

YAPAY SİNİR AĞI İLE GÜÇLENDİRİLMİŞ GENETİK ALGORİTMA VE TERSTEN KANAT PROFİLİ DİZAYNI

Abdurrahman HACIOĞLU

Hava Harp Okulu Komutanlığı
Dekanlık Havacılık Mühendisliği Bölümü
34149, Yeşilyurt, İstanbul
a.hacioglu@hho.edu.tr

ÖZET

Bu çalışmada, yapay sinir ağı ile güçlendirilmiş bir genetik algoritma önerilerek, tersten kanat profili dizaynına uygulaması yapılmıştır. Yapay sinir ağı ve genetik algoritma melez bir yapı içerisinde, yeni bir yaklaşımla birleştirilerek hızlı bir dizayn algoritması elde edilmiştir. Bu yeni yaklaşımda yapay sinir ağı, amaç fonksiyonunun yaklaşık olarak hesaplanması yerine, doğrudan hedef çözümün tahmin edilmesi için kullanılmıştır. Yapay sinir ağı, genetik sürecin her adımında, mevcut popülasyon kullanılarak eğitilmiştir. Yapay sinir ağı tarafından üretilen bir bireyin, her adımda, genetik işlemlerle oluşturulmuş olan yeni popülasyona dahil edilmesiyle dizayn sürecinin hızlandırılması amaçlanmıştır. Saf genetik algoritmalar kadar gürbüz olan bu yeni yöntemin tersten kanat profili dizaynına uygulanması ile dizayn sürecinin çok büyük oranda hızlandığı, işlem sayısının oldukça azaldığı görülmüştür.

Anahtar Kelimeler: Kanat Profili, Tersten Dizayn, Yapay Sinir Ağı, Genetik Algoritma.

ABSTRACT :Augmented Genetic Algorithm with Neural Network and Implementation to Inverse Airfoil

Design

In this study, an augmented genetic algorithm via artificial neural network has been introduced, and its implementation to the inverse airfoil design problem is demonstrated. Neural network and a real coded genetic algorithm are hybridized in a new way with the purpose of getting a faster algorithm. In this approximation, instead of predicting computational fluid dynamics calculations of a candidate airfoil, neural network is used for predicting candidate itself. This powerful method is tested for an inverse airfoil design problem in transonic flow cases. The computational efficiency of this implemented algorithm is tremendously high, and due to still being genetic algorithm based technique, this new method is also as robust as the pure genetic algorithms.

Key Words: Airfoil, Inverse Design, Neural Network, Genetic Algorithm.

1. GİRİŞ

Geçtiğimiz yüzyılın son çeyreğinde bilgisayar teknolojisinde yaşanan büyük gelişim sonucu, sayısal simülasyon yöntemlerinin mühendislik dizayn uygulamalarındaki kullanımı giderek artmış ve günümüzün mühendisleri zamanlarının pek çoğunu bilgisayarlar başında, sayısal modellemeler ve çözümler için geçirir olmaya başlamışlardır. Aynı dönemde Hesaplamalı Akışkanlar Dinamiği

(HAD), uçak dizayn işlemlerinin vazgeçilmez bir parçası haline gelmiştir. HAD, rüzgar tüneli deneyleri gibi çalışmaları azaltması nedeniyle, dizayn işlemlerinin süresini ve maliyetlerini düşürmektedir. HAD, verilen bir uçak konfigürasyonunun aerodinamik performansını belirlemek için kullanılabilirliği gibi, sayısal optimizasyon teknikleri ile birleştirilerek istenilen performansı sağlayacak aerodinamik konfigürasyonun belirlenmesi veya belli bir aerodinamik konfigürasyonun performansının

arttırılması, optimize edilmesi amacıyla da kullanılabilir.

Tersten kanat profili dizaynı (inverse airfoil design), arzu edilen belli bir basınç dağılımını sağlayan kanat profilinin elde edilmesi problemi olup, aerodinamik dizayn çalışmalarının temel konularından biridir. Bu problem, değişik optimizasyon teknikleriyle birlikte olduğu gibi, kullanımı son yıllarda oldukça yaygınlaşan genetik algoritmalar (GA) ile birlikte de çözülebilmektedir.

Aerodinamik dizayn ve optimizasyon çalışmalarındaki uygulamaları çok başarılı sonuçlar vermekle birlikte, çok fazla HAD hesabı gerektirmesi, GA'ların bu konudaki en büyük eksikliğidir [1,2,3,4]. Bu eksikliğin giderilmesi ve GA'ların daha hızlı sonuç vermesi için genel olarak dört yol kullanılır [5]. Bu yollar: Gelişmiş GA işlem yöntemleri [6,7,8]; paralel hesaplama yöntemleri [9,10]; sayısal optimizasyon metotları ile GA'nın melez bir yapı içerisinde olduğu yöntemler [1]; HAD hesabı için gerçek sayısal çözüm yerine, yaklaşık sayısal çözüm (örnek olarak belli bir miktar HAD hesabı için yapay sinir ağı, YSA, ile elde edilen çözümü) kullanan [5,11] yöntemlerdir.

Yukarıda en son belirtilmiş olan yöntemle yapılmış olan çalışmalarda ([5] ve [11] gibi) YSA, çok fazla işlem gerektiren ve çok zaman alan HAD çözümünü tahmin etmek için kullanılır. GA ile yapılan dizayn sürecindeki her bir adımda, popülasyondaki bireylerin bir kısmına ait HAD hesapları, eğitilmiş olan bir YSA ile gerçekleştirilir. Böylece, YSA tarafından yapılan yaklaşık HAD hesapları ile gerçek HAD hesabı sayısı azaltılarak dizayn süreci hızlandırılır. Bu teknikte, YSA eğitilirken kanat profilleri girdi, kanat profillerine ait HAD çözümleri çıktı olarak kullanılır. Yöntemin başarısı, YSA'dan elde edilen yaklaşık HAD çözümlerinin başarısına bağlıdır. Diğer taraftan, dizayn sürecinde hedeflenen sonuca ulaşmak için tek belirleyici GA'dır. Çünkü genetik sürecin her adımında üretilen yeni popülasyondaki bireyler (dizayn problemin aday çözümleri) çaprazlama, mutasyon gibi genetik işlemciler tarafından üretilmektedir.

Bu çalışmada, tersten kanat profili dizaynı için kullanılan GA'ların hızını artırmak için yeni bir yol önerilmiştir. Bu amaçla, YSA ve GA'nın melez kullanımı için yeni bir teknik geliştirilmiştir. Bu tekniğe göre, YSA, popülasyondaki bireylerin yaklaşık HAD hesabında kullanılmak yerine, genetik sürecin her bir adımında hedef çözümü sağlayan bireyi tahmin etmek için kullanılacaktır. Tahmin edilen bu birey, genetik işlemlerle oluşturulan yeni popülasyona ilave edilerek, genetik sürecin bir sonraki adımında kullanılacaktır.

Yapılan bu işlem sonucunda, YSA hedef çözüme ulaşmada doğrudan belirleyici olabilecektir. Çünkü, buradaki yeni popülasyonda bireylerden bir tanesi YSA tarafından üretilmiştir. Diğer taraftan bu yeni teknikte YSA'nın her adım için çok başarılı bir birey (çözüm) üretmesi de şart değildir. Bunun nedeni, YSA'dan gelen birey çok hatalı olsa bile, genetik sürecin başarısız bireyleri eleyerek süreç dışı bırakabilmesi ve daha az uygun bireylerden daha iyi bireyler üretebilmesidir. YSA bir defa çok başarılı bir tahmin yaptığında ise zaten problemin çözümüne ulaşılmış olacak ve dizay süreci tamamlanacaktır. Bu teknik, *Yapay Sinir Ağı İle Güçlendirilmiş Genetik Algoritma* (YGGA) olarak isimlendirilmiş olup tersten kanat profili dizaynına uygulanması ile oldukça iyi sonuçlar elde edilmiştir. Yöntemin detayları 2. bölümde açıklanacaktır.

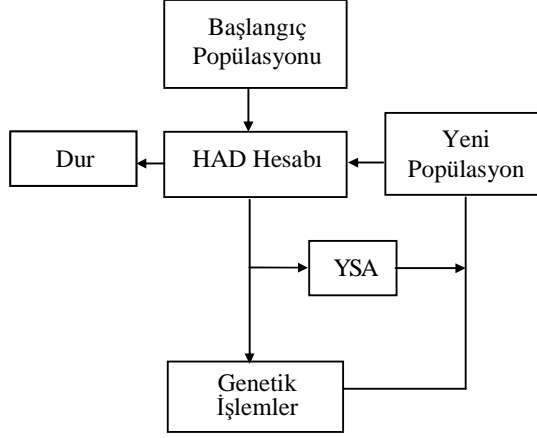
Bu çalışmada kullanılan GA, *Dağıtım Stratejileri* (DS) uygulaması içeren *Titreşimli Genetik Algoritma* (TGA)'dır. TGA ve DS yöntemleri [12] ile yazar tarafından yapılan doktora çalışmasında geliştirilmiş olup bunlara ait geniş bilgi [12]'de bulunabilir. TGA ve DS daha sonra kısaca açıklanacaktır.

2. YAPAY SİNİR AĞLARI İLE GÜÇLENDİRİLMİŞ GENETİK ALGORİTMA

YGGA yönteminde YSA, genetik sürecin her adımında bir tane aday çözüm üretmesi için kullanılır. Genetik sürecin her adımında kullanılan popülasyon içerisindeki bireyler (kanat profilleri) ve bunlara ait HAD çözümleri (basınç katsayısı dağılımları) YSA'mı eğitmek için, eğitim seti olarak kullanılır. Bu yapılırken HAD çözümleri girdileri, bunların ait oldukları kanat profili geometrileri çıktıları oluşturur. Eğitilmiş olan YSA, genetik sürecin o adımı için, dizayn probleminin girdisi olan hedef basınç dağılımını kullanarak bir kanat profili üretir. Üretilen bu kanat profili, genetik işlemciler tarafından üretilmiş olan yeni popülasyona dahil edilerek bir sonraki adımda onlarla birlikte kullanılır. Genetik sürecin herhangi bir adımında, YSA'nın yapacağı yeterince iyi bir tahmin hedeflenen sonucu verebilecektir. Bununla birlikte, genetik sürecin ilk adımlarında, popülasyon hedef çözüme fazla yakın olmayacağı için, bunların kullanılmasıyla eğitilecek olan YSA, hedef çözüme göre yeterince iyi tahmin yapamayacaktır. Diğer taraftan, YSA'nın yapacağı tahmin, muhtemelen genetik sürecin o adımda çıkartacağı en iyi bireyden daha iyi olabilecektir. Bu böyle olduğu zaman, YSA'nın ürettiği birey daha baskın olacak ve popülasyonun daha hızlı gelişmesini sağlayacaktır. Bu durumda da GA, YSA'dan gelen bireyle güçlendirilen popülasyondan daha iyi bir popülasyon üretecektir. Daha iyi bir popülasyon, hedef çözüme daha yakın olacağından, genetik süreç ilerlerken YSA için daha iyi bir eğitim seti elde edilmiş olacaktır. Bu, YSA'nın daha az hatalı bir birey üretmesini sağlayacak; YSA'dan gelecek daha az

hatalı birey ile de GA daha iyi bir popülasyon üretecektir. Sonuç olarak, bu karşılıklı pozitif etkileşim genetik süreci oldukça hızlandıracak ve hedeflenen sonucun çok az işlemle elde edilebilmesini sağlayacaktır..

Akış şeması Şekil 1’de gösterilen YGGA’nın ana adımlarını aşağıdaki gibi sıralayabiliriz:



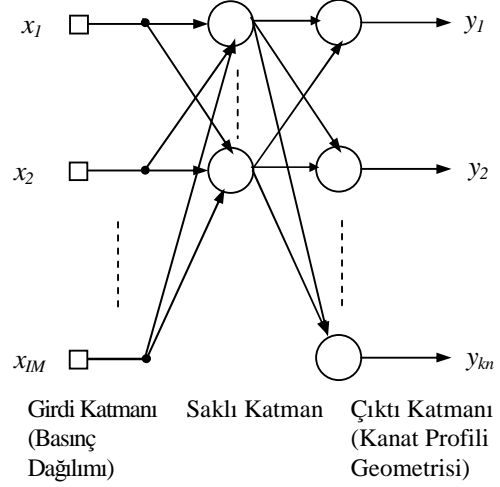
Şekil 1. YGGA'nın akış şeması.

- İlk olarak, popülasyondaki bireylere (kanat profilleri) ait HAD hesapları yapılarak, basınç katsayısı dağılımları ve uygunluk değerleri belirlenir ve genetik işlemler yapılarak yeni popülasyon üretilir.
- İkinci olarak, popülasyondaki kanat profilleri ve bunlara ait basınç katsayısı dağılımları kullanılarak YSA eğitilir. Eğitim sırasında basınç katsayısı dağılımları girdi, kanat profili geometriyi çıktı olarak kullanılır.
- Son olarak, hedef basınç katsayısı dağılımı girdi olarak kullanılarak eğitilmiş olan YSA'dan bir kanat profili elde edilir ve genetik sürecin bir sonraki adımında kullanılmak üzere, genetik işlemcilerle elde edilen popülasyona ilave edilir.

Bu işlemler hedeflenen çözüm elde edilinceye kadar genetik sürecin her adımında tekrarlanır.

Bu çalışmada kullanılan YSA “back propagation neural network” (BPNN) [13] olup; bu BPNN’de, saklı katmanda doğrusal olmayan sigmoid transfer fonksiyonu ve doğrusal çıktı katmanı kullanılmıştır. Bu YSA’nın yapısı Şekil 2’de gösterilmiştir. Yukarıda belirtildiği gibi, eğitim setinde basınç katsayısı dağılımları girdileri, kanat profilleri de çıktıları oluşturmaktadır. YSA’nın kullandığı bu eğitim seti, genetik sürecin her adımında, o adımdaki popülasyon ve HAD çözümlerinden elde

edilir. Eğitim sonucu elde edilen YSA’ya ait parametreler (ağırlıklar) korunarak, bir sonraki adımdaki YSA eğitiminde başlangıç değerleri olarak kullanılır. Bu işlem, YSA’nın eğitim hatalarını azaltarak, daha etkin tahmin yapmasını sağlar [14].



Şekil 2. Kullanılan YSA'nın (BPNN) yapısı.

3. DAĞITIM STRATEJİLERİ

Genetik işlemler sırasında, kromozomları belli parçalara bölerek, amaç fonksiyonunu bu parçalar için ayrı ayrı hesaplama; genetik işlemleri bu parçalar için ayrı ayrı yapma yaklaşımıdır. Eğer bu yaklaşım, ele alınan probleme doğru bir biçimde uygulanabilirse, genetik süreci oldukça hızlandırmak mümkün olmaktadır. Yaklaşım, *Dağıtılmış Amaç Fonksiyon (DAF)* ve *Dağıtılmış Elitizm (DE)* şeklinde iki ayrı şekilde veya istenirse aynı anda beraber kullanılabilir.

DAF, amaç fonksiyonun belirlenen kromozom parçaları için ayrı ayrı hesaplanarak, genetik işlemlerin kromozom parçaları için ayrı ayrı yürütülmesi yaklaşımıdır. DE ise, genetik sürecin her adımında, en iyi kromozomdan ayrı olarak, en iyi kromozom parçalarından oluşturulan bir başka kromozomun da yeni adıma aktarılmasıdır. Bu yaklaşımların ayrıntıları [12] de verilmiş olup, test fonksiyonu üzerindeki uygulamaları, konseptin faydasını açıkça göstermiş ve GA’nın hızlandığı görülmüştür. Yöntemin kanat profili dizaynına uygulaması ile ilgili ayrıntılar 6. bölümde verilecektir.

4. TİTREŞİMLİ GENETİK ALGORİTMA

Titreşimli Genetik Algoritma (TGA) etkin bir çeşitlilik ile arama/bulmayı sağlaması nedeniyle, GA’nın yakınsama performansını arttıran bir yöntemdir. Titreşim ile kastedilen, genetik işlemlerde

kullanılan birtakım parametrelerin değerlerinde meydana getirilen bazı dalga formlarındaki salınımlardır. *Titreşimli Çaprazlama ve Titreşimli Mutasyon* olarak iki ayrı teknikten oluşur. Bu tekniklerin ayrıntıları [8] ve [12] de verilmiştir.

Titreşimli mutasyon yenilemeden hemen sonra uygulanır. Uygulama, genetik sürecin başlangıcından itibaren periyodik olarak gerçekleştirilir. İlk adımı takiben, genliği rassal bir şekilde değişen bir dalga popülasyona etki ettirilir. Titreşimli mutasyon sırasında, popülasyondaki bütün kromozomların (bireyler) tüm genleri aşağıda ifade edilen dalgaya bağlı olarak mutasyon geçirirler.

$$\begin{aligned} y_i^m &= y_i^m \cdot [1 + w1 \cdot MA \cdot (0.5 - u)] \\ m &= 1, \dots, n \\ i &= 1, \dots, kn \end{aligned} \quad (1)$$

Burada y gen (kontrol noktası), kn kromozomdaki toplam gen sayısı, n popülasyondaki toplam birey (kromozom) sayısı, MA ana genlik, u [0,1] aralığında rassal bir reel sayı ve $w1$, bir civarında reel bir sayıdır.

Dalga uygulaması, ilk kromozomun belirli bir sırasındaki genen başlar ve diğer kromozomlardaki aynı sıradaki genler boyunca devam eder. Bu işlem popülasyondaki tüm bireylere her IP periyotta uygulanır. IP bir tam sayı olmak üzere, mutasyon oranı $P_m=1/IP$ 'dir. Genetik süreç boyunca iyi bir performans yakalanması için titreşim periyodu IP 'nin uygun bir değere sabitlenmesi gereklidir. Bu periyod değerinin (dolayısıyla mutasyon oranı P_m değerinin) büyüklüğü yöntemin performansını etkileyecektir. Global optimuma yaklaşıırken popülasyonu dar bir aralıkta titreşime maruz bırakmak global optimuma ulaşmayı hızlandıracaktır. Bu nedenle ana genlik değeri MA genetik süreç boyunca aşağıdaki gibi belirlenir:

$$MA = \left[\frac{\log(1 + AF_0)}{\log(1 + AF_k)} \right]^r \quad (2)$$

AF_0 ve AF_k sırasıyla genetik sürecin başlangıç adımındaki ve içinde bulunulan adımındaki ortalama uygunluk değerleri olup r reel bir sayıdır. Genetik sürecin ilk adımında $MA=1$ olacaktır. Eğer ilk adım için 1'den farklı bir sayı istenirse edilirse, MA bir parametre ile çarpılarak istenen ayarlama yapılabilir. MA , olabilecek en büyük dalga genliğidir. Denklem (2)'deki r , MA değerinin azalma hızını belirler. Hızlı bir azalma için r büyük bir değer almalı, yavaş bir azalma için ise r küçültülmelidir.

5. KANAT PROFİLİ OPTİMİZASYONU İÇİN GENETİK ALGORİTMA İŞLEMLERİ

Hedeflenen kanat profiline ait basınç katsayısı dağılımı, C_p girdi olarak verilir. Hedeflenen kanat profiline ulaşmak için çözüme NACA0012 gibi bilinen bir kanat profili ile başlanır. Bu tür problemler için çoğunlukla kullanılan hedef fonksiyonu,

$$J(\lambda) = \int_{\lambda} (C_{p\lambda} - C_{p_i})^2 d\lambda \quad (3)$$

şeklinde. Burada $C_{p\lambda}$ ve C_{p_i} sırasıyla, kanat profili yüzeyi λ üzerindeki hesaplanan ve hedeflenen basınç katsayılarıdır. Popülasyondaki kanat profillerinin uygunluk değeri için uygunluk fonksiyonu aşağıdaki gibi olacaktır:

$$\phi(\lambda) = \frac{1}{J(\lambda)} \quad (4)$$

Buna göre problem tipik bir enbüyük değeri elde etme problemi olur. Uygunluk değerinin sonsuza gitmesi durumunda hedeflenen kanat profili ile ulaşılan kanat profi tam olarak çakışmış olacaktır.

Genetik algoritma ile kanat profili dizaynındaki en önemli işlemlerden biri de kanat profili geometrisinin temsildir. Bu amaçla, kanat profilinin bir yüzeyine ait eğriyi m adet nokta ile ifade etmeyi sağlayan, ve aşağıda denklemleri verilen Bezier eğrisi temsili kullanılacaktır.

$$y(t) = \sum_{i=0}^m C_m^i t^i (1-t)^{m-i} y_i \quad (5)$$


$$x(t) = \sum_{i=0}^m C_m^i t^i (1-t)^{m-i} x_i \quad (6)$$

Kanat profilinin bir yüzeyinin 8 nci mertebeden temsilde 9 adet kontrol noktası kullanılır ve bunlardan, hücum kenarı ile firar kenarında olan 2 tanesi sabittir. $C_m^i = \frac{m!}{i!(m-i)!}$ olup, t , [0,1] aralığında

değişen değerler alan bir parametredir. Kontrol noktalarının koordinatları (x_i, y_i) ile verilmiştir. Burada x_i 'ler sabit tutularak, genetik süreçte yalnızca y_i değerleri kullanılır. Kanat profilinin yüzeyini ifade eden kontrol noktalarının tamamı bir kromozom oluştururken, her bir kontrol noktası da bir gen olacaktır. NACA0012 kanat profilinin Bezier eğrisi ile temsili Şekil 3'de gösterilmiştir.

6. DAĞITIM STRATEJİLERİNİN KANAT PROFİLİ DİZAYNINA UYGULAMASI

Kanat profilinin Bezier eğrileriyle temsil edileceği geçen bölümde söylenmişti. Buna göre, kanat profilinin her bir yüzeyi, kendilerine ait iki ayrı grup kontrol noktası ile aşağıdaki gibi temsil edilecektir.



Buradan da kolaylıkla görülebileceği gibi kanat profiline ait kromozom iki parça olarak ele alınacak ve her bir parça için amaç fonksiyonu ve uygunluk değerleri ayrı ayrı hesaplanacaktır. Seçim işlemleri alt ve üst yüzeyler için ayrı ayrı yapılacaktır. Buna göre amaç fonksiyonları, alt ve üst yüzeyler için;

$$J_{ALT}(\lambda) = \int_{\lambda_{ALT}} (Cp_{\lambda} - Cp_t)^2 d\lambda \quad (7.a)$$


$$J_{ÜST}(\lambda) = \int_{\lambda_{ÜST}} (Cp_{\lambda} - Cp_t)^2 d\lambda \quad (7.b)$$

olarak ayrı ayrı hesaplanacaktır. Uygunluk değerleri de;

$$\phi_{ALT}(\lambda) = \frac{1}{J_{ALT}(\lambda)} \quad (8.a)$$

$$\phi_{ÜST}(\lambda) = \frac{1}{J_{ÜST}(\lambda)} \quad (8.b)$$

olarak hesaplanacaktır. Alt ve üst uygunluk değerleri toplamı en büyük olan kromozom, en iyi kromozom olarak bir sonraki popülasyona




Şekil 3. NACA0012 profilinin Bezier eğrisi ile temsili.

aktarılarak elitizme tabi tutulurken, en iyi alt ve üst yüzey parçaları da birleştirilerek elitizme tabi tutulacaktır.

7. UYGULAMA

RAE2822 kanat profilinin 0.725 Mach sayısında ve 2 derece hücum açısı için olan transonik akım şartlarındaki basınç katsayısı dağılımı, C_p , hedef olarak alınacaktır. Çözüme NACA0012 kanat profili ile başlanarak hedeflenen profile (RAE2822) ulaşılmaya çalışılacaktır. HAD tekniği olarak; ayrıntıları [14]'de verilen, 161x31 büyüklüğünde O-grid kullanan ve transonik akış şartları için de çözüm yapabilen, bir tam potansiyel akım çözücüsü kullanılacaktır. Başlangıç popülasyonu, NACA0012'nin kalınlık oranı ± 30 oranında düzgün bir şekilde değiştirilerek oluşturulacaktır. Çaprazlama oranı, $P_c = 1$ olup mutasyon oranı, P_m , titreşimli mutasyon uygulamasının periyoduna (IP) bağlıdır. Seçim işlemi için Stokastik Tümel Örnekleme (*Stochastic Universal Sampling*, SUS) [15] yöntemi kullanılacaktır.

Uygulama aşağıdaki stratejiler ile yapılacaktır:



Şekil 4. Kullanılan stratejilere ait uygulama sonuçları.

- i. Strateji I (ST-I): Çaprazlama tekniği BLX- α [16] ve $\alpha=0.7$, $P_m=0.015$. Mutasyon için rasgele seçilen bir kromozomun rasgele seçilen bir geni aşağıdaki işleme tabi tutulacaktır.

$$y_i^k = y_i^k + 2w(0.5 - u)$$

Burada $w=0.04$ alınmıştır; u [0,1] aralığında rassal bir reel sayıdır.

- ii. Strateji II (ST-II): Çaprazlama tekniği BLX- α ve $\alpha=0.7$, ilave olarak DS ile birlikte TGA kullanılacaktır.
- iii. Strateji III (ST-III): ST-II ile birlikte YGGA kullanılacaktır.
- iv. Strateji IV (ST-IV): ST-III'de DS ve TGA uygulaması yapılmayacaktır. ST-I'deki mutasyon formülü uygulanacaktır.

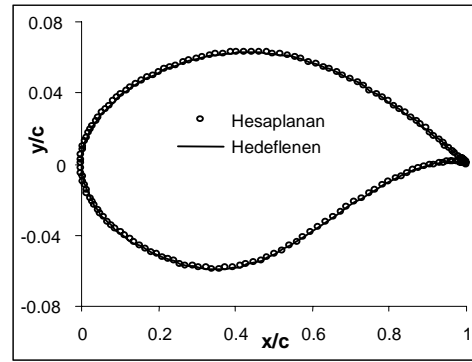
Titreşimli mutasyon için $IP=4$; denklem (1)'de $w=1$ ve denklem (2)'de $r=4$ alınacaktır. Popülasyon büyüklüğü, n , ST-I kullanılırken 30, diğer stratejiler için 14 olarak kullanılacaktır.

8. SONUÇLAR

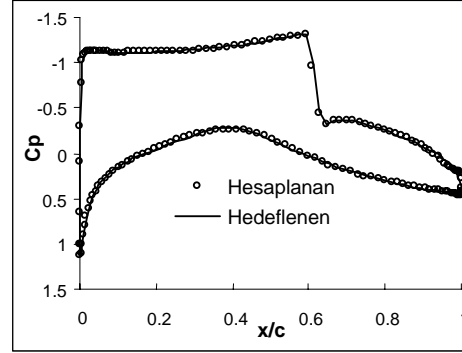
Bu çalışmada tersten kanat profili dizaynına uygulanan YGGA ile, genetik süreçteki HAD hesabı sayısı önemli ölçüde azaltılmıştır. YSA, bundan önceki [1] ve [5] gibi çalışmalarda olduğu gibi yaklaşık HAD hesabı için kullanılmamış; bunun yerine, doğrudan hedef kanat profilini tahmin etmek için kullanılmıştır. Yapılan bu yeni yaklaşımla, 2. bölümde açıklandığı gibi, YSA ile GA arasında pozitif bir etkileşim sağlanarak genetik süreç oldukça hızlandırılmıştır.

RAE2822 profili için transonik akım şartlarında yapılan tersten dizayn çalışmasında değişik stratejilerin performansını gösteren grafik Şekil 4'de verilmiştir. Buradaki sonuçların herbiri, 10 farklı denemenin ortalamasıdır. Grafikde yatay eksen yapılan HAD hesabı sayısını, dikey eksen ise en iyi uygunluk değerini göstermektedir. Popülasyon büyüklüğü n olmak üzere, genetik sürecin her bir adımında $n-1$ adet HAD hesabı yapıldığına dikkat edilmelidir. Şekil 4'deki sonuçlara bakıldığında, ST-III ile elde edilen sonucun, diğerlerine göre dik bir çizgi olduğu görülmektedir. Bu durum, YSA ve GA arasındaki pozitif etkileşimin sonucudur. Genetik süreçte uygunluk değerinin 70000 olması için ST-I ile 10320; ST-II ile 2282; ST-III ile ise yalnızca 195 HAD hesabı gerekmiştir. Elde edilen bu sonuçlara göre, ST-I ile karşılaştırıldığında HAD hesabı sayısı, ST-II uygulaması ile %78; ST-III

uygulaması ile %98 azaltılmıştır. Diğer taraftan ST-II ile karşılaştırıldığında ST-III uygulamasının HAD hesabı sayısını %92 azalttığı görülmektedir. Bu sonuç, uygulanan YGGA tekniğinin etkisini çok belirgin bir şekilde ortaya koymaktadır. YGGA, yaklaşık olarak 200 HAD hesabından sonra istenilen sonucu vermiştir. Bu sayı, GA ile yapılan tersten kanat profili dizaynı çalışması için oldukça küçüktür. Benzer çalışmalar olan [7]'deki 10000; [1]'deki 5000; [6]'daki (10 farklı denemenin en iyisi olarak) 2160 ve [2]'deki 5000 rakamları ile karşılaştırılırsa bu durum çok açık bir şekilde görülecektir. Diğer bir önemli noktada, GA esaslı bir teknik olma özelliğini sürdürmesi nedeniyle YGGA yönteminin, hala gürbüz ve geniş bir uygulama sahasına sahip olacak olmasıdır.



Şekil 5. Hesaplanan ve hedeflenen profiller.



Şekil 6. Hesaplanan ve hedeflenen Cp dağılımları.

TGA ve DS uygulamasının yapılmadığı durumda (ST-IV), ST-III'deki HAD hesabı sayısı 198'den 412'ye yükselmiştir. Bu, TGA ve DS kullanılmadığında YGGA'daki HAD hesabı sayısının %100'den daha fazla arttığını göstermektedir. Bu nedenle bu çalışma aynı zamanda, [12]'de de gösterilmiş olduğu gibi, TGA ve DS tekniklerinin GA ile yapılan aerodinamik dizayn çalışmalarındaki başarısını bir kez daha ortaya koymaktadır.

Tersten dizayn çalışması sonucunda elde edilen kanat profili ve basınç katsayısı dağılımı, hedef kanat profili ve basınç katsayısı dağılımı ile karşılaştırılmaları Şekil 5 ve 6'da gösterilmiştir. Şekillerden de

görüldüğü gibi elde edilen sonuçlarla hedeflenenler arasında oldukça iyi bir uyum vardır.

YGGA yönteminin, gradyan esaslı yöntemlerle işlem sayısı bakımından kıyaslanabilirliği devam eden bir çalışma olup bir başka makalenin konusunu oluşturacaktır.

9. TEŞEKKÜR

Yapay sinir ağları konusundaki bilgisinden istifade ettiğim Hv.Müh.Yzb. Murat ERMİŞ'e, bu çalışmaya yapmış olduğu katkıdan dolayı teşekkürlerimi sunarım.

10. KAYNAKLAR

[1] Vicini, A. ve Quagliarella, D., "Airfoil and Wing Design Through Hybrid Optimization Strategies," *AIAA Journal*, Vol. 37, No. 5, 1999.

[2] Holst, T. L. ve Pulliam, T. H., "Aerodynamic Shape Optimization Using a Real-Encoded Genetic Algorithm," *AIAA* 2001-2473, 2001.

[3] Obayashi, S. ve Tsukahara, T., "Comparison of Optimization Algorithms for Aerodynamic Shape Design," *AIAA Journal*, Vol. 35, 1997.

[4] Quagliarella, D. ve Vicini, A., "GAs for Aerodynamic Shape Design I: General Issues, Shape Parameterization Problems and Hybridization Techniques," GAs for Optimization in Aeronautics and Turbomachinery, von Karman Institute for Fluid Dynamics, Lecture Series 2000-07.

[5] Giannakoglou, K. C., "Acceleration GAs Using ANN- Theoretical Background," GAs for Optimization in Aeronautics and Turbomachinery, von Karman Institute for Fluid Dynamics, Lecture Series 2000-07.

[6] De Falco, I., Cioppa, A. D., Balio, R. D. ve Tarantino, E., "Breeder Genetic Algorithms for Airfoil Design Optimisation," *Proceedings of IEEE International Conference On Evolutionary Computing*, Nagoya, Japan, 1996, pp. 71-75.

[7] De Falco, I., Cioppa, A. D., Lazzetta, A. ve Tarantino E., "M_{ijn} Mutation Operator for Airfoil Design Optimisation," *Soft Computing in Engineering Design and Manufacturing*, Springer Verlag, 1998, pp.211-220.

[8] Hacıoğlu, A. ve Özkol, İ., "Transonic Airfoil Design And Optimisation By Using Vibrational Genetic Algorithm," *Aircraft Engineering and Aerospace Technology*, Vol. 75, No 4, 2003.

[9] Jones, B. R., Crossly, W. A. ve Lyrintzis, A. S., "Aerodynamic and Aeroacoustic Optimization of Airfoils via a Parallel Genetic Algorithm," *Journal of Aircraft*, Vol. 37, No. 6, 2000.

[10] Doorly, D. J. ve Peiro, L., "Supervised Parallel Genetic Algorithms in Aerodynamic Optimisation," *AIAA* 97-1852, 1997.

[11] Tse, D.C.M. ve Chan, L.Y.Y., "Application of Micro Genetic Algorithms and Neural Networks for Airfoil Design Optimization," *RTO MP-035 Aerodynamic Design and Optimisation of Flight Vehicles in a Concurrent Multi-Disciplinary Environment*, 1999.

[12] Hacıoğlu, A., "Aerodinamik Dizayn ve Optimizasyonda Genetik Algoritma Kullanımı," Uçak Mühendisliği Programı Doktora Tezi, İ.T.Ü. Fen Bilimleri Enstitüsü, İstanbul, 2003.

[13] Rumelhart, D. E., Hinton, G. E., ve Williams, R. J., "Learning Representations By Back Propagating Errors," *Nature*, 323, 1986, pp. 533-536.

[14] Hacıoğlu, A., "Interactive Solution Procedure for Full Potential and Boundary Layer Equations", Havacılık Mühendisliği Yüksek Lisans Tezi, ODTÜ Fen Bilimleri Enstitüsü, 1997.

[15] Baker, J. E., "Reducing Bias and Inefficiency in the Selection Algorithm," *Proceedings of the Second International Conference on Genetic Algorithms*, Morgan Kaufmann Publishers, 1987, pp.14-21.

[16] Eshelman, L.J. ve Schaffer, J. D., "Real Coded Genetic Algorithms and Interval Schemata," *Foundations of Genetic Algorithms 2*, Morgan Kaufmann Publishers, 1993, pp.187-202.

ÖZGEÇMİS:

Dr.Hv.Müh.Yzb. Abdurrahman Hacıoğlu İTÜ Uçak ve Uzay Bilimleri Fakültesi Uçak Mühendisliği bölümünden 1991 yılında mezun oldu. 1991-1995 yılları arasında Kayseri 2.HİBM K.lığında görev yaptı. 1995-1997 yılları arasında ODTÜ Havacılık Mühendisliğinde yüksek lisans eğitimini; 1998-2003 yılları arasında İTÜ Uçak Mühendisliği bölümündeki doktora eğitimini tamamladı. Akışkanlar Mekaniği, Hesaplamalı Akışkanlar Dinamiği, Genetik Algoritmalar ve Aerodinamik Optimizasyon konuları ile ilgilenmektedir. Halen Yüzbaşı rütbesinde olup Hava Harp Okulu Dekanlığı, Havacılık Mühendisliği bölümünde öğretim üyesi olarak görev yapmaktadır.