

## ÜÇ ELEMANLI BİR KANAT PROFİLİ İÇİN İŞLEMSEL ZEKA YAKLAŞIMLARI İLE AKIŞ ÖZELLİKLERİNİN TAHMİNİ

Coşku KASNAKOĞLU\* ve Mehmet Önder EFE†  
TOBB Ekonomi ve Teknoloji Üniversitesi, Ankara

### ÖZET

*Bu çalışmada bir kanat profili üzerinden geçen hava akımının hız ve basınç değerlerinin tahmini problemi incelenmiştir. Kanat profilinin etrafındaki beş sensörden alınan değerler kullanılarak, kanadın arkasındaki altıncı sensördeki akış dinamiklerinin kestirilmesi amaçlanmaktadır. Ele alınan problem,  $k$  anındaki gözlemlere bakarak  $k + D$  anındaki bilgilerin tahmini şeklinde olup,  $D$  arttıkça problemin çözülebilirliği azalmaktadır. Hesaplamalı akışkanlar dinamiği (HAD) benzetimleri ile veri toplandıktan sonra, değişik işlemsel zeka yöntemleri kullanılarak tahmin ediciler oluşturulmuştur. Bu yöntemler: İleri Sürümlü Yapay Sinir Ağları (İSYSA<sup>1</sup>), Uyarlamalı Nöro Bulanık Çıkarım Mekanizması (UNBÇM<sup>2</sup>), Merkezci Taban Fonksiyonlu Sinir Ağları (MT-FYSA<sup>3</sup>), ve En Küçük Karelere Dayalı Destek Vektör Makinası (EKKDDVM<sup>4</sup>). Bahsi geçen bu dört yöntemin yanı sıra, denektaşı olarak da basit bir doğrusal kestirici tasarlanmıştır. Benzetim sonuçlarından, İSYSA ve UNBÇM tabanlı tahmin edicilerin en iyi başarıyı gösterdikleri, ve tüm kestiricilerin basit doğrusal kestiriciye göre üstün sonuç verdiği gözlemlenmiştir.*

---

\*Yrd. Doç. Dr., Elektrik ve Elektronik Mühendisliği Bölümü, E-posta: kasnakoglu@etu.edu.tr

†Doç. Dr., Elektrik ve Elektronik Mühendisliği Bölümü, E-posta: onderefe@etu.edu.tr

<sup>1</sup>İng. Feedforward Neural Networks

<sup>2</sup>İng. Adaptive Neuro Fuzzy Inference System

<sup>3</sup>İng. Radial Basis Function Neural Network

<sup>4</sup>İng. Least Squares Support Vector Machines

## GİRİŞ

Yapay Sinir Ağları (YSA), gözlemsel verilerden öğrenebilme kabiliyetleri sayesinde çok farklı alanlarda uygulanmış olup, özellikle verinin içinde doğrudan görülmesi çok zor olan saklı gerektirimler bulunduğu durumlarda büyük faydalar sağlamaktadır. YSA uygulama alanları içerisinde sistem tanılama ve kontrol (araç kontrolü, süreç kontrolü), oyun kuramı ve karar verme (tavla, satranç, yarış), örüntü tanıma (radar sistemleri, yüz tanılama, nesne tanıma), dizi tanıma (el hareketleri, konuşma ve yazı tanıma), tıbbi tanı koyma, mali uygulamalar (otomatik alım satım), veri madenciliği, görselleştirme, ve elektronik posta mesaj yağanağı süzülmesi sayılabilir [13]. Çok sayıda YSA biçimi mevcut olmakla beraber, her birinin kendine özgü getiri ve götürüleri vardır.. En yaygın YSA türlerinden biri İSYSA olup, bunların evrensel yaklaşıklayıcı oldukları bilinmektedir [19].

Bir başka YSA türü olan MTFYSA, değeri sadece bir merkezden uzaklığa bağlı olan özel fonksiyonların etkinleştirme fonksiyonu olarak kullanılması prensibine dayanır. MTFYSA üzerinde de yoğun araştırmalar yapılmış olup, bunlar arasında evrensel yaklaşıklama kabiliyeti [18], çok değişkenli aradeğerleme [20] ve MTFYSA sınıflandırıcılarının eğitimi [17] ile ilgili çalışmalar sayılabilir.

MTFYSA, her giriş değerinin bir çekirdek fonksiyonu ile ilişkilendirildiği çekirdek metodlarına [6] bir örnektir (MTFYSA için çekirdek fonksiyonu merkezci taban fonksiyonudur). Bir başka önemli çekirdek metodu ise Destek Vektör Makinasıdır (DVM). DVM yönteminde önce, azami ayırıcı hiperdüzlemi içinde barındıran yüksek boyutlu bir öznitelik uzayı oluşturulur ve giriş vektörleri bu uzaya gönderilir. Bunun ardından bu azami ayırıcı hiperdüzlemin her iki tarafında veriyi ayıran hiperdüzlemler oluşturulur. Bu iki paralel hiperdüzlem arasındaki uzaklığı en büyük yapan hiperdüzlem ise ayırma hiperdüzlemi olarak belirlenir. DVM yönetimini çok önemli bir özelliği, ampirik sınıflandırma hatasını en küçük yaparken, aynı anda geometrik payı en büyük yapmasıdır. Bu özelliğiyle, genellikle en büyük olabilirlik çatısı altında olasılığı en büyük değerine (hatayı da en küçük değerine) ulaştırma gayesiyle eğitilen MTFYSA'dan farklılık gösterir. DVM ile ilgili detaylı bilgiye [7, 8] kaynaklarından ulaşılabilir. EKKDDVM, DVM'nin özel bir durumu olup, eşitsizlik kısıtlarını eşitlik kısıtlarına çevirme fikrine dayanır ve bağlanım problemleri için çok uygundur [5].

Bir başka önemli YSA metodu olan UNBÇM, nöro-uyarlamalı, bulanık kümeler ve dilsel tasvirlerle dayalı bir yöntemdir [14]. UNBÇM üzerindeki çalışmalara örnek olarak MTFYSA ile fonksiyonel denklik [15], modelleme ve kontrol için tasarım yöntemleri [2], ve dönen araçlarda arızalanmanın algılanması [3] gibi pratik uygulamalar gösterilebilir.

Bu bildiride, yukarıda bahsedilen yöntemlerin üç elemanlı bir kanat profili üzerindeki hava akımının hız ve basınç tahmini için kullanılması irdelenmiştir. Kanat tasarımı ve analizi, aerodinamik alanının en önemli konularından biri olup, bu alandaki özel bir problem olan eldeki ölçümlerden bir kanat profili üzerindeki akış özelliklerinin tespiti problemi üzerinde de pek çok bilimsel çalışmalar yapılmıştır. Kanat profilinin dinamik süratsız kalma özelliklerinin tahmini [10], kanat etrafındaki akışın kestirilmesi [11], kanat üzerindeki aerodinamik gürültünün tahmini [4], kanat ardında bırakılan hava kütlelerinin basınç ve hız tahmini [23] ve kanat profilinin rastgele titreşim özelliklerinin tahmini [21] bu çalışmalardan bazılarıdır. Bu bildiride, bir kanat profilinin çeşitli bölgelerinden alınan basınç ölçümleri kullanılarak bu ölçümlerin alındığı noktalar dışındaki bir noktanın hız ve basınç özelliklerinin, İSYSA, UNBÇM, MTFYSA ve EKKDDVM tabanlı kestiriciler kullanılarak tahmini amaçlanmıştır. Çoğu zaman ölçülmesi mümkün olan tek değer basınç olduğu için ve basınç sensörleri de kanat üzerine sınırlı sayıda konuma yerleştirilebildiğinden dolayı, bu bildiride irdelenen türde kestiricilerin pratik uygulamalarda potansiyel faydaları olabileceği kuvvetle muhtemeldir. Çalışmanın bundan sonraki kısımları şu şekilde düzenlenmiştir: Üzerinde çalışılacak problem tanıttıldıktan sonra, takip

eden bölümde kullanılacak işlemsel zeka yöntemleri özetlenip, ardından benzetim sonuçları sunulacak, ve en son bölümünde de elde edilen sonuçlar yorumlanacaktır.

### PROBLEMİN TANIMI

Ele alınacak problem üç elemanlı bir kanat profilinin üzerindeki hava akışı olup, amaç kanadın arkasındaki basınç ve hız özelliklerini, kanadın diğer beş yerinden alınan basınç ölçümlerini kullanarak tahmin etmektir. Kanadın yandan kesiti üzerinde,  $\Omega := \Omega_1 \setminus \Omega_2$  alanı üzerindeki hava akışı incelenecek olup, burada  $\Omega_1 \subseteq \mathbb{R}^2$ ,  $[a, b] \times [c, d]$  ile verilen dikdörtgen ve  $\Omega_2 \subseteq \Omega_1$  de kanat profilinin iç kısmındaki alandır. Kanadın üzerindeki hava akışı aşağıdaki iki boyutlu sıkıştırılmaz Navier-Stokes denklemleri ile ifade edilir.

$$\begin{aligned} \frac{\partial \mathbf{q}}{\partial t} + \mathbf{q} \cdot \nabla \mathbf{q} &= -\frac{\nabla p}{\rho} + \nu \nabla^2 \mathbf{q} \\ \nabla \cdot \mathbf{q} &= 0. \end{aligned} \quad (1)$$

Burada  $t \in \mathbb{R}_+$  zaman değişkeni,  $(x, y) \in \Omega$  akış alanı içindeki bir noktanın koordinatları,  $\nu \in \mathbb{R}_+$  kinematik viskozite,  $\mathbf{q} : \Omega \times \mathbb{R}_+ \rightarrow \mathbb{R}^2$  akış hızı,  $p : \Omega \times \mathbb{R}_+ \rightarrow \mathbb{R}$  basınç ve  $\rho \in \mathbb{R}_+$  hava yoğunluğudur.

$\mathbf{q}$ 'nin yatay bileşenini  $u$ , dikey bileşeni de  $v$  olarak adlandırılacaktır. Akışın başlangıç koşulları

$$u(x, y, 0) = v(x, y, 0) = 0 ; (x, y) \in \Omega \text{ için}$$

olup sınır koşulları da

$$u(a, y, t) = u_{\text{in}}, v(a, y, t) = 0 ; y \in [c, d], t \in \mathbb{R}_+ \text{ için}$$

$$u(x, c, t) = u_{\text{in}}, v(x, c, t) = 0 ; x \in [a, b], t \in \mathbb{R}_+ \text{ için}$$

$$u(x, d, t) = u_{\text{in}}, v(x, d, t) = 0 ; x \in [a, b], t \in \mathbb{R}_+ \text{ için}$$

$$\frac{\partial p}{\partial x}(b, y, t) = 0 ; y \in [c, d], t \in \mathbb{R}_+ \text{ için}$$

$$u(x, y, t) = v(x, y, t) = 0 ; (x, y) \in \partial\Omega_2, t \in \mathbb{R}_+ \text{ için}$$


şeklindedir. Burada  $\partial\Omega_2$  kanat profilinin yüzeyini gösterir. Bu başlangıç ve sınır koşulları, örnek olarak, kanadın bir rüzgar tüneli içinde sabit duruken, birden soldan sağa  $u_{\text{in}}$  hızında hava akımı verilmesi durumunu temsil edebilir.

Şekil 1'de kanat profili geometrisi ve sensör konumları ile, sayısal benzetimlerde kullanılan örgü gösterilmiştir. Sayısal benzetimler MATLAB altında *Navier2d* çözücüsü ile gerçekleştirilmiştir [1]. Basınç sensörleri kanadın ilk ögesinin ön (S1) ve arkasında (S2), ikinci ögesinin üst (S3) ve altında (S4), ve üçüncü ögenin ön tarafında (S5) yer almaktadır. Sensör ölçüleri her  $\Delta t$  saniyede bir alınmaktadır; buradaki  $\Delta t$  zaman adıdır. Amaç kanadın arkasındaki (S6) akış özelliklerini, S1-S5 sensörlerinden gelen basınç ölçümleri doğrultusunda tahmin etmektir. Bir miktar sensör ve işlem gecikmelerini de dikkate almak için şu anki zamandan  $D \in \mathbb{N}$  zaman adımı sonraki akışı tahmin eden bir kestirici tasarımı üzerinde durulacaktır. Bir başka deyişle,  $f_p, f_u, f_v : \mathbb{R}^5 \rightarrow \mathbb{R}$  biçiminde ve


$$p_6(k + D) = f_p(p_1(k), p_2(k), p_3(k), p_4(k), p_5(k))$$

$$u_6(k + D) = f_u(p_1(k), p_2(k), p_3(k), p_4(k), p_5(k))$$

$$v_6(k + D) = f_v(p_1(k), p_2(k), p_3(k), p_4(k), p_5(k))$$



Şekil 1: Kanat profili geometrisi, sensör konumları ve sayısal benzetimlerde kullanılan örgü.



Şekil 2: İki adet gizli katmanı olan tek çıkışlı bir ağ yapısı

olan üç fonksiyonun bulunması istenmektedir. Burada,  $k \in \mathbb{N}$ ,  $p_1(k) := p(x_{S1}, y_{S1}, t_k)$ ,  $t_k = k\Delta t$  şeklinde olup,  $(x_{S1}, y_{S1}) \in \partial\Omega_2$  de S1 sensörünün konumudur.  $p_2(k)$ ,  $p_3(k)$ ,  $p_4(k)$ ,  $p_5(k)$  de benzer şekilde tanımlanabilir. Girişte de ifade edildiği gibi,  $f_p$ ,  $f_u$  and  $f_v$  fonksiyonlarını bulmak için dört farklı işlemsel zeka mimarisi kullanılacak olup, takip eden bölümde bu mimariler kısaca açıklanacaktır.

## MODELLEME YAKLAŞIMLARI

Bu kısımda bildiriye konu dört yöntemin analitik tarifleri yapılacaktır. Bu yöntemler sırasıyla İSYSA, MTFYSA, UNBÇM, EKKDDVM'dir.

### İleri Sürümlü Yapay Sinir Ağları (İSYSA)

Şekil 2'de iki adet gizli katmanı olan,  $m$  girişli tek çıkışlı bir İSYSA yapısı gösterilmektedir. Bu yapıların nümerik gözlemlere dayalı modelleme problemlerinde sıklıkla tercih edilmelerinin temel nedeni büyük veri kümelerinde değişkenler arasında doğrudan görülmesi zor olan ilişkileri ortaya çıkarmaktaki marifetleridir. Ağ yapısının konfigürasyonunun kolayca değiştirilebilir olması, çok çeşitli öğrenme algoritmalarının bulunması bu sistemleri modelleme konularında dikkate değer alternatiflerden biri kılmaktadır.

İSYSA yapısı ile öğrenme için aşağıdaki çiftler üzerinden bir bağlanım<sup>5</sup> problemi kurgulanmaktadır.

$$\mathcal{T} = \{(\mathbf{u}_1, \mathbf{d}_1), \dots, (\mathbf{u}_{N_T}, \mathbf{d}_{N_T}, \mathbf{d}_{N_T})\}, \quad \mathbf{u}_i \in \mathbb{R}^m, \quad \mathbf{d}_i \in \mathbb{R}^n \quad (2)$$

Ağ yapısındaki gizli katman sayısı  $H$  ile gösterilmekte ve  $i$ . katmanın çıkış vektörü  $\mathbf{h}_i$  ile tanımlanmaktadır. Burada  $\mathbf{h}_i = \Phi(\mathbf{s}_i)$  dir ve  $\mathbf{s}_i$  değerleri aşağıda açık ifadesi verilen net toplamlara tekabül etmektedir.

$$\mathbf{s}_i = \mathbf{w}_i \mathbf{h}_{i-1} + \mathbf{B}_i, \quad i = 1, 2, \dots, H \quad (3)$$

Burada  $\mathbf{w}_i$  ve  $\mathbf{B}_i$  değerleri  $i$ . katman için sırasıyla ağırlık parametrelerini ve öteleme terimlerini göstermektedir. Şekil 2'de gösterilen ağ yapısı için ileri yönde geçiş<sup>6</sup> (4) ile hesaplanmaktadır.

$$\mathbf{h}_0 = \mathbf{u} \quad (4a)$$

$$\mathbf{s}_1 = \mathbf{w}_1 \mathbf{h}_0 + \mathbf{B}_1 \quad \text{and} \quad \mathbf{h}_1 = \tanh(\mathbf{s}_1) \quad (4b)$$

$$\mathbf{s}_2 = \mathbf{w}_2 \mathbf{h}_1 + \mathbf{B}_2 \quad \text{and} \quad \mathbf{h}_2 = \tanh(\mathbf{s}_2) \quad (4c)$$

$$\mathbf{s}_3 = \mathbf{w}_3 \mathbf{h}_2 + \mathbf{B}_3 \quad \text{and} \quad \mathbf{f} = \mathbf{s}_3; \quad (4d)$$

Bu tarife göre ağ yapısının giriş-çıkış ilişkisi  $\mathbf{f} = \mathbf{w}_3 \tanh(\mathbf{w}_2 \tanh(\mathbf{w}_1 \mathbf{u} + \mathbf{B}_1) + \mathbf{B}_2) + \mathbf{B}_3$  ile verilmektedir. Yapısal tercihler yapıldıktan sonra tasarımcının karar vermesi gereken bir diğer husus da bu tercihlere uygun bir öğrenme algoritmasının seçilmesidir. Literatürde bu ağ yapısı için çok sayıda öğrenme algoritması bulmak mümkündür; ancak, hızı ve yakınsama hassasiyeti açısından bu yapıya en uygun yöntemlerden birisi Levenberg-Marquardt (LM) optimizasyon tekniğidir. Bu teknik Newton yöntemine bir yaklaşımdan ibaret olup yaklaşıklığın uygulanış biçiminden dolayı hem eğim düşümü hem de Newton yönteminin müsbet vasıflarını barındırıp matris tersi alma işlemindeki tekillik problemlerinden etkilenmez, [16, 12]. LM eğitim algoritmasının uygulanması safhasında uyarlanabilir tüm parametreler düzenlenerek vektör haline getirilir.. Bu bildiride uyarlanabilir parametre vektörü  $\omega$  değişkeni ile gösterilmektedir ve bu vektör  $P \times 1$  boyutludur. Bir  $k$  anında aradeğerlemenin başarımını göstermek için (5) ile verilen ampirik risk fonksiyonu tanımlanmaktadır.

$$E(\omega_k) = \frac{1}{2} \sum_{i=1}^{N_T} \|\mathbf{d}_i - \mathbf{f}(\mathbf{u}_i, \omega_k)\|^2 \quad (5)$$

Bu ifadeye göre LM öğrenme algoritmasının öngördüğü parametre güncelleme kuralı aşağıdaki gibi olacaktır.

$$\omega_{k+1} = \omega_k - (\alpha \mathbf{I} + \nabla_{\omega_k}^2 E(\omega_k))^{-1} \nabla_{\omega_k} E(\omega_k) \quad (6)$$

Burada  $\alpha > 0$  ile verilen değişken kullanıcı tarafından seçilen bir değişkendir,  $\mathbf{I}$  ise ifadeye uygun boyutları olan bir birim matrisi göstermektedir.  $\alpha$  değişkeninin çok küçük

<sup>5</sup>İng. Regression

<sup>6</sup>İng. Forward pass

değerleri için yukarıdaki uyarlama kuralı Gauss-Newton metodunun öngördüğü parametre güncelleme kuralına benzer davranırken tersi durumda güncelleme kuralı eğim düşümü kuralının öngörülerine benzer davranır ve LM algoritması bu parametrenin uygun seçimi ile her iki yöntem arasında yumuşak bir geçiş sağlayarak iyi performansın elde edildiği bir neticeyi üretir.

### Merkezcil Taban Fonksiyonlu Yapay Sinir Ağları (MTFYSA)

Merkezcil taban fonksiyonlu sinir ağı yapıları yapay sinir ağları konusunun özel bir alanını teşkil eder. Bu yaklaşım giriş uzayının taban fonksiyonları yardımıyla alt uzaylara bölünmesi esasına dayalı olup kararların alt uzaylar üzerinde alınmasının pratikliği açısından önem arz eder. Bir MTFYSA yapısının çıkışı, nitelik vektörlerini barındıran nöron çıkışlarının ağırlıklı toplamı ile hesaplanır. Yapıyı oluşturan nöronların çıkışı (7) ile hesaplanır.

$$f = \sum_{i=1}^H \mathbf{y}_i \mathbf{h}_i \quad (7)$$

burada

$$\mathbf{h}_i = \prod_{j=1}^m \mu_{ij}(u_j, c_{ij}, \sigma_i, \phi_{ij}) . \quad (8)$$

MTFYSA yapısının uyarlanabilir parametreleri taban fonksiyonlarının  $c_{ij}$  ile gösterilen merkez değişkenleri, yayılma değişkenleri ( $\sigma_i$ ),  $\phi_{ij}$  ile gösterilen biçim değişkenleri ve  $\mathbf{y}_i$  ile gösterilen ağırlık parametreleridir. Uyarlama mekanizması olarak (6) ile verilen LM algoritması kullanılmaktadır.

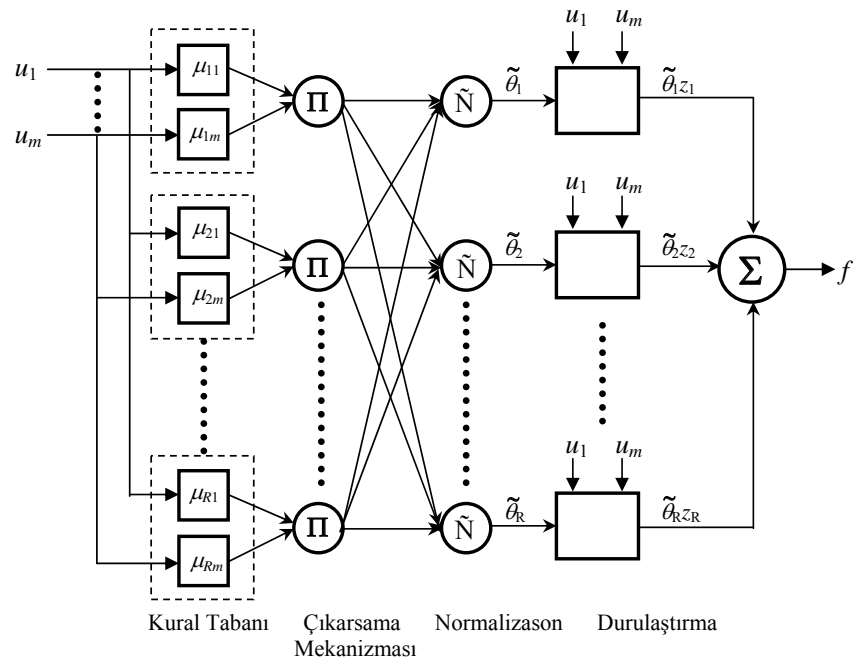
### Uyarlamalı Nöro Bulanık Çıkarım Mekanizmaları (UNBÇM)

Bulanık mantık, insanın düşünüş ve algılayış biçimine uygun bir bilgi gösterilimi tasvir ettiği için gerçek zamanlı birçok mühendislik probleminin çözümünde düşünülen alternatifler arasında yer almıştır. Özünde bir önceki altbölümde verilen giriş uzayının alt uzaylara bölünmesi gerçeğini taşıyan bulanık çıkarım mekanizmaları, durulaştırma<sup>7</sup> safhasındaki seçeneklerin çokluğu, kuralların oluşturulmasındaki sistematik yaklaşımlar, ve koşulların birlikteliği ile varılacak yargılardaki doğrallık süreçleri dolayısıyla düşünüşün sözel gücünü kullanan, diğer yandan türevlenebilir bileşenlerle kurulabilmesi ve parametrik olabilmesi dolayısıyla üzerinde parametre güncelleme olanağı bulunduran bu sistemler bu bildiri de benzer motivasyonlarla ele alınmaktadır, [14]. Şekil 3'de UNBÇM yapısının bileşenleri gösterilmektedir. Duru girişler üyelik fonksiyoları aracılığı ile bulanıklaştırılmakta, böylelikle giriş vektörü bulanık kümelerce karakterize edilen bir nitelik uzayı<sup>8</sup> vektörüne eşleştirilmektedir. Çıkarsama mekanizmasında ise üyelik değerleri her bir kural için bir aktifleşme derecesine dönüştürülür. Bu aktifleşme derecelerinin normalize edilmesini müteakip yer alan durulaştırıcı, öngörülen -şekle göre skalar- çıkış değerini üretir.

Şekilde  $\theta_i$  değişkeni bir kurala ait aktifleşme derecesini,  $\tilde{\theta}_i$  ise o kurala ait normalize edilmiş aktifleşme derecesini göstermektedir. Kural tabanında EĞER  $u_1 \in \mathbb{U}_{r,1}$  VE  $u_2 \in \mathbb{U}_{r,2}$  VE ... VE  $u_m \in \mathbb{U}_{r,m}$  İSE  $y_r = z_r$  yapısına sahip  $R$  adet kural içeren bir UNBÇM sisteminin

<sup>7</sup>İng.. Defuzzification

<sup>8</sup>İng. Feature space



Şekil 3: UNBÇM Yapısının iç bağlaşımı

çarpım tipinde çıkarım sistemi ve Sugeno tipinde durulaştırıcı seçimleriyle betimlenen giriş-çıkış ilişkisi (9a)-(9d) ile verilmektedir [22]. Burada  $\mathcal{U}_{r,i}$ 'ler bulanık kümeleri,  $y_r$  ise  $r$ . kuralın yerel öngörüsünü simgeler.

$$\theta_i = \prod_{j=1}^m \mu_{ij}(u_j) \quad (9a)$$

$$\tilde{\theta}_i = \frac{\theta_i}{\sum_{k=1}^R \theta_k} \quad (9b)$$

$$z_i = \zeta_i + \sum_{j=1}^m \phi_{ij} u_j \quad (9c)$$

$$f = \sum_{i=1}^R \tilde{\theta}_i z_i \quad (9d)$$

Yukarıda (9a) ve (9c) denklemlerinde  $u_j$  değişkeni  $\mathbf{u}$  ile gösterilen giriş vektörünün  $j$ . elemanına tekabül eder. UNBÇM sisteminin parametrelerinin uyarlanması melez bir güncelleme yaklaşımı ile gerçekleştirilmektedir. Daha açık ifade etmek gerekirse  $\zeta_i$  ve  $\phi_{ij}$  değişkenleri en küçük kareler yaklaşımıyla, diğer parametreler ise eğim düşümü yöntemi ile güncellenmektedir. Bu türde bir melez yaklaşımın kullanılmasının sebebi, [14] kaynağında da belirtildiği gibi eğim düşümü algoritmasının arama uzayını daraltması ve yakınsama hızını arttırmasıdır.



### En Küçük Karelere Dayalı Destek Vektör Makinaları (EKKDDVM)

Destek vektör makinaları ampirik risk foksionu yerine yapısal risk fonksiyonunun enküçüklenmesine dayanan alternatif bir yaklaşımdır. Önceki üç altbölümde tanıtılan yaklaşımlar ampirik risk fonksiyonunun enküçüklenmesini amaçlayan yaklaşımlardır ve bu kısımda maliyet fonksiyonunun farklı tanımlanması ve eğitim sürecinin bir optimizasyon süreciyle yer değiştirmesi neticesinde elde edilen EKKDDVM sistemlerinin başarımları üzerinde durulmaktadır. Özellikle sınıflandırma problemlerinde oldukça üstün neticeler veren destek vektör makinaları bağlanım problemlerinde önemli ölçüde iyi sonuçlar üretebilmektedir.

En küçük karelere dayalı destek vektör makinaları, klasik anlamda destek vektör makinalarından farklıdır. Eşitsizlik kısıtlarının eşitlik kısıtlara dönüştürülmesi ve seyreklik<sup>9</sup> niteliğinin kaybı bu yapılarla beraber gelen farklılıklardır. Bu bildiride EKKDDVM yapısı ele alınmakta ve her bir yaklaşım için istenen çıkış değerlerine olabildiğince yaklaşılması beklenmektedir.

Aşağıdaki çiftler kümesi üzerinden bir bağlanım işlemi gerçekleştirilecektir ve bağlanım probleminin çözümü ile (11) ifadesinde verilen  $f$  fonksiyonu elde edilecektir.

$$\mathcal{T} = \{(\mathbf{u}_1, d_1), \dots, (\mathbf{u}_{N_{\mathcal{T}}}, d_{N_{\mathcal{T}}})\}, \quad \mathbf{u}_i \in \mathbb{R}^m, \quad d_i \in \mathbb{R} \quad (10)$$

$$f(\mathbf{u}) = \mathbf{w}^T \varphi(\mathbf{u}) + \delta \quad (11)$$

Burada  $\mathbf{w}$  ve  $\delta$  değişkenleri sırasıyla ağırlık parametreleri vektörünü ve öteleme değerini göstermektedir. İfadede yer alan  $\varphi$  doğrusal olmayan bir işlevi simgelemektedir ve destek vektör makinalarının eğitiminde başvurulan *çekirdek hilesine*<sup>10</sup> uygun bir eşleştirmedir.  $i$ . çifti ilgilendiren hata değişkeninin  $e_i := d_i - f(\mathbf{u}_i)$  şeklinde tanımlanması ve (12) ile verilen yapısal risk fonksiyonunun enküçüklenmesi  $\|\mathbf{w}\|^2$  ile ifade edilen yapısal karmaşıklığın asgari olduğu  $\mathbf{w}_i$ 'lerin elde edilmesini mümkün kılar.

$$R = \frac{1}{2} \|\mathbf{w}\|^2 + \frac{C}{2} \sum_{i=1}^{N_{\mathcal{T}}} e_i^2 \quad (12)$$

Yukarıdaki yapısal risk fonksiyonu ifadesinde  $C$  değişkeni ifadedeki terimlerin  $R$  üzerindeki etkisini belirleyen bir ağırlık parametresidir, [9]. Denklem (12)'e göre,  $C$  değişkeninin değerce büyük seçilmesi verilen nümerik verilere daha iyi bir yaklaşıma sağlar. Enyileme probleminin birincil biçimi<sup>11</sup> aşağıda verilmiştir.

$$\min_{\mathbf{w}, \delta, e} \frac{1}{2} \|\mathbf{w}\|^2 + \frac{C}{2} \sum_{i=1}^{N_{\mathcal{T}}} e_i^2 \quad (13)$$

such that  $d_i = \mathbf{w}^T \varphi(\mathbf{u}_i) + \delta + e_i, \quad i = 1, 2, \dots, N_{\mathcal{T}}$

<sup>9</sup>İng. Sparseness

<sup>10</sup>İng. Kernel trick

<sup>11</sup>İng. Primal form



Bu biçim,  $\lambda$  ile gösterilen Lagrange çarpanlarının kullanılmasıyla aşağıda verilen ikincil biçime<sup>12</sup> dönüştürülebilir ve eniyileme probleminin çözümü Lagrangian'ın semer noktasında elde edilir, yani aranan nokta  $\max_{\lambda} \min_{\mathbf{w}, \delta, e} \mathcal{L}(\mathbf{w}, \delta, e, \lambda)$  ile ifade edilmektedir.

$$\mathcal{L}(\mathbf{w}, \delta, e, \lambda) = \frac{1}{2} \|\mathbf{w}\|^2 + \frac{C}{2} \sum_{i=1}^{N_T} e_i^2 - \sum_{i=1}^{N_T} \lambda_i (\mathbf{w}^T \varphi(\mathbf{u}_i) + \delta + e_i - d_i) \quad (14)$$

Bu nokta için optimallik koşulları aşağıda verilmiştir.

$$\frac{\partial \mathcal{L}}{\partial \mathbf{w}} = 0 \implies \mathbf{w} = \sum_{i=1}^{N_T} \lambda_i \varphi(\mathbf{u}_i) \quad (15)$$

$$\frac{\partial \mathcal{L}}{\partial \delta} = 0 \implies \sum_{i=1}^{N_T} \lambda_i = 0 \quad (16)$$

$$\frac{\partial \mathcal{L}}{\partial e_i} = 0 \implies \lambda_i = C e_i, \quad i = 1, 2, \dots, N_T \quad (17)$$

$$\frac{\partial \mathcal{L}}{\partial \lambda_i} = 0 \implies \mathbf{w}^T \varphi(\mathbf{u}_i) + \delta + e_i - d_i = 0, \quad i = 1, 2, \dots, N_T \quad (18)$$

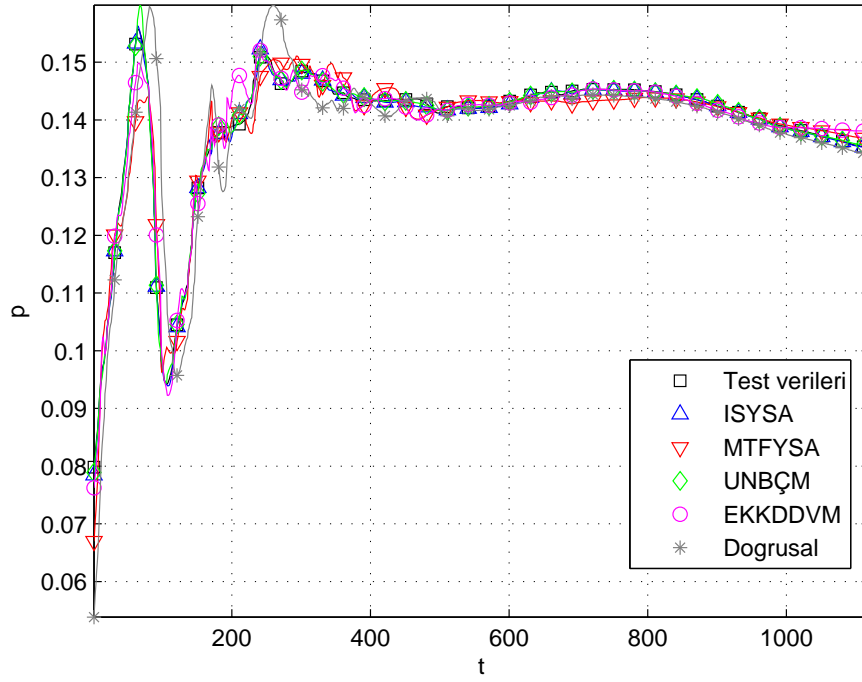
Çözüm, aşağıda verilen  $N_T + 1$  adet denklemin birlikte çözümü ile elde edilir.

$$\delta + \frac{\lambda_k}{C} - d_k + \sum_{i=1}^{N_T} \lambda_i \varphi(\mathbf{u}_i)^T \varphi(\mathbf{u}_k) = 0, \quad k = 1, 2, \dots, N_T \quad (19)$$

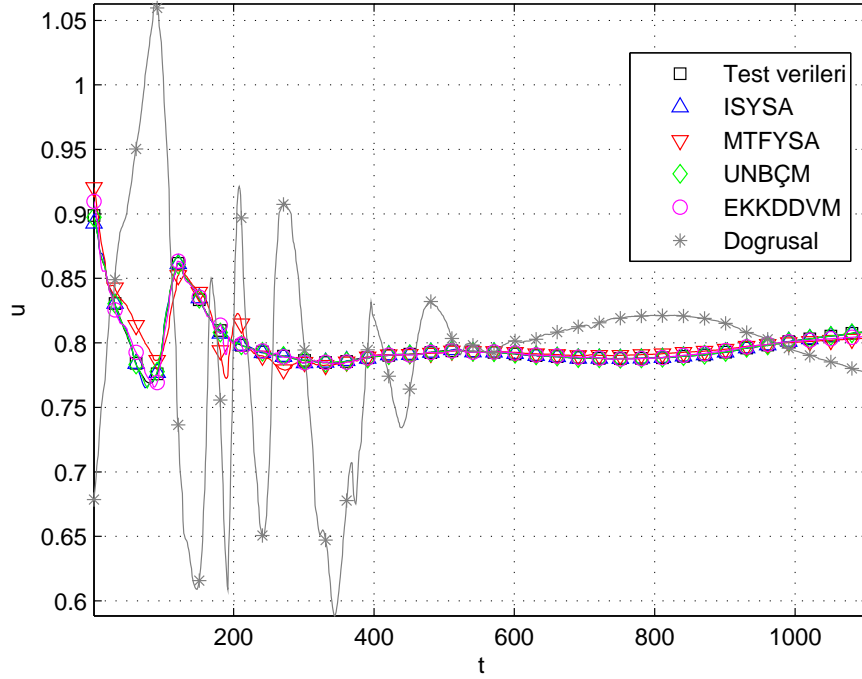
## BENZETİM SONUÇLARI


Bu bölümde elde edilen benzetim sonuçları tartışılacaktır.. Deneyler için ilk aşama, eğitim, denetim ve test için veri kümeleri oluşturulmasıdır. İkinci bölümde anlatılan ve Şekil 1'de gösterilen sistem MATLAB altında Navier2d çözücüsü ile  $25.2 \times 10^{-3}$  saniyelik bir zaman için benzetilmiş olup, kullanılan zaman adımı  $\Delta t = 1.5112 \times 10^{-5}$  saniyedir ve bu da 1666 anlık değere karşılık gelmektedir. Sistem parametleri için de şu değerler kullanılmıştır:  $a = -0.75 \text{ m}$ ,  $b = 2.25 \text{ m}$ ,  $c = -1 \text{ m}$ ,  $d = 1 \text{ m}$ ,  $\rho = 1 \text{ kg/m}^3$ ,  $\nu = 10^{-5} \text{ m}^2/\text{s}$ ,  $u_{\text{in}} = 68 \text{ m/s}$  ( $\approx \text{Mach } 0.2$ ). Eğitim verisi oluşturmak için öncelikle benzetim verilerini işlemsel zeka yöntemleri için uygun bir aralığa getirmek gereklidir; bunu için  $p$  için olan benzetim verileri 1000 ile,  $u$  için olanlar 65 ile ve  $v$  için olanlar da 30 ile ölçeklenmiştir. Eğitim veri sayısı  $N_T = 400$  alınarak bu satırlar rastgele seçilmiştir. Kestiricinin girişleri S1-S5 sensörlerinden gelen bilgiler olup, istenen çıkış da  $D = 20$  zaman adımı sonra S6 konumundaki hız ve basınç değerleridir. Zamanda ileriye yönelik tahminlerde basit kestiricilerin başarısı hızla düştüğünden, bu tür problemler önerilen kestiricilerin değerlendirilmesi için daha uygun olmaktadır. Veri seçimi sırasında eğitim için seçilen veriler işaretlenerek sadece bir defa kullanılmaları sağlanmıştır. Eğitimi durdurma kararı için kullanılacak denetim verileri için  $N_C = 100$  alınmış, eğitim ve denetim verileri dışında kalan veriler de test için kullanılmıştır.

<sup>12</sup>İng. Dual form



Şekil 4: Basınç için tahmin sonuçları

Şekil 5: Hızın  $u$  bileşeni için tahmin sonuçları



Şekil 6: Hızın  $v$  bileşeni için tahmin sonuçları

İSYSA yaklaşımında saklı katman için nöron sayıları  $H_1 = 15$  and  $H_2 = 8$  olup, hiperbolik tanjant tipi nöronlar ile tek bir nörondan oluşan doğrusal çıkış katmanı kullanılmıştır. İSYSA yapısında bu şekliyle 227 ayarlanabilir parametre bulunmaktadır. UNBÇM yaklaşımda her giriş için iki dilbilimsel etiket kullanılmış olup, böylece toplam 32 kural ve 222 ayarlanabilir parametre elde edilmiştir. MTFYSA durumunda ise, taban fonksiyonları için Gauss fonksiyonları ve  $H = 32$  saklı nöron kullanılmış olup, bu yapılandırmadaki ayarlanabilir parametre sayısı 225'tir. EKKDDVM yaklaşımında ise, *bspline* çekirdek fonksiyonları kullanılmış ve  $C = 10$  alınmıştır. Bu yaklaşımda klasik DVM yaklaşımındaki seyreklik özellikleri yitirildiğinden dolayı [5], bütün eğitim verileri destek vektörü olarak içerilmektedir. Tüm işlemsel zeka yaklaşımları için yakın ayarlanabilir parametre sayılarının seçilmiş olması yöntemlerin birbirine yakın karmaşıklık derecelerine sahip olmalarına ve böylece adil bir kıyaslama yapılabilmesine olanak vermektedir.

Üç grup deney yapılmış olup, bütün durumlarda tahmin edicilerin girişi S1-S5 sensörlerinden gelen basınç olmakla beraber, birinci durum için tahmin edilmek istenen değer S6 konumundaki basınç  $p$ , ikinci durumda tahmin edilmek istenen değer S6 konumundaki hızın  $u$  bileşeni, ve üçüncü durumda tahmin edilmek istenen değer de S6 konumundaki hızın  $v$  bileşenidir. Tüm durumlar için, bağımsız eğitim ve test deneyleri gerçekleştirilmiştir. Bu deneylerin sonucunda, eğitim evresi için elde edilen ortalama karesel hata (OKH) değerleri, Tablo 1'de görülebilir. Bu tabloya bakıldığında, en küçük OKH değerlerinin UNBÇM ve İSYSA tabanlı kestiriciler için elde edildiği görülmektedir. MTFYSA ve EKKDDVM yöntemlerinin önceki iki metoda göre daha kötü sonuç verdiği görülmektedir. Bu dört YSA yaklaşımının dışında, denektaş olarak  $S6(k+20) = \sum_{i=1}^5 \omega_i S_i(k)$  şeklinde basit bir doğrusal karesel kestirici tasarlanmıştır.

Tablo 1'deki değerler eğitim algoritmalarının kullandığı ve sonuçları uydurmaya çalıştığı eğitim verileri için olduğundan, genel olarak oldukça düşük değerli olmaları normaldir. Yöntemlerin daha önce görmedikleri test verileri için başarıları ise Tablo 2'de görülebilir. Tablodan görüleceği üzere, bu durum için de UNBÇM ve İSYSA yaklaşımları hedef verilere

Yöntem	$p$ tahmini	$u$ tahmini	$v$ tahmini
İSYSA	1.4194e-007	1.6056e-007	1.928e-005
MTFYSA	8.8575e-006	6.1744e-005	2.3624e-004
UNBÇM	2.5051e-009	4.4698e-011	3.8114e-009
EKKDDVM	1.2413e-005	1.5837e-005	3.9192e-004
Doğrusal	4.0742e-005	6.9796e-003	1.5509e-002

Tablo 1: Eğitim verileri için OKH değerleri

Yöntem	$p$ tahmini	$u$ tahmini	$v$ tahmini
İSYSA	3.1378e-007	7.7433e-007	3.2086e-005
MTFYSA	8.8575e-006	6.1744e-005	2.3624e-004
UNBÇM	3.5955e-007	6.1744e-005	3.1844e-005
EKKDDVM	4.4334e-006	5.7278e-006	1.4110e-004
Doğrusal	4.0742e-005	7.0000e-003	1.5500e-002

Tablo 2: Test verileri için OKH değerleri

en yakın tahminleri vermektedirler. MTFYSA ve EKKDDVM yöntemleri istenilen değerleri UNBÇM ve İSYSA'ya göre daha başarısız şekilde tahmin etmekte olup, doğrusal kestirici ise kabul edilemeyecek derecede kötü sonuçlar vermektedir.

Şekil 4'te basınç ölçümlerinden basınç tahminleri, Şekil 5'te basınç ölçümlerinden akış hızının  $u$  bileşeni tahminleri, ve Şekil 6'da da basınç ölçümlerinden akış hızının  $v$  bileşeni tahminleri görülmektedir. Şekillerden görüleceği üzere, doğrusal kestirici dışındaki tüm yöntemler aşağı yukarı istenilen sonucu vermekle beraber, en iyi tahminler UNBÇM ve İSYSA tabanlı kestiriciler için elde edilmiştir.

Bu noktada, ayarlanabilir parametre sayısı artırılarak daha iyi sonuçlar elde edilebilir mi sorusu sorulabilir. Gerçekleştirilen çok sayıda deneye dayanarak bu soruya evet cevabı verilebilir; ancak tüm yaklaşımlar için ayarlanabilir parametre sayısı birbirine yakın tutulduğu takdirde, UNBÇM ve İSYSA yine en başarılı yöntemler olarak ortaya çıkmaktadır.

## SONUÇLAR

Bu çalışmada çeşitli işlemsel zeka yöntemleri kullanılarak bir kanat profili üzerindeki hava akışının hız ve basınç değerlerinin tahmini ele alınmıştır. Pek çok hava akış problemi yapılanmasında ölçülmesi mümkün olan tek akış değişkeninin basınç olduğu, ve basınç sensörlerinin sınırlı sayıda konuma yerleştirilebildiği göz önüne alınırsa bildiride irdelenen konunun önemi daha iyi anlaşılacaktır. Böyle bir yapılanmada basınç dışındaki akış verilerinin de tahmin edilebilmesi, ve sensörlerin bulunduğu yerler dışındaki konumlar için de bu tahminlerin yapılabilmesinin pek çok pratik uygulamalarda fayda sağlayabileceği açıktır. Ele alınan sistemin dağıtılmış parametreliliği bir sistem olması ve ilgilenilen konumda geçmişe ait değerlerin kullanılamaması ise problemin zorluğunu artıran öğelerdir. İstenilen tahminleri elde etmek amacı ile İSYSA, UNBÇM, EKKDDVM ve MTFYSA tabanlı yaklaşımlar ile, denektaşı olarak basit bir doğrusal kestirici tasarlanmıştır. Tüm yöntemler için benzer sayıda ayarlanabilir parametre seçilerek karmaşıklık derecelerinin birbirine yakın olması ve adil bir kıyaslama olanağı oluşması sağlanmıştır. Yapılan benzetimler sonucunda, hem eğitim verileri hem de daha önceden görülmemiş test verileri için UNBÇM ve İSYSA yöntemlerinin en başarılı yöntemler oldukları ortaya çıkmış, MTFYSA ve EKKDDVM yaklaşımlarının diğer iki yönteme göre daha büyük OKH değerleri verdikleri gözlemlenmiş, basit doğrusal kestiricinin başarımının ise oldukça düşük olduğu görülmüştür.

Bu sonuçlar ışığında, bu çalışmanın ana katkıları 1) ele alınan kanat profili üzerindeki hava akışı problemi için, işlemsel zeka yöntemleri ile zamanda ileriye yönelik tahminlerin yapılabileceğinin ortaya çıkarılması ve, 2) basınç değerleri kullanılarak başka konumlardaki hız ve basıncın kestirilmesi için incelenen dört temel işlemsel zeka yöntemi içinde UNBÇM ve İSYSA yaklaşımlarının en başarılı yaklaşımlar olduklarının gösterilmesi şeklinde özetlenebilir. Böyle bir kestiricinin elde edilmesinin genel potansiyel faydaları arasında, dinamikleri uzaysal bir alan üzerinde gelişen bir sistemin, sınırlı sayıda noktalardan alınacak ölçümler kullanılarak, yine aynı uzaysal alan üzerinde tanımlı bir başarımlı ölçütüne ulaştırılması için kontrol tasarlanması probleminde gözleyici olarak kullanılabilir olması sayılabilir. Yukarıda anılan problemlerin yanı sıra, bildiride elde edilen kestiricilerin, öngörülü<sup>13</sup> kontrol uygulamalarında kullanılabilirliğinin irdelenmesi de yazarların gelecekte planlanan çalışmaları arasında yer almaktadır.

## Kaynaklar

- [1] Engwirda, D. Navier-Stokes solver (Navier2d). MATLAB Central File Exchange, 2006
- [2] Jang, J.S.R. ve Sun, C.T. Neuro-fuzzy modeling and control. *Proceedings of the IEEE*, 83(3):378–406, 2002
- [3] Lo, S.-P. The application of an ANFIS and grey system method in turning tool-failure detection. *The International Journal of Advanced Manufacturing Technology*, 19(8):564–572, 2002
- [4] Manoha, E., Herrero, C., Sagau, P. ve Redonne, S. Numerical prediction of airfoil aerodynamic noise. In *8th AIAA/CEAS Aeroacoustics Conference and Exhibit*, Breckenridge, CO, 2002
- [5] Suykens, J.A.K., Van Gestel, T., De Brabanter, J., De Moor, B. ve Vandewalle, J. *Least Squares Support Vector Machines*. World Scientific, Singapore, 2002
- [6] Scholkopf, B. ve Smola, A.J. *Learning with Kernels: Support Vector Machines, Regularization, Optimization, and Beyond*. MIT Press, Cambridge, MA, USA, 2001
- [7] Cristianini, N. ve Shawe-Taylor, J. *An Introduction to Support Vector Machines*. Cambridge University Press, Cambridge, UK, 2000
- [8] Schölkopf, B., Burges, C.J. C. ve Smola, A.J. *Advances in Kernel Methods: Support Vector Learning*. MIT Press, 1999
- [9] Gunn, S.R. Support vector machines for classification and regression<sup>274</sup>. Technical report, ISIS Technical Report, University of Southampton, United Kingdom, 1998
- [10] Ekaterinaris, J.A. ve Platzer, M.F. Computational prediction of airfoil dynamic stall. *Progress in aerospace sciences*, 33(11-12):759–846, 1997
- [11] Davidson, L. Prediction of the flow around an airfoil using a reynolds stress transport model. *Journal of fluids engineering*, 117(1):50–57, 1995
- [12] Hagan, M.T. ve Menhaj, M.B. Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Networks*, 5:989–993, 1994

<sup>13</sup>İng. Predictive

- [13] Haykin, S. *Neural Networks: A Comprehensive Foundation*. Prentice Hall PTR, Upper Saddle River, NJ, USA, 1994
- [14] Jang, J.S.R. ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3):665–685, 1993
- [15] Jang, J.S.R. ve Sun, C.T. Functional equivalence between radial basis function networks and fuzzy inference systems. *IEEE Transactions on Neural Networks*, 4(1):156–159, 1993
- [16] Battiti, R. First- and second-order methods for learning: between steepest descent and newton's method. *Neural Computation*, 4(2):141–166, 1992
- [17] Musavi, M. T., Ahmed, W., Chan, K. H., Faris, K. B. ve Hummels, D. M. On the training of radial basis function classifiers. *Neural Netw.*, 5(4):595–603, 1992
- [18] Park, J. ve Sandberg, I. W. Universal approximation using radial-basis-function networks. *Neural Computing*, 3(2):246–257, 1991
- [19] Hornik, K., Stinchcombe, M. ve White, H. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5):359–366, 1989
- [20] Powell, M. J. D. *Radial basis functions for multivariable interpolation: a review*. Clarendon Press, New York, NY, USA, 1987
- [21] Wu, J., Sankar, L. N. ve Kaza, K. R. V. A technique for the prediction of airfoil flutter characteristics in separated flow. In *28th Structures, Structural Dynamics and Materials Conference*, pages 664–673, Monterey, CA, 1987
- [22] Takagi, T. ve Sugeno, M. Fuzzy identification of systems and its applications to modeling and control. *IEEE Transactions on Systems, Man, and Cybernetics*, SMC-15:116–132, 1985
- [23] Hah, C. ve Lakshminarayana, B. Measurement and prediction of mean velocity and turbulence structure in the near wake of an airfoil. *Journal of Fluid Mechanics*, 115:251–282, 1982