.



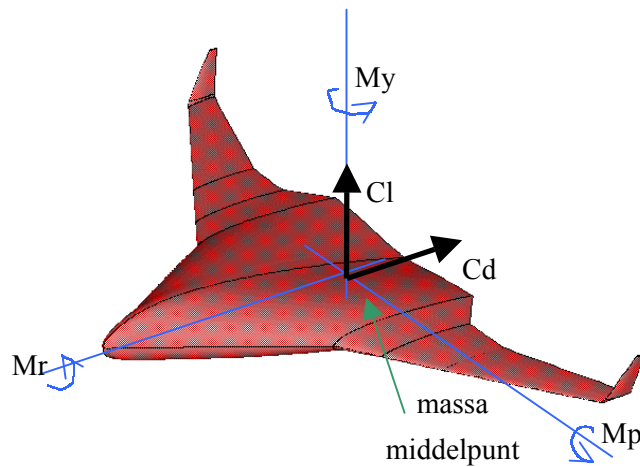
Figuur 33: C_p waarden op het oppervlak van de referentie BWB tijdens kruisvlucht

De volgende CFD resultaten worden in het vervolg van de studie gebruikt:

lift coëfficiënt (Cl)	dimensieloze coëfficiënt van de resulterende opwaartse kracht
drag coëfficiënt (Cd)	dimensieloze coëfficiënt van de resulterende weerstandskracht
pitching moment (Mp)	dimensieloze coëfficiënt van het resulterende duik moment in het massamiddelpunt
roll moment (Mr)	dimensieloze coëfficiënt van het resulterende rol moment in het massamiddelpunt
yaw moment (My)	dimensieloze coëfficiënt van het resulterende draai moment in het massamiddelpunt

N.B. De roll en yaw momenten in deze simulaties van de halve BWB geometrie in kruisvlucht (symmetrie in het x-z vlak) worden geneutraliseerd door de andere helft van de BWB, dus hebben voor de gehele BWB geen resultante die gecompenseerd moet worden met stuuracties.

Figuur 34 illustreert de betekenis van deze grootheden.



Figuur 34: Illustratie van de gebruikte CFD grootheden C_l , C_d , M_p , M_r en M_y in de BWB voorontwerpstudie.

5.4 ANN instellingen

De verkregen dataset wordt gebruikt voor de training van het neurale netwerk. Dit netwerk zal tijdens optimalisatie gebruikt worden als benaderingsmodel van de CFD berekeningen.

De volgende instellingen worden gebruikt bij de training van het neurale netwerk:

Soort netwerk:	Feed Forward, Back propagation
Trainingsmethode:	Levenberg-Marquardt
Aantal hidden layers:	1
Aantal hidden nodes:	10
Transfer functie hidden layer:	Log-Sigmoid
Transfer functie output layer:	Lineair
Aantal inputs:	3 (Twist, Sweep, Alpha)
Aantal outputs:	5 (C_l , C_d , M_p , M_r , M_y)

Gebruik makend van deze instellingen is het netwerk in staat om de onderliggende functie met een kleine fout ($MSE < 0.001$) te benaderen.

5.5 BWB optimalisaties

Het doel is om een aantal eigenschappen van de BWB te optimaliseren. Tijdens dit optimalisatie proces wordt het getrainde neurale netwerk gebruikt voor de benadering van waarden van deze eigenschappen.

Alvorens de optimalisatie plaats kan vinden dienen de te optimaliseren doelfuncties gedefinieerd te worden. In deze voorontwerpstudie zijn de volgende te minimaliseren doelfuncties gekozen (11).

$$\begin{aligned}
 Cdl &= \frac{Cd}{Cl} \\
 Mt &= \sqrt{Mr^2 + My^2} \\
 MpA &= |Mp|
 \end{aligned}
 \tag{11}$$


Deze doelfuncties kunnen allen afgeleid worden uit de CFD resultaten. De waarden ervan representeren echter eigenschappen van de BWB die relevant zijn in verschillende disciplines:

- Cdl representeert de *aërodynamische* prestatie van de BWB
- Mt representeert het *mechanische* buigende moment in het massamiddelpunt ten gevolge van aërodynamische krachten die gedragen moeten worden door de BWB constructie
- MpA representeert het voor de *vlieg mechanica* relevante resulterende duikmoment

Uit voorgaande studies is gebleken dat een neurale netwerk slechte resultaten geeft bij extrapolatie. Extrapolatie tot 10% buiten de parameter ranges wordt hier echter nog als toelaatbaar beschouwd. Deze grenzen worden gebruikt in beide optimalisatie methoden.


5.5.1 GM optimalisatie

Bij het optimaliseren met behulp van GM worden als startpunten de Pareto punten uit de trainingsset genomen mits deze niet te dicht bij elkaar liggen. Deze punten worden geoptimaliseerd en het dan gevonden Pareto front is te zien in figuur 35. De punten van het Pareto front liggen in een gekromd vlak in de 3-D doelfunctie ruimte. Voor de duidelijkheid zijn ook de projecties van de gevonden Pareto punten in de Cdl – Mt en Cdl – MpA vlakken weergegeven.



Figuur 35: Resulterende Pareto front van de GM run voor de BWB ontwerp studie gepresenteerd in de 3-D doelfunctie ruimte (links) en geprojecteerd in de Cdl-Mt en Cdl-MpA vlakken (midden en rechts, resp.).

Projecties in de Alpha – Twist en Alpha – Sweep vlakken van de ontwerpparameters behorende bij de gevonden Pareto punten zijn te zien in figuur 36.




Figuur 36: Projecties van de 3-D ontwerpparameters in de Alpha – Twist (links) en Alpha – Sweep (rechts) vlakken behorende bij de Pareto punten na GM optimalisatie (figuur 35).

5.5.2 GA optimalisatie

Bij de optimalisatie met behulp van GA worden de volgende instellingen gebruikt:

Aantal generaties:	100
Populatie grootte:	100
Crossover kans:	0.7
Aantal Crossover punten:	2
Selectie proces:	Tournament
Tournament grootte:	2

Tijdens de optimalisatie kan verder nog gebruik gemaakt worden van Niching en Mating. Figuur 37 toont de verschillende Pareto fronten gevonden door het GA, waarbij wel of geen Niching en Mating wordt toegepast.




Figuur 37: Resulterende Pareto fronten van de GA runs voor de BWB ontwerp studie gepresenteerd in de 3-D doelfunctie ruimte, waarbij Niching en Mating resp. niet (links), op de doelfuncties (midden) en op de parameters (rechts) wordt toegepast.

De Pareto punten die bij GA optimalisatie gevonden worden zonder gebruik te maken van Niching en Mating tonen een zeer beperkte spreiding (figuur 37 links). Spreiding tussen de

Pareto punten is echter wel gewenst en daarom is Niching en Mating toegepast. Bij toepassing van Niching en Mating op de doelfuncties (figuur 37 midden) en op de parameters (figuur 37 rechts) is de spreiding goed. In het vervolg van de studie is gekozen voor het toepassen van Niching en Mating op de parameters, aangezien een spreiding in ontwerpparameters ook gewenst is ten behoeve van de variatie binnen de opeenvolgende populaties van ontwerpen tijdens de GA iteratie.


Projecties in de Alpha – Twist en Alpha – Sweep vlakken van de ontwerpparameters behorende bij de gevonden Pareto punten, waarbij Niching en Mating op de parameters is toegepast, zijn te zien in figuur 38.




Figuur 38: Projecties van de 3-D ontwerpparameters in de Alpha – Twist (links) en Alpha – Sweep (rechts) vlakken behorende bij de Pareto punten na GA optimalisatie met Niching en Mating op de parameters (figuur 37 rechts).

5.5.3 Resultaten GM versus GA

Een vergelijking van de door het GM en GA gevonden Pareto front in de doelfunctie ruimte staat in figuur 39. In deze figuur is ook de ligging van de referentie BWB aangegeven. Een vergelijking in de parameter ruimte staat in figuur 40.



Figuur 39: Vergelijking van GM en GA BWB optimalisatie resultaten in de doelfunctie ruimte geprojecteerd in de Cdl-Mt (links) en Cdl-MpA (rechts) vlakken. De groene ster illustreert de ligging van de referentie BWB en de pijl toont de ligging van de enigszins willekeurig gekozen optimale geometrie.



Figuur 40: Vergelijking van GM en GA BWB optimalisatie resultaten in de parameter ruimte geprojecteerd in de Alpha – Twist (links) en Alpha – Sweep (rechts) vlakken. De pijl toont de ligging van de enigszins willekeurig gekozen optimale geometrie.

Uit figuur 39 blijkt dat er vergelijkbare Pareto fronten worden gevonden door GM en GA. Ook de bijbehorende ontwerpparameters bedekken hetzelfde gebied, maar vertonen toch enige afwijking (figuur 40). De oorzaken hiervan liggen vooral aan de kant van het GA. Door ‘vlakke doelfuncties’ in de buurt van het Pareto front en door het gebruik van Niching en Mating op de parameters is de spreiding tussen de Pareto punten in de parameter ruimte groter dan bij GM.

Verder blijkt uit figuur 40 dat een aantal Pareto punten die gevonden worden door het GM zich tegen de bovengrens van de Sweep parameter bevinden. Dit zou kunnen betekenen dat verder optimaliseren in die richting zinvol is.

5.6 Verificatie van ANN benadering in optimalisatie

Om de correctheid van de benadering met behulp van ANN te verifiëren wordt uit de, door het GA gevonden, Pareto punten een zo gunstig mogelijk punt geselecteerd waarmee een exacte CFD simulatie wordt uitgevoerd. Er is hier gekozen voor een punt met een zo laag mogelijke C_{dI} waarde, waarbij bovendien nog redelijk lage waarden voor M_{pA} en M_t geldig zijn. Deze keuze is echter enigszins arbitrair en zou in de praktijk door ervaren ontwerpers genomen moeten worden op basis van extra overwegingen, zoals bijvoorbeeld constructie eigenschappen, productie aspecten, haalbaarheid van het ontwerp, etc.. Het gekozen punt is in de doelfunctie ruimte (figuur 39) en parameter ruimte (figuur 40) aangegeven met de pijl.

In tabel 3 staan de parameterwaarden, de bijbehorende doelfunctie waarden en het procentuele verschil tussen de ANN benadering en de exacte CFD berekening voor de gekozen ‘optimale’ BWB. Ter vergelijking staan ook de doelfunctie waarden van de referentie BWB en de procentuele verandering van de gekozen ‘optimale’ BWB ten opzichte van de referentie BWB vermeld.



	Opt. BWB		Opt. BWB (ANN)	Opt. BWB (CFD)	% verschil ANN tov. CFD	Ref. BWB (CFD)	% verandering Opt. tov. Ref.
Twist	-1.7894	Cdl	0.0741	0.0734	0.9537	0.0812	-8.7438
Sweep	12.8252	Mt	0.4334	0.4330	0.0924	0.4670	-7.1949
Alpha	7.7631	MpA	0.0715	0.0712	0.4213	0.0485	+47.4227

Tabel 3: Vergelijking van doelfunctie waarden van de 'optimale' en referentie BWB.

Uit de tabel blijkt dat het neurale netwerk een goede benadering geeft van de exacte CFD resultaten. Verder blijkt de gekozen 'optimale' BWB een verbetering in de Cdl en Mt waarden en een verslechtering in de MpA waarde ten opzichte van de referentie BWB op te leveren.

6 Algemene conclusies en discussie

In multi-disciplinair ontwerp van vliegtuigen worden vaak rekenintensieve numerieke simulaties gebruikt om de eigenschappen en het gedrag van het vliegtuig te voorspellen. In multi-objective optimalisatie kunnen GA of GM worden gebruikt om het Pareto front te bepalen. Tijdens dergelijke optimalisaties worden de doelfuncties evaluaties zeer veelvuldig uitgevoerd. Nauwkeurige numerieke simulaties zijn te tijdrovend en daarom is onderzocht of het mogelijk is om gebruik te maken van benaderingsmodellen, waarmee zeer snel en met geringe rekeninspanning een schatting van de eigenschappen van het vliegtuig verkregen kan worden.

Er zijn in deze studie multi-objective optimalisaties uitgevoerd van het 2-D vleugelprofiel van een BWB vliegtuigconfiguratie en vervolgens ook van de complete 3-D BWB vliegtuigconfiguratie. Deze multi-objective optimalisatiestudie is beperkt tot het bepalen van een Pareto front dat bestaat uit verschillende mogelijke concurrerende ontwerpen waaruit vervolgens de ontwerper een keuze kan maken.

De in deze studie gebruikte ANN benaderingsmodellen voorspellen de CFD resultaten met voldoende nauwkeurigheid. In deze modellen is een goede spreiding in de trainingsdata en een nauwkeurige bepaling van de dataranges noodzakelijk. Het trainen van het ANN kan binnen afzienbare tijd en het vervolgens gebruiken van het getrainde ANN voor de benadering van de doelfuncties bij een willekeurig ontwerp duurt slechts een fractie van een seconde. Interpolatie met deze benaderingsmodellen is goed mogelijk en extrapolatie slechts zeer beperkt.

Er is met het ANN benaderingsmodel een multi-objective optimalisatie van aërodynamische-, mechanische- en besturingseigenschappen van de BWB uitgevoerd. De resulterende set van geoptimaliseerde ontwerpen, het zogenaamde Pareto front, bestaat uit enkele tientallen “niet-gedomineerde” ontwerpen, welke allen voor tenminste één eigenschap beter zijn dan het referentie BWB ontwerp.

De gebruikte methoden voor optimalisatie, GM en GA, hebben beide hun voor- en nadelen. Zo vertonen de GA Pareto punten in de parameterruimte doorgaans meer spreiding dan de GM Pareto punten en is de spreiding van de GM Pareto punten erg afhankelijk van de gekozen startpunten. Eventueel vervolg onderzoek zou zich kunnen richten op het gebruik van andere optimalisatie methoden.

Literatuur

- [1] D. Quagliarella, A. Vicini (2000); *GAs for aerodynamic shape design I: general issues, shape parameterization problems and hybridization techniques*, C.I.R.A., Centro Italiano Ricerche Aerospaziali Via Maiorise – 81043 Capua (Italy)
- [2] S. de Kleermaeker (2000); *Genetic algorithms in multiobjective design optimisation*, NLR memorandum IW-2000-27
- [3] R. Maas (2000); *Use of ANN for estimating optimal design parameters for CFD problems*, NLR memorandum
- [4] R. Beale, T. Jackson (1990); *Neural Computing: an Introduction*, Department of computer science, University of York
- [5] K. C. Tan; *MOEA – Multi-objective evolutionary algorithm*,
<http://vlab.ee.nus.edu.sg/~kctan>
- [6] “*MOB: A computational design engine incorporating multi-disciplinary design and optimization for blended-wing-body configuration*”, EC 5th Framework Program, Contract nr. GRD1-1999-11162 (2000).
- [7] The MathWorks, “*Matlab Optimization Toolbox*”,
<http://www.mathworks.com/products/optimization>.
- [8] The MathWorks, “*Matlab Neural Network Toolbox*”,
<http://www.mathworks.com/products/neuralnet>.
- [9] Boerstoeel, J.W., A. Kassies, J.C. Kok, S.P. Spekreijse (1996); *ENFLOW, a full-functionality system of CFD codes for industrial Euler/Navier-Stokes computations*, NLR CR 96286 L.
- [10] Schultheiss, B.C., Baalbergen, E.H.; *Utilizing Supercomputer Power from your Desktop*, proc. HPCN 2001 Conferentie, Amsterdam.
- [11] W. J. Vankan, R. Maas, M. ten Dam (2001); *A virtual environment for transparent distributed computing in evolutionary search*, proc. Eurogen 2001 conferentie, Athene.
- [12] W. J. Vankan, R. Maas, M. ten Dam (2002); *ICT environment for multi-disciplinary design and multi objective optimisation: a case study*, ICCS 2002 conferentie, Amsterdam.
- [13] Bishop. Chr. M (1997); *Neural Networks for Pattern Recognition*, Clarendon Press, Oxford.
- [14] Baalbergen, E.H., van der Ven, H. (1999); *SPINEware – A Framework for User-Oriented and Tailorable Metacomputers*, Future Generation Computer Systems 15 549-558



Appendix A Condor versus Runonhosts

De CFD berekeningen worden parallel uitgevoerd op een cluster van SGI workstations op het NLR. De scheduling van de parallele taken zou gedaan kunnen worden met behulp van Condor of met behulp van het script Runonhosts.

Condor

Condor is een High Throughput Computing omgeving waarbinnen scheduling en migratie geregeld wordt. Er wordt hierbij gebruik gemaakt van een checkpointing systeem.

Checkpointing en taak migratie binnen Condor is alleen mogelijk als het te scheduleren programma opnieuw gelinkt wordt met de Condor libraries. Bij het gebruikte pakket om de CFD berekeningen te doen, het NLR Enflow CFD systeem, is dit niet mogelijk vanwege het niet beschikbaar zijn van de source code van Enflow. Het voordeel van het gebruik van Condor wordt hierdoor beperkt. Als bijvoorbeeld in deze situatie een parallele Enflow job niet afgerond kan worden door het niet meer beschikbaar zijn van het systeem, moet de bewuste taak opnieuw gestart worden en kan niet gemigreerd worden naar een ander systeem om daar afgerond te worden. Met volledige functionaliteit zou Condor een fout tolerant systeem zijn.

Runonhosts

Het Runonhosts script verzorgt de verdeling van de verschillende parallele taken over de beschikbare machines. Hierbij worden een aantal controles uitgevoerd. Het uitvoeren van parallele taken met behulp van Runonhosts is niet fout tolerant.

Functionaliteiten

Aangezien er geen gebruik gemaakt kan worden van het checkpointing en migratie systeem binnen Condor en door de beperkte installatie mogelijkheden hiervan, is ervoor gekozen om het eenvoudige Runonhosts te gebruiken voor het doen van de parallele CFD berekeningen. Hierbij is echter wel onderzocht met welke relevante functionaliteiten van Condor, Runonhosts uitgebreid kan worden. De volgende zijn onderzocht:

1. Checkpointing: Binnen Runonhosts wordt geen gebruik gemaakt van Checkpointing. Dit is niet mogelijk, omdat er tijdens de uitvoering van de taken op de verschillende systemen geen communicatie plaatsvindt.
2. Taak migratie: Het migreren van niet afgeronde taken in Runonhosts is niet mogelijk. Dat wil zeggen, een niet afgeronde taak kan handmatig opnieuw gestart worden, maar kan niet vervolgd worden vanaf het punt waar de berekeningen gebleven zijn.



3. Beschikbaarheid systeem: Binnen Runonhosts wordt er gecontroleerd of een systeem bereikbaar is.
4. Maximaal één taak per systeem: Binnen Runonhosts wordt gecontroleerd of er op het bewuste systeem nog geen Enflow proces draait en of er geen andere user is ingelogd.
5. Minimale systeem eisen: In Condor is het mogelijk een aantal eisen te stellen aan het systeem waar een taak op gestart mag worden. In Runonhosts is dit niet mogelijk, maar voor het doen van de CFD berekeningen is dit ook niet noodzakelijk.

A.1 Werking Myrunonhosts

Het verschil in functionaliteit tussen Condor en Myrunonhosts is hierboven reeds beknopt aangegeven. In deze paragraaf wordt de werking van Myrunonhosts beschreven.

Functionaliteit

In de eerste plaats verzorgt het script Myrunonhost de taakverdeling van de uit te voeren Ensolv taken op de beschikbare systemen. Verder verzorgt het script ook een stukje postprocessing door het verzamelen van de uitvoer data. Voor alle profielen wordt een gedefinieerd aantal Ensolv taken gestart.

Voorbereiding

Alvorens een Ensolv taak uitgevoerd kan worden, moet eerst het programma Engrid uitgevoerd zijn. Na uitvoering van de Engrid taken moet de root directory een aantal subdirectories voor de verschillende profielen bevatten, waarvoor de Ensolv berekeningen gedaan moeten worden.

Starten van Myrunonhosts

Myrunonhosts wordt gestart met als input parameter het pad van de root directory. Als er gestart wordt vanuit de root directory is deze parameter niet noodzakelijk. In het script staan de systemen opgesomd waar de taken eventueel op gestart kunnen worden.

Starten van Ensolv taken

Voor alle profielen wordt een aparte Ensolv taak gestart op een beschikbaar systeem. De volgende controles worden uitgevoerd om de beschikbaarheid van een systeem te testen.

- bereikbaarheid: Met behulp van het ping commando wordt gecontroleerd of een systeem bereikbaar is.
- beschikbaarheid: Omdat een Ensolv taak veel resources in beslag neemt wordt er op het bewuste systeem alleen een Ensolv taak gestart als het systeem volledig beschikbaar is. Om dit te garanderen wordt er gecontroleerd of er niet reeds een andere user op het systeem heeft ingelogd.



- bezettingsgraad: Om volledige beschikbaarheid van het systeem te garanderen mag er ook niet reeds een andere Ensolv taak op het systeem gestart zijn.

Als na deze drie controles het systeem beschikbaar blijkt te zijn, wordt hierop een Ensolv taak gestart voor het bewuste profiel. Als het systeem niet beschikbaar is, worden de controles uitgevoerd voor een volgend systeem in de lijst en indien mogelijk wordt hierop de taak gestart. Zolang als dat er taken te verdelen zijn, wordt de lijst met systemen doorlopen.

Verzamelen van uitvoer data

Nadat alle taken verdeeld zijn wordt er begonnen met het verzamelen van de uitvoer data. Deze uitvoer staat in de '.conv-files'. De verschillende subdirectories worden, een vooraf gedefinieerd aantal keer, gecontroleerd op het bestaan van deze files. De verzamelde uitvoer wordt geschreven in de root directory in de '.out-file'.

Beëindigen van Ensolv taken

Als alle data verzameld is of als het maximaal aantal pogingen verstreken is worden de nog draaiende en de niet meer reagerende Ensolv taken beëindigd. Hiertoe wordt het taaknummer van de draaiende of niet reagerende taak opgevraagd en in files geschreven. Vervolgens worden alle taken uit deze file beëindigd met behulp van het kill commando.

Logfile

Tijdens het uitvoeren van Myrunonhosts wordt er een logfile bijgehouden, waarin de volgende meldingen kunnen worden geschreven.

- `$host NOT RESPONDING`: Het bewuste systeem heeft niet gereageerd op het ping commando.
- `$host NOT AVAILABLE`: Het bewuste systeem is niet beschikbaar, omdat er reeds een Ensolv taak op het systeem draait, of omdat er een andere user op het systeem heeft ingelogd.
- `input-set $setname NOT SUCCEEDED`: Het verzamelen van de data behorende bij het bewuste profiel is mislukt. Het maximaal aantal pogingen is bereikt.
- `FINISHED`: De data is verzameld. Nog draaiende en niet meer reagerende taken moeten nog worden beëindigd.

Hierin is `$host` de naam van het bewuste systeem en `$setname` de naam van de bewuste subdirectory.



Appendix B Ensolv invoer voor CFD berekeningen

Vleugelprofiel invoer

```
RAE case 9 (TLNS; CS model)
MACH      REYN      RLEN
.730      6.5E06      1.00
LIFT      ALPHA     BETA      CLT
0         2.800      0.000     0.000
AREA      LENGTH    XREF      YREF      ZREF
1.000     1.000     0.250     0.500     0.000
GRIDL     FIRSTL     LASTL     MAXML
2         2         2         2
NITER     NSTAG      NPRNT     RESIT
200       5         10        0
CFL       RESAV      ENTHD
4.500     1.500     0.000
VIS2      VIS4      VSWIT     VISAR
1.000     2.000     0.500     1
NASMOD    TURMOD
1         2
SELECT    INTOO     FDAT      CONV      INUNS
0         0         0         1         0
```

BWB invoer

```
BWB
" --- Reference data
Area          Length    Xref      Yref      Zref
418254684.8  12287.9  29079.8   0.0       0.0
" --- Flow conditions
Mach      Reyn      Rlen
0.85      82.0E6    12287.9
Alpha
6.636000
" --- Numerical things
GridL  FirstL  LastL  MaxML
3      3       3      2
NasMod TurMod  TurLim
2      21     0
" --- Number of Iteration
Niter
10
Select
1
```