

Farklı Ölçekteki Yapay Sinir Ağlarının İnsansız Bir Helikopterin Boylamsal Davranışı Üzerinde İncelenmesi

Investigation of Artificial Neural Networks of Different Scales on the Longitudinal Behavior of an Unmanned Helicopter

Burhan PARLAK¹, Bülent ÖZKAN², Berat SEMERCİOĞLU¹

¹Titra Teknoloji, Ankara

burhan.parlak@titra.com.tr ve berat.semercioglu@titra.com.tr

² Makine Mühendisliği Bölümü

Gazi Üniversitesi, Ankara

bozkan37@gmail.com

Özetçe

Gelişen teknolojinin sonuçlarından biri olarak, insansız sistemler gerek sivil gerekse askeri birçok uygulamada insanlı öncüllerinin yerini almaktadır. Bilhassa güvenlik, doğruluk, tekrarlanabilirlik ve maliyet gibi temel başarımların istenmelerinin karşılanması bakımından sağladıkları üstünlükler dolayısıyla, otonom olarak görev yapan insansız araçlar geniş bir kullanım alanı bulmuştur. Bu çalışmada, ele alınan tek ana rotorlu döner kanat insansız hava aracının doğrusal olmayan dinamik yapısı baz alınarak boylamsal düzlemdeki davranışı öncelikle geleneksel yöntem kullanılarak bu alanda daha önce de sıkça uygulama örnekleri bulunan bir kod parçası (İng. script) yardımıyla incelenmiş; ardından ele alınan yapay sinir ağının eğitim sonuçları kaydedilmiştir. Akabinde, NARX yöntemi ile karşılaştırmalar yapılmış, doğruluğu yüksek olan model tercih edildikten sonra bu modelin farklı veri ölçeklerindeki karşılaştırması ve öğrenim durumu ayrıntılı olarak incelenmiştir. Sinir ağı eğitimi ve doğrulama süreci için Titra Teknoloji A.Ş. bünyesinde yer alan Alpin insansız helikopterin gerçek zamanlı “log” kayıtları göz önünde bulundurulmuş ve gerekli eliminasyonlar yapılarak kullanılabilir veriler elde edilmiştir.

Abstract

As one of the results of developing technology, unmanned systems have replaced their manned predecessors in many civil and military applications. Unmanned vehicles operating autonomously have found a wide area of use, especially thanks to the advantages they provide in terms of meeting basic performance requirements such as safety, accuracy, repeatability, and cost. In this study, based on the nonlinear dynamic nature of the single main rotor rotary wing unmanned aerial vehicle, the longitudinal behavior of the unmanned aerial vehicle is first examined using a traditional method using a script, which has been frequently used in this field. Then, the training results of the artificial neural network are recorded. Afterwards, comparisons are made with the NARX method, and after preferring the model with high accuracy, the comparison of that model in different data scales and the learning status are examined in detail. For the neural network training and validation process, the real-time log records of the Alpin unmanned helicopter in Titra Teknoloji A.Ş. are taken into

account and usable data are obtained after making the required elimination.

1. Giriş

Helikopter tabanlı insansız hava araçları başta gözetleme, hava haritalama, yüksek yapı denetim ve izleme operasyonları gibi hem sivil hem de askeri uygulamalarda birçok potansiyel yetenek sunmaktadır. Bu heyecan verici alandaki teknolojik gelişmeler, insansız bir hava aracının otonom olarak çalıştırılmasını sağlayarak, uçuş esnasındaki riskler ve pilotun iş yükünün azaltılmasına önyak olmuştur. Benzersiz uçuş yeteneklerinin yanı sıra helikopterler, kimi zaman küçük boyutları nedeniyle hızlı tepki veren dinamik davranışa sahip, kararsız ve doğrusal olmayan sistemler olarak kabul edilmektedir [1].

Helikopter dinamik davranışı, aracın doğası gereği kararsızdır. Otonom bir helikopter kısa bir süre için bile stabilize edici (kararlılaştırıcı) denetim (kontrol) komutları alamazsa, büyük olasılıkla dengesizleşecek (kararsızlık durumu) ve düşecektir (kırma uğrama). Bu, hataya yer olmaması gereken veya sonuçların feci olabileceği helikopter platformunda araştırma yapmayı zorlaştıran başlıca etkenlerdendir [1].

Bir sistemin girdi ve çıktı sinyallerine ait ölçülmüş veriler kullanılarak o sisteme ait dinamik modelin oluşturulması için kullanılan metodoloji “sistem tanımlama” olarak adlandırılmaktadır. Analitik yöntemlere ve rüzgâr tüneli testlerine bir alternatif olarak, gerçek işletim verileri kullanılarak yapılan sistem tanımlaması yaklaşımı dinamik sistem modelleri geliştirmek ve parametre kestirimi için uygun bir yöntem olarak öne çıkmaktadır. Bu bağlamda tanımlama işlemi, gürültülü verilerden karmaşık sistemlerin doğru modellerini oluşturmak için güçlü bir teknik olarak günümüzde yaygın bir şekilde kullanılmaktadır. Sistem tanımlama uygulamaları, girdi ve çıktıların ölçülebildiği herhangi bir sistemi içerebilmektedir. [3].

Rotorlu bir taşıtın doğrusal olmayan ve yüksek mertebeden dinamik davranışının genellikle birinci prensip yaklaşımı (araca etkiyen kuvvetlerin ve moment dengesinin doğrudan fiziksel olarak anlaşılması) kullanılarak modellenmesi zordur ve bu tür bir yaklaşım yanlış olabilir. Bu tür tanımlamalarda sinir ağı esaslı sistem tanımlaması gibi modelleme yöntemleri, problemi çözmek için daha uygun olabilmektedir.

Helikopter dinamiği doğrusal olmadığından, ekstra girişli sinir ağı (NARX) model yapısını kullanan yapay sinir ağı (YSA) sistem tanımlama yaklaşımı, böyle bir sorunu çözmek için kullanılabilir. NARX ağları yaklaşımı, girdi-çıkı veri kümesi arasındaki karmaşık doğrusal olmayan ilişkiyi ortaya çıkarabilir ve bir çalışma koşulundaki değişikliklere uyum sağlama yeteneğini gösterebilir. Popüler ileri beslemeli NARX mimarisini kullanan YSA tabanlı yaklaşıma ilişkin çeşitli araştırmalar Suresh[4], Samal [5], San Martin [6], Rimal[7] ve Chetouani [8] tarafından yapılmıştır ve burada elde edilen sonuçlar NARX yaklaşımının dinamik tepkiyi modellemede etkili olduğunu göstermektedir.[1]

Bu çalışmada, ele alınan tek ana rotorlu döner kanat insansız hava aracının doğrusal olmayan dinamik yapısı baz alınarak boylamsal düzlemdeki davranışı öncelikle geleneksel yöntem kullanılarak bu alanda daha önce de sıkça uygulama örnekleri bulunan bir kod parçası (İng. script) ile incelenmiş; ardından ele alınan yapay sinir ağının eğitim sonuçları kaydedilmiştir.

2. Sistem Tanımlaması

2.1. Girdi sinyalleri

Girdi sinyalleri temel olarak bir sistemin dinamik davranışını harekete geçirmek (uyarmak) için kullanıldıkları ve tanımlama işleminin çıktılarını etkilediklerinden dolayı sistem tanımlamanın en önemli parçası olarak kabul edilebilir. Belirtilen yaklaşımda, girdiler ve sistem cevabı (çıktılar) incelenip analiz edilerek model yapısı ve model parametreleri belirlenmektedir. Girdi sinyalleri incelenirken dikkat edilecek en önemli husus, sistemin dinamik davranışı uyarılmıyorsa bunların toplanan verilerde görülemeyecek ve tanımlama için kullanılmayacak olmasıdır. Bu sebeple, sistem davranışını uyararak için özel olarak tasarlanmış ve gerektiğinde filtrelenmiş girdilere sahip olmak ve elde etmek oldukça önemlidir [9].

Bahsedilen durumun yanı sıra sisteme ait dinamik davranışların basitçe uyarılmış olması, tanımlama işleminin sistemin dinamik davranışını bire bir betimleyeceğini göstermemektedir. Bundan dolayı, sağlıklı bir davranış analizi için sistemin doğru ve bilinçli bir şekilde uyarılması gerekmektedir. Davranışların yeterince tanımlanması için uzun süreli uyarma gerekebilir; böylece sistem tanımlama yöntemi, sistem dinamik davranışlarını tanımlamak için gerekli zamanı içerecektir.

2.2. Veri Toplama

Sistem tanımlamada diğer bir önemli husus sisteme ait gerçek dinamik verilerin elde edilmesindeki zorluklardır. Dinamik veriler nispeten gürültülü olabilmektedir. Örneğin bir ataletsel ölçüm birimi (İng. inertial measurement unit, IMU), sistemin davranışının yanı sıra aerodinamik kuvvet ve momentlerdeki değişiklikleri, rüzgâr etkisini ve buna benzer gürültüleri de ölçüm sonuçları üzerine ekleyecektir.

Tischler ve Remple, sistem tanımlamada sistem dinamiğinin gürültü tarafından bastırılmasını önlemek için tüm girdi/çıkı sinyallerine aynı filtrelemenin uygulanmasının daha doğru olacağını önermektedir [9]. Fakat bu durumda, elde edilecek kayıt (İng. log) verileri için herhangi bir filtre kullanılmayacaktır. Bunun başlıca sebebi elde edilen "log" verilerinin otopilot kayıtlarından elde edildiği ve kendi içinde kapalı bir filtreleme işlemi yaptığıdır. Bu sebepten ötürü

filtreleme işlemine ihtiyaç duyulmamakla birlikte veriler elimine edilirken en geniş genlikteki veriler tercih edilmiştir.


Veriler sadece ilerde bahsedilecek olan geleneksel yöntemim kullanımı için kod parçası (İng. script) içerisinde -1 ile 1 arasında ölçeklendirilecektir. Bunun yanında bu bölümde yer alan prosedürler zaman kümesinde gerçekleştirilmiş olup frekans alanında işlem yapılmamıştır.

Helikopterin tutumunu değiştirmek için 4 girdi kullanılmaktadır. Bunlar "z" ekseninde konum oluşturmak için "collective" girdisi, "x" ekseninde moment oluşturmak için "yanal cyclic" girdisi, "y" ekseninde moment oluşturmak için "boylamsal cyclic" girdisi ve son olarak "z" ekseninde moment oluşturmak için "pedal" girdisidir. Helikopter üzerinde bulunan "cyclic" adı verilen mekanizma, helikopteri boylamsal ve yanal eksenlerde hareketini sağlayan kumanda çubuğudur. Boylamsal eksene sistem tanımlaması yapabilmek için girdi bileşeni olarak "boylamsal cyclic" servo çıktısı seçilmiş olup, çıktı bileşeni olarak y ekseninde açılmal hız olan "q" bileşeni helikopter üzerinde yer alan INS modülü üzerinden alınarak seçilmiştir.

2.3. Karşılaştırılacak Modeller

2.3.1. Geleneksel Yapay Sinir Ağları

Yapay sinir ağları (YSA'lar) paralel çalışan basit elemanlardan oluşan genel bir mimariye sahiptir. Temel olarak gerçek hayattaki biyolojik sinir sistemlerinden ilham alınarak oluşturulan YSA'lar, genel olarak bir girdi ve bir çıktı veya hedef katmanı ile bunların arasında bir gizli katman içeren bir yapıda bulunmaktadır. Katmanlar, düğümler aracılığı ile birbirleriyle ilişkilendirilmekte ve bu bağlantılar birbirine bağlı düğümlerden oluşan bir "ağ (sinir ağı)" oluşturmaktadır [10].



Şekil 1: Yapay sinir ağı yapısı [10].

YSA'lar eğitilebilme özelliğinden dolayı, elemanlar arasındaki bağlantıların ağırlık değerleri ayarlanarak belirli bir işlevi yerine getirmesi amacıyla şekillendirilebilir. Yani ağ, çıktı ile hedefin karşılaştırmasına dayanılarak, ağ çıktısı hedefle eşleşene kadar ayarlanabilmektedir [10].

YSA'lar, örüntü tanıma, tanımlama, sınıflandırma, konuşma, görüntü, denetim sistemleri, uçuş yolu benzetimi, savunma sanayi (silah yönlendirme ve hedef izleme gibi), üretim süreci denetimi ve yönlendirme gibi alanlarda karmaşık işlevleri yerine getirmek için eğitilebilmektedir. Tipik bir YSA, Şekil 1'de görüldüğü gibi girdi, ağırlık, toplama işlemi, aktivasyon fonksiyonu ve çıktı olmak üzere beş kısımdan oluşmaktadır [10].

2.3.2. NARX Yöntemi

Nonlinear Autoregressive Network with Extra Inputs (NARX) ağı, doğrusal olmayan dinamik sistemlerin girdi-çıkı modellemesi için yaygın olarak kullanılan dinamik bir sinir ağı

mimarisi'dir. Zaman serisi tahminine uygulandığında, NARX ağı, bir ileri beslemeli zaman gecikmeli sinir ağı (İng. time-delayed neural network, TDNN) olarak tasarlanmaktadır. Bir başka deyişle NARX, gecikmeli çıktıların geri besleme döngüsü olmaksızın, tahmin başarımını (performansını) önemli ölçüde azaltmaktadır [11].


Literatüre göre zaman serisi gürültülü olduğunda ve temel dinamik sistem doğrusal olmadığında (nonlinearite), YSA modelleri, sıklıkla iyi bilinen Box-Jenkins modelleri gibi standart doğrusal tekniklerden daha iyi başarımla özelliği göstermektedir [12].

Teoride, geleneksel tekrarlayan ağlar yerine NARX ağlarının herhangi bir hesaplama kaybı olmadan kullanılabilmesi ve Turing makinelerine eşdeğer oldukları gösterilmiştir [13].

NARX, matematiksel olarak temsil edilebilen ayrık zamanlı doğrusal olmayan sistemlerin önemli bir sınıfıdır [14]. Matematiksel model, genel olarak aşağıdaki şekilde gösterilebilir [14]:

$$y(t) = f(y(t-1), y(t-2), \dots, y(t-ny), u(t-1), u(t-2), \dots, u(t-nu)) \quad (1)$$

NARX ağının topolojisi Şekil 2'de gösterilmektedir.



Şekil 2: NARX ağının topolojisi [14].

2.4. Karşılaştırılacak Ölçekler

Çalışma kapsamında göz önüne alınan modelde ilk olarak 250 verilik bir set kullanılmış olup bu veri seti geleneksel YSA ve NARX modeli oluşturularak karşılaştırılmıştır. Sonuçlar yorumlandıktan sonra ölçek artırılarak sırasıyla 500, 1.000 ve 2.000 verilik setler seçilmiş olan model üzerinden incelenmiştir.

Hedef değerler, geleneksel YSA yönteminde, aşağıdaki büyüklükler göz önünde bulundurulmuştur:

- İterasyon sayısı = 35.000
- İstenen en yüksek hata/Başarımla = 0,01
- Bias değeri = 0,5,
- Öğrenme hızı = 0,9
- Gizli katman sayısı = 5

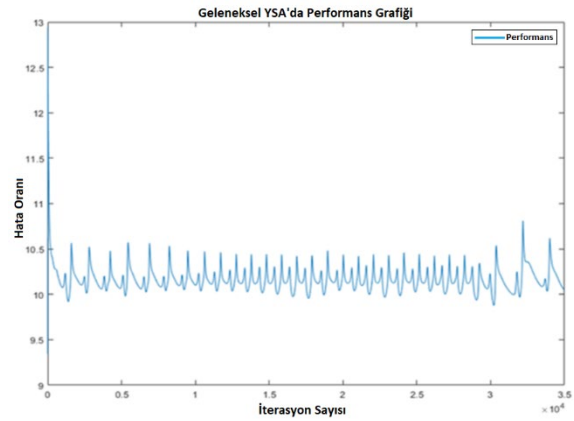
NARX yöntemindeki hedef değerler için ise müteakip sayısal büyüklükler dikkate alınmıştır:

- İterasyon sayısı = 1.000
- İstenen en yüksek hata = 0
- Gradyan = 1×10^{-7}
- Mu = 1×10^{10}
- Doğrulama kontrolü = 6
- Gizli katman sayısı = 5
- Zaman gecikmesi = 5

Yukarıda hedef değeri yer alan “gradyan” parametresi fonksiyonun belirli bir noktadaki değişim hızını ifade eder. Ağdaki her ağırlık ve bias (İng. yanlışlık) değeri, hata/kayıp fonksiyonunun değerini en aza indirmeye çalışan bir optimizasyon algoritması tarafından ayarlanır. Bu ayarlama, kayıp fonksiyonunun gradyanı kullanılarak gerçekleştirilir.

Yapay sinir ağını eğitmek için kullanılan algoritmanın kontrol parametresi eğitim kazancıdır (Mu) ve öğrenme hızını temsil eder. Bu değer, her iterasyonda ağırlık güncellemelerinin ne kadar büyük veya küçük olacağını belirler.

2.5. Alpin Helikopter Sistem Tanımlama Faaliyeti



Şekil 3: Geleneksel YSA'da başarımla grafiği.

Sistem tanımlama faaliyeti kapsamında, ele alınan Alpin helikopterinin gerçek uçuş test verileri kullanılmış olup helikopterin sadece boyutsal düzlemdeki dinamik davranışı incelenmiştir. Bahsi geçen davranış incelenirken helikopterin “hover (askı uçuşu)” anındaki uçuş verileri alınarak diğer veriler elimine edilmiştir. Veriler arasında boşluk olmayıp zamana bağlı bir veri seti seçilmiştir. Ayrıca, veriler seçilirken mümkün olduğunca büyük genliğe sahip veriler dikkate alınmıştır. Bu durumun sebebi YSA'nın temel olarak iç orantılama (interpolasyon) ile işlem yapması, dış orantılama (ekstrapolasyon) gerektiren durumlarda hatalı sonuçlar vermesinden kaynaklanmaktadır.

2.5.1. Model Karşılaştırması

2.5.1.1. Geleneksel Yapay Sinir Ağları

Çalışmada, geleneksel yöntem kullanılarak bir kod parçası oluşturulmuş ve 250 adımlık bir veri seti kod parçasına girdi olarak sağlanmıştır. “Karşılaştırılacak Ölçekler” bölümünde anlatılan isterler kod parçası hazırlanırken dikkate alınmıştır.

Sonuç olarak 35.000 iterasyon ve 693,668 saniye sonucunda Şekil 3'te verilen başarımla grafiği elde edilmiştir.

2.5.1.2. NARX Yöntemi

Aynı veri seti ile MATLAB® yazılımı ortamında “Neural Network Time Series” aracı kullanılmış ve NARX yöntemi ile gerekli girdiler girilmiştir. Daha önce bahsedilen ve “Karşılaştırılacak Ölçekler” bölümünde anlatılan isterler model hazırlanırken dikkate alınmıştır. Sonuç olarak yeterli doğrulama kontrolüne ulaşıldığında hedef değerlerden bir tanesi doğrulandığı için model geliştirme faaliyeti durdurulmuştur. Bu esnada diğer değerler Tablo 1’de verildiği gibidir.

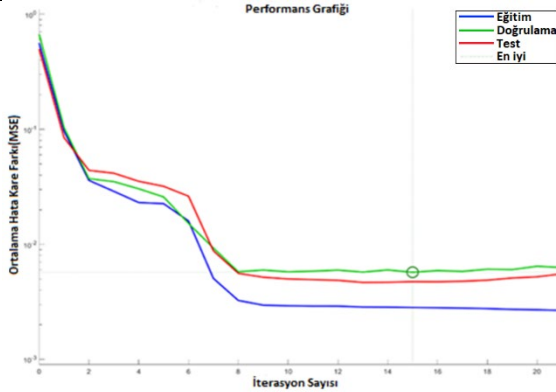
Tablo 1: NARX eğitim süreci

Birim	Girdi Değeri	Durdurulmuş Değer	Hedef Değer
İterasyon Sayısı	0	21	1000
Geçen Zaman	-	00:00:00	-
Başarım	0,562	0,0026	0
Gradyan	1,6	0,0023	1×10^{-7}
Mu	0,001	1×10^{-5}	1×10^{10}
Doğrulama Kontrolü	0	6	6

Yukarıdaki belirtilen süreç sonunda alınan sonuçlar Tablo 2’deki gibi olup NARX uygulaması sonucunda Şekil 4’te verilen başarımlar grafiği elde edilmiştir. Tablo 2’de yer alan MSE kısaltması ortalama “hata karesi (İng. mean square error)” büyüklüğüne karşılık gelmekte olup R harfi ile regresyon belirtilmektedir.

Tablo 2: NARX Yöntemi ile elde edilen eğitim sonuçları

	Kullanılan Veri Seti	MSE	R
Eğitim	171	0,003	0,997
Doğrulama	37	0,006	0,994
Test	37	0,005	0,994




Şekil 4: NARX başarımlar grafiği

Elde edilen sonuçlar ve çizdirilen grafikler incelendiğinde, geleneksel YSA’da istenen başarımlar değerlerinin yakalanamadığı, 693 saniye gibi uzun bir süreye karşın belli bir yakınsama değerinin elde edilemediği görülmüştür.

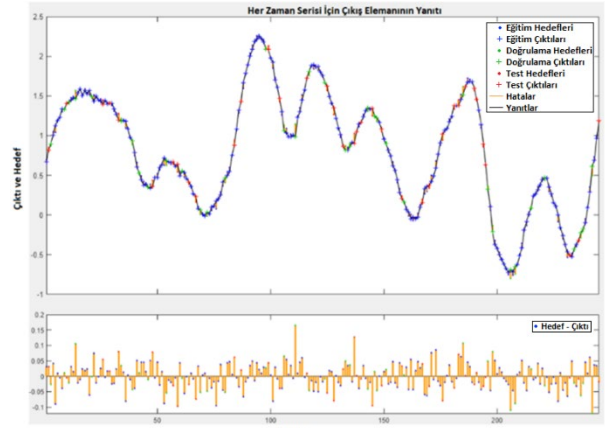
NARX yönteminde ise çok hızlı bir çözüm sonucunda büyük bir doğrulukla başarımlar grafiği elde edilmiştir. Sadece 21 iterasyon yeterli olmuş olup bu işlemler 1 saniyeden daha kısa sürede gerçekleşmiştir. NARX yöntemini daha iyi incelemek için otokorelasyon grafikleri incelenecektir. Otokorelasyon bir veri setindeki ardışık veriler arasındaki ilişkiyi ölçen grafik türüdür. Grafik, farklı gecikme değerleri için korelasyonun nasıl değiştiğini gösterir. NARX yöntemine ait hata-otokorelasyon ve yanıt grafikleri, sırasıyla Şekil 5 ve Şekil 6’da verilmiştir.

Şekil 5 ve Şekil 6’da gösterilen otokorelasyon ve çıktı yanıt değerlerinin tanımlı güven aralığında oldukları görülmüştür.

Özellikle eğitim, doğrulama ve test verilerinin hedef-çıktı ilişkisinde yüksek seviyede korelasyon gözlemlenmiştir. Sonuç olarak, NARX yönteminin geleneksel YSA yaklaşımına göre büyük bir oranda daha etkili ve doğruluğu yüksek olduğu görülmüştür. İncelemeye NARX yöntemi üzerinden farklı ölçeklerden devam edilmiştir.



Şekil 5: NARX hata-otokorelasyon grafiği



Şekil 6: NARX yanıt grafiği

2.5.2. Ölçek Karşılaştırması

Titra Teknoloji A.Ş bünyesinde bulunan Alpin insansız helikopterin kayıt verileri kullanılarak 500, 1.000 ve 2.000 adetlik veri setleri boylamsal davranışa odaklanılacak şekilde incelenmiştir. 500 veriye sahip sette model üzerinde Tablo 3’teki sonuçlar elde edilmiştir.

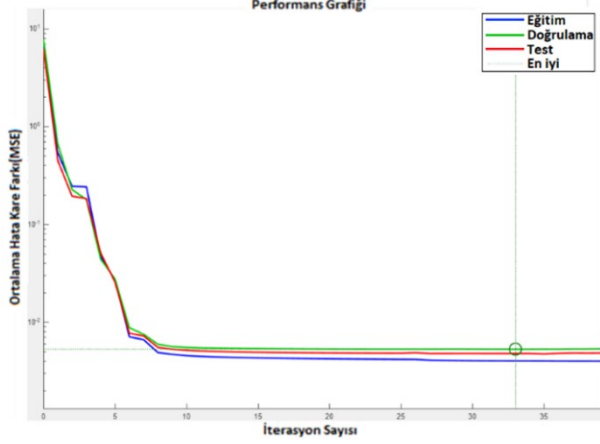
Tablo 3: NARX 500 veri setine ait eğitim süreci

Birim	Girdi Değeri	Durdurulmuş Değer	Hedef Değer
İterasyon Sayısı	0	39	1000
Geçen Zaman	-	00:00:00	-
Başarım	6,68	0,00401	0
Gradyan	8,94	0,0014	1×10^{-7}
Mu	0,001	1×10^{-7}	1×10^{10}
Doğrulama Kontrolü	0	6	6

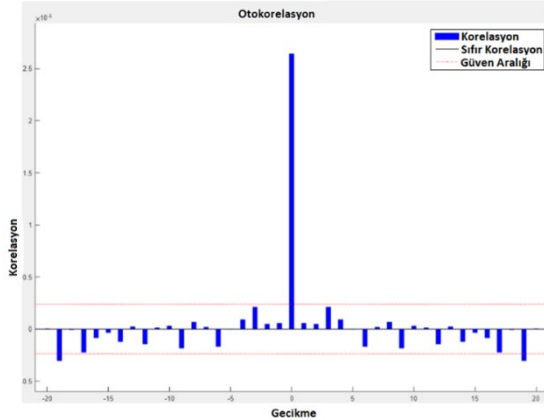
Neticede, yeterli doğrulama kontrolüne ulaşıldığı anda, hedef değerlerden bir tanesi doğrulandığı için model geliştirme faaliyeti durdurulmuştur. Yukarıdaki süreç sonunda 500 verilik set için alınan sonuçlar Tablo 4’te sunulmaktadır. İlgili veri setine ait başarımlar ve otokorelasyon grafikleri, sırasıyla Şekil 7 ve Şekil 8’de verilmektedir.

Tablo 4: NARX 500 veri setine ait eğitim sonuçları

	Kullanılan Veri Seti	MSE	R
Eğitim	347	0,0040	0,997
Doğrulama	74	0,0053	0,997
Test	74	0,0048	0,996



Şekil 7: NARX 500 veri setine ait başarıım grafiği



Şekil 8: NARX 500 veri setine ait otokorelasyon grafiği

Benzer şekilde, 1.000 veriye sahip set için model üzerinde Tablo 5'teki sonuçlar elde edilmiştir.


Tablo 5: NARX 1.000 veri setine ait eğitim süreci

Birim	Girdi Değeri	Durdurulmuş Değer	Hedef Değer
İterasyon Sayısı	0	16	1000
Geçen Zaman	-	00:00:00	-
Performans	1,24	0,004	0
Gradyan	3,59	0,014	1×10^{-7}
Mu	0,001	1×10^{-6}	1×10^{10}
Doğrulama Kontrolü	0	6	6

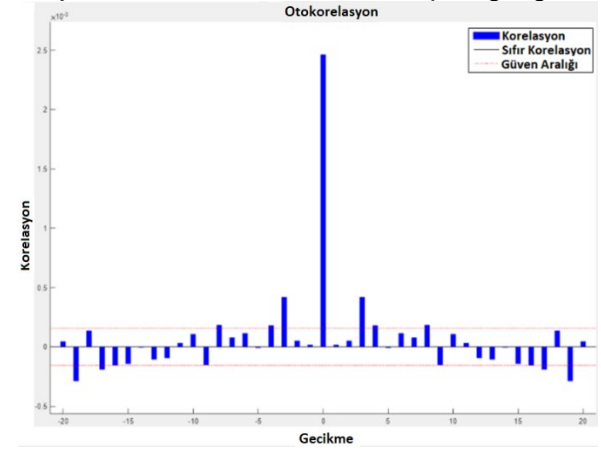
Yeterli doğrulama kontrolüne ulaşıldığı anda, hedef değerlerden bir tanesi doğrulandığı için model geliştirme faaliyeti durdurulmuştur. Yukarıdaki süreç sonunda 1.000 verilik set için alınan sonuçlar Tablo 6'daki gibi ortaya çıkmıştır. İlgili veri setine ait başarıım ve otokorelasyon grafikleri, sırasıyla Şekil 9 ve Şekil 10'da verilmektedir.

Tablo 6: NARX 1.000 veri setine ait eğitim sonuçları

	Kullanılan Veri Seti	MSE	R
Eğitim	697	0,004	0,999
Doğrulama	149	0,005	0,998
Test	149	0,005	0,998



Şekil 9: NARX 1.000 veri setine ait başarıım grafiği



Şekil 10: NARX 1.000 veri setine ait otokorelasyon grafiği

Şekil 10'daki grafik incelendiğinde, yalnızca 10 iterasyonda yakınsama kriterine ulaştığı, gecikme değerine bağlı korelasyon grafiğinde ise gecikme değerlerinin güven aralıklarında bulunduğu gözlemlenmiştir.

Son olarak, 2.000 veriye sahip sette model üzerinde Tablo 7'de gösterilen sonuçlar elde edilmiştir.


Tablo 7: NARX 2.000 veri setine ait eğitim süreci

Birim	Girdi Değeri	Durdurulmuş Değer	Hedef Değer
İterasyon Sayısı	0	79	1000
Geçen Zaman	-	00:00:01	-
Performans	2,38	0,004	0
Gradyan	6,69	0,014	1×10^{-7}
Mu	0,001	1×10^{-6}	1×10^{10}
Doğrulama Kontrolü	0	6	6


Yeterli doğrulama kontrolüne ulaşıldığı anda, hedef değerlerden bir tanesi doğrulandığı için 2.000 verilik set için de model geliştirme faaliyeti durdurulmuş ve Tablo 8'deki sonuçlar ortaya çıkmıştır. İlgili başarıım ve otokorelasyon grafikleri de sırasıyla Şekil 11 ve Şekil 12'deki gibidir.

Tablo 8: NARX 2.000 veri setine ait eğitim sonuçları

	Kullanılan Veri Seti	MSE	R
Eğitim	1397	0,004	0,999
Doğrulama	299	0,004	0,999
Test	299	0,004	0,999



Şekil 11: NARX 2.000 veri setine ait başarımlar grafiği



Şekil 12: NARX 2.000 veri setine ait otokorelasyon grafiği

Grafiklerden görüldüğü üzere ölçek arttıkça korelasyon değeri artmış ve ortalama kare hatası azalmıştır. Bunun yanında eğitim tüm ölçeklerde güven aralığı içerisinde kalmıştır. Böylece, NARX yönteminin doğrusal olmayan sistemlere uygulanabilirliği de bir anlamda ele alınan Alpin modeli üzerinden doğrulanmıştır.

3. Tartışma ve Sonuç

İnsansız bir helikopterin yapay sinir ağları ile sistem tanımlama işleminin ele alındığı bu çalışmada, geleneksel YSA ile NARX yöntemlerinin karşılaştırılması neticesinde, NARX yönteminin daha iyi sonuçlar verdiği gözlemlenmiştir. Gözlem esnasında başarımlar grafiği, otokorelasyon grafiği ve yanıt grafiği incelenmiştir. Bu veriler ışığında NARX yöntemi ile diğer veri setleri için analize devam edilerek 500, 1.000 ve 2.000 veri setleri için başarımlar grafiği ve otokorelasyon grafiklerine bakılmıştır. Veriler ışığında gizli katman sayısı ve zaman gecikmesi tercihlerinin, kullanılan veri setleri kapsamında her zaman güvenli limit aralığında tuttuğu gözlemlenmiştir. Bunun yanında tıpkı 250 veride olduğu gibi diğer veri setlerinde de ortalama MSE değerlerinde istenen yakınsama ve sonuç değerleri elde edilmiştir. R değeri ise veri sayısı arttıkça yakın ilişki kavramına yakınsaklığı temsil eden bire yaklaşmış ve öğrenim düzeyi artmıştır. Bu çalışma kapsamında sistem tanımlama yapılırken birden çok veri seti seçilmiş ve bu veri setleri model seçimi ve ölçek karşılaştırması için bölünmüştür.

Bu çalışmanın devamında, farklı uçuş zarfları ve girdi-çıkıtları bağlantıları arasında denetim sistemi geliştirilerek gerekli testlerin yapılabileceği değerlendirilmektedir. Bunun yanında, elde edilen modellere aynı denetim algoritması uygulanıp model başarımlar özelliklerinin karşılaştırılması mümkün olacaktır.

4. Kaynakça

- [1] S.S. Shamsudin and X. Chen, *Identification of an unmanned helicopter system using optimised neural network structure*, International Journal of Modelling Identification and Control, 2012
- [2] B. Mettler, *Flight-Test Evaluation of a Dynamic Compensation for High-Bandwidth Control of a Small-Scale Helicopter*, American Helicopter Society., ABD, 2002.
- [3] R. V. Jategaonkar, *Flight Vehicle System Identification- A Time Domain Methodology*, ABD, 2006.
- [4] Suresh, S., Kumar, M.V., Omkar, S.N., Mani, V. ve Sampath, P. *Neural networks based identification of helicopter dynamics using flight data*, 9th International Conference on Neural Information Processing, 2002.
- [5] Samal, M.K., Anavatti, S. and Garratt, M., *Neural networkbased system identification for autonomous flight of an eagle helicopter*, in 17th World Congress The International Federation of Automatic Control, 2008.
- [6] San Martin, R., Barrientos, A., Gutierrez, P. and del Cerro, J. *Unmanned aerial vehicle (uav) modelling based on supervised neural networks*, Robotics and Automation, 2006.
- [7] Rimal, B., Putro, I., Budiyo, A., Min, D. and Choi, E. *System Identification of NN-based Model Reference Control of RUAV during Hover*, InTech, 2011.
- [8] Chetouani, Y., *Use of a neural-network-based approach for reliable modelling of a distillation column*, International Journal of Modelling, Identification and Control, 2010.
- [9] M. B. Tischler ve R. K. Remple, *Aircraft and Rotorcraft System Identification*, AIAA Press, ABD, 2006
- [10] F. Adıyaman, *Talep Tahmininde Yapay Sinir Ağlarının Kullanılması*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul, 2007.
- [11] H. Xie, H. Tang ve Y. Liao, "Time Series Prediction based on NARX Neural Networks: An Advanced Approach", International Conference on Machine Learning and Cybernetics, 2009.
- [12] G. Box ve G.M. Jenkins, *Time Series Analysis: Forecasting & Control*, Prentice-Hall, Englewood Cliffs, Third ed., 1994.
- [13] H. T. Siegelmann, B. G. Horne B. G. ve C. L. Giles, "Computational Capabilities of Recurrent Narx Neural Networks", *IEEE Trans. Syst., Man Cybern.*, 1997.
- [14] J. Menejes ve G. Barreto, "A New Look at Nonlinear Time Series Prediction with NARX Recurrent Neural Network", The Ninth Brazilian Symposium on Neural Networks, 2006.
- [15] K. Güven ve A. T. Şamiloğlu, "System Identification of an Aerial Delivery System with a Ram-Air Parachute Using a NARX Network", *Aerospace* 9, 2022.