

Zaman Serilerinde NARX Sinir Ağları Modeliyle Uçuşa Elverişlilik Süresinin Kestirimi NARX Neural Networks Based Time Series Prediction for Amount of Airworthiness Time

Ali TATLI¹, Sinem KAHVECİOĞLU²

¹ Havacılık Elektrik ve Elektronik Bölümü
Anadolu Üniversitesi, Eskişehir
alitatti@anadolu.edu.tr

² Havacılık Elektrik ve Elektronik Bölümü
Anadolu Üniversitesi, Eskişehir
skahvecioglu@anadolu.edu.tr

Özet

Havacılık planlamalara yoğun bir şekilde başvurulmuş ciddi bir sektördür. Yüksek maliyetlere sebep olabilecek plansızlığın giderilmesi ve vahim sonuçlar doğurabilecek kazaların önüne geçilebilmesi için öngörülere ihtiyaç duyulmaktadır. Hiç şüphesiz bu durum tecrübesiz pilot adayları dikkate alındığında, kâr amaçlı uçuş eğitim organizasyonları için daha da önem kazanmaktadır. Bu çalışma, uçuşa elverişlilik zaman serilerinin çıkarımı ve bu seriler üzerinde NARX(Nonlinear Autoregressive Exogenous) yapay sinir ağı modelleriyle günlük uçuşa elverişlilik süresinin kestirimi çalışmasından oluşmaktadır.

Anahtar Kelimeler—NARX ağları, Uçuşa elverişlilik, Zaman serilerinde kestirim, Yapay sinir ağları performansı

Abstract

Aviation, a serious sector, is required to recourse planning intensively. There is a need for foresight in order to eliminate the planless that can lead to high costs and prevent accidents that could cause to fatal consequences. Without doubt, considering inexperienced pilot candidates this situation comes into prominence for profit-oriented flight training organizations. This study contains extracting time series of airworthiness and forecasting amount of daily airworthiness time based on NARX (Nonlinear Auto Regressive Exogenous) neural network models.

Keywords—NARX networks, Airworthiness, Time series prediction, Artificial neural networks performance

1. Giriş

Uçuş Eğitimi, adaylara çoğunlukla meteorolojik hadiselerin gerçekleştiği troposfer katmanında ve eğitim uçaklarıyla verilmektedir. Bu eğitim uçakları, kısa menzillidir ve büyük yolcu uçaklarına nazaran çevre şartlarına karşı daha duyarlıdır. Bu sebeple tecrübesiz adayların eğitim süreçleri hava hadiseleri öngörülmesi dâhilinde yapılan planlamalara göre sürdürülmektedir. Türkiye Havacılık Enformasyon Yayını'na (AIP, Aeronautical Information Publication) göre; bulut tavanının 1500 ft'in (450 m) altına, rüyetin 5 km'nin altına düştüğü durumlarda ve günbatımından 30 dk sonrası

ile gündeğumundan 30 dk öncesi olarak tanımlanan gece şartlarının oluştuğu süreçte görüş uçuş (VFR, Visual Flight Rules) yapılamaz[1]. Uçaklar için el kitaplarında belirtilen yan rüzgâr limitleri ise kısıtlayıcı bir diğer unsurdur ve bu yan rüzgâr limitlerini uçağın tasarımı belirlemektedir[2, 3].

Yapay sinir ağları, kontrol, model oluşturma ve tahmin uygulamalarında sıklıkla kullanılmaktadır. NARX ağları, nonlineer sistem modelleme ve zaman serilerinde tahmin uygulamalarında başarılı sonuçlar veren bir geribeslemeli yapay sinir ağı modelidir. Geleneksel geribeslemeli ağ yapılarına göre NARX ağları, daha hızlı yakınsamakta ve daha etkili bir öğrenme ortaya koymaktadır[4–6].


Bu çalışmada NARX yapay sinir ağı modelleri kullanılarak günlük uçuşa elverişlilik süresi kestirimi yapılmıştır. İkinci bölümde NARX ağlarının genel yapısı, üçüncü bölümde kestirim için oluşturulan veri seti, dördüncü bölümde uygulamanın nasıl gerçekleştirildiği ve değerlendirilme kriterleri hakkında bilgiler verilmektedir. Beşinci ve altıncı bölümlerde ise elde edilen sonuçlar sırasıyla tartışılmakta ve değerlendirilmektedir.

2. NARX Ağları

NARX ağları, statik MLP (Multilayer Layer Perceptron) ağ yapısıyla eğitim yönüyle benzerlik gösteren fakat ağ çıkışının, girişe geri besleme olarak uygulandığı yapılardır. Nonlineer model benzetimlerinde başarılı sonuçlar verebilmektedirler. Ayrık zamanlı bu sistemler matematiksel model olarak


$$\mathbf{o}(t) = F(\mathbf{o}(t-1), \mathbf{o}(t-2), \dots, \mathbf{o}(t-\hat{p}), \mathbf{x}(t), \mathbf{x}(t-1), \dots, \mathbf{x}(t-p)) \quad (1)$$

şeklinde ifade edilebilir. Burada $\mathbf{o}(t - \hat{p}) \in \mathbb{R}$ ve $\mathbf{x}(t - p) \in \mathbb{R}$ sırasıyla ağ çıktılarını ve girdilerini, $\hat{p}$ ve p ise sırasıyla geribesleme için uygulanacak geçmiş çıktılarının ve geçmiş girdilerin sayısını ifade etmektedir. Şöyle ki, geribesleme ve girdi katmanları zaman gecikmelidir ve geçmiş verileri barındırmaktadır. Modelin hücresel yapısı Şekil 1'de gösterilmektedir. Burada sırasıyla N giriş katmanındaki, L gizli katmandaki ve M çıkış katmanındaki hücre sayısını ifade etmektedir[7, 8].



Şekil 1. NARX ağı genel yapısı

Geribesleme katmanı tahmin edilen veya gerçek verilerden oluşabilmekte ve yapısına göre sırasıyla paralel ve seri-paralel şeklinde isimlendirilmektedirler. Paralel yapı kullanılarak geliştirilen bir modelde tahmin çıktısı geribesleme olarak girişe uygulanırken, seri-paralel modelde gerçek verinin de elde edilmesiyle birlikte bu gerçek veri girişe bir geribesleme olarak uygulanmaktadır. Şekil 2’de NARX modelinin topolojik yapısı gösterilmiştir. Çalışma, ilerleyen zamanın gerçek verilerin elde edilmesini olanaklı kılmasından dolayı seri-paralel yapıyı kapsamaktadır[4].



Şekil 2. NARX ağı

3. Veri Seti

Havacılıkla ilgili bilimsel çalışmalarda hava durumu verilerinin en az beş yılı kapsayan bir gözlem sonucu elde edilmesini bir gereklilik olarak kabul edilmektedir[9]. Çalışmada kullanılan veri Ocak 09’ - Haziran 15’ (≈ 6.5 yıl) zaman aralığını kapsayan 58053 adet METAR ve SPECI raporları ile gerçekleştirilmiştir.

3.1. Çalışma Bölgesi

Hasan Polatkan Havaalanı, Anadolu Üniversitesi İki-Eylül Kampüsü bitişiğinde yer almakla birlikte Havacılık ve Uzay Bilimleri Fakültesi tarafından eğitim amacıyla kullanılmaktadır. Tablo 1’de havalanı genel özellikleri verilmektedir. Bu özelliklerden pist istikâmeti, uçağın iniş ve kalkışları sırasındaki yan rüzgâr etkileri açısından önemlidir.

Tablo 1. Hasan Polatkan Havaalanı genel özellikleri[1, 10]

Özellik	Açıklama
IATA Tanıtım Kodu	AOE
ICAO Tanıtım Kodu	LTRY
Meydan Yüksekliği	2580 ft
Pist İstikâmeti	09 / 27
Pist Uzunluğu	2739 mt
Pist Genişliği	30 mt
Pist Kaplaması	Asfalt
Şehir merkezinden uzaklık	2.7 NM N
Koordinatları	AD 39°48'45"N - 030°31'14"E

3.2. METAR

METAR(Meteorological Terminal Air Report), eşgüdümlü evresel zaman (UTC) temel alınarak elde edilen havacılık maksatlı bir rasat türüdür. Uluslararası meydanlarda yarım saatte bir, ulusal meydanlar ve askerî meydanlarda ise saatte bir yapılmak suretiyle konum, zaman, rüzgâr hızı ve yönü, rüyet, hava olayları, bulutlara yönelik bilgiler, sıcaklık, çiğ noktası, basınç temel olmak üzere çeşitli bilgileri içeren rutin rasatlardır. SPECI rasatları yapısal olarak METAR ile aynı olmakla birlikte hava durumlarına göre gerekli görülmeleri halinde rasat edilirler[11].


3.3. Uçuşa Elverişlilik

Aday pilotlar eğitim süresinin büyük bir bölümünde basit yapılu eğitim uçaklarını ve hava hadiselerinin gerçekleştiği atmosferin troposfer katmanını kullanmaktadırlar. Bu sebeple havanın mevcut durumu ve seyri havacılık faaliyetleri açısından büyük bir önem taşımaktadır. Uçuş eğitim organizasyonları ağırlıklı olarak faaliyetlerini, VFR uçuş prosedürlerine göre gerçekleştirmektedirler. Türkiye AIP’sinde bulut tavanı 1500 ft’in (450m) altına inmesi durumunda, rüyetin 5 km altına inmesi ve gece şartlarının oluşması durumunda VFR uçuş yapılamayacağı belirtilmiştir ve gece şartları gündoğumundan yarım saat öncesi ve günbatımından yarım saat sonrası olarak tanımlanmıştır[1].

Yan rüzgâr, uçakları tasarımlarının bir sonucu olarak el kitaplarında da belirtildiği şekilde farklı farklı etkilemekte ve uçağın kararlılığını etkileyerek dengesini bozabilmektedirler. Bu etki pist istikâmetinin de sabit olmasının bir sonucu olarak özellikle kalkış ve iniş evrelerinde oldukça önem kazanmaktadır. Çalışma kapsamında Anadolu Üniversitesi Havacılık ve Uzay Bilimleri Fakültesi envanterinde kullanılan Cessna 172 SP ve TB-20 Trinidad uçaklarının yan rüzgâr bileşenleri göz önünde bulundurulmuştur. Yan rüzgâr bileşenleri Şekil 3’de verilmektedir. Uçaklar güvenli uçuşlarını; Cessna 172 SP

uçakları için 15 kt ve TB-20 Trinidad uçakları için 25 kt yan rüzgâr bileşenleri içerisinde gerçekleştirebilmektedirler[2, 3, 12].

Çalışmada uçuşa elverişlilik kriterleri olarak; VFR uçuş prosedürlerinin sağlanması, meydan ihbarlarını gerektiren ve havacılığı etkileyen önemli meteorolojik hadiselerin olmaması ve pilot tecrübeleri göz önünde bulundurularak bulut kapalılığının 5/8 okta'dan fazla olmaması, bulut taban yüksekliğinin 3000 m'den az olmaması, oraj(thunderstorm), cumulonimbus ve cumulus congestus bulutlarının olmaması, şiddetli sağanak yağışların olmaması, sıcaklığın 5°C'den düşük olmaması ve bir uçuş eğitim organizasyonu olarak Anadolu Üniversitesi Havacılık ve Uzay Bilimleri Fakültesi'nin kullandığı Hasan Polatkan Havaalanı pist istikâmeti temel alınarak envanterdeki uçakların yan rüzgârlardan etkilenmemesi için rüzgâr hızı ve hamle durumunun uygun olması belirlenmiştir.



Şekil 3. Cessna 172 SP & TB-20 Trinidad Rüzgâr bileşenleri


4. Yöntem

Günlük uçuşa elverişli saat sayısı bilgisini içeren 6.5 yılı kapsayan zaman serisinin 5 yıllık bölümü ağır eğitimi ve son 1.5 yıllık bölümü ise ağır test edilmesi amacıyla kullanılmıştır. Böylelikle verilerin yaklaşık %75'i eğitim ve %25'i test verilerini oluşturmuştur. Bu maksatla t 'inci günün sahip olabileceği uçuşa elverişli saat sayısının kestirilebilmesi için $p = 1, 2..5$ olmak üzere $t - 1$ 'den $t - p$ 'inci zamana kadar ki zaman serisi verileri girdi olarak kullanılmıştır. Başka bir ifadeyle, yarın üzerine yapılacak tahminde bugün; bugün ve dün; bugün, dün ve bir önceki gün şeklinde geçmiş 5 güne kadar ki veri zarfları kullanılmıştır. Yine geribesleme olarak $p = 1, 2..3$ olmak üzere benzer şekilde uygulanmıştır. Buna ek olarak tahminin gerçekleştirildiği ay bilgisi girişe uygulanarak sonuçlar gözlemlenmiştir.

Seri-paralel yapıda geribesleme olarak gerçek verilerin kullanılması, iki ve üzeri geçmiş verilere bağlı giriş uygulanan yapılarda aynı girişin iki defa uygulanması anlamına gelse de yeni ağ ağırlıklarının yapıya eklenmiş olduğu gözden kaçırıl-

mamalıdır. Gizli katman hücre sayısı 3'den 60'a kadar değiştirilerek RMSE(Root Mean Square Error) karşılaştırma kriteri olarak hesaplanmıştır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2} \quad (2)$$





Şekil 4. Aktivasyon fonksiyonları



Gizli katmanda Elliot, sigmoid, lineer ve hiperbolik tanjant aktivasyon fonksiyonları kullanılmıştır. Şekil 4'de aktivasyon fonksiyonları verilmiştir. Elliot fonksiyonu, hiperbolik tanjant fonksiyonuna oldukça benzeyen fakat hesaplama açısından daha az işlem gerektiren bir fonksiyondur. Bu sebeple eğitim süreleri açısından hiperbolik tanjant fonksiyonu ile kıyaslanmaya değerdir[13, 14].

5. Sonuçlar ve Tartışma



Çalışma kapsamında gizli katman aktivasyon fonksiyonunun, geribesleme sayısının, geçmişe bağlı girdi sayısının değiştirilmesinin yanı sıra tahminin gerçekleştirildiği ay bilgisinin de girdi olarak ilave edilip edilmemesi durumları dikkate alınarak 6960 ağ eğitilmiştir. Sigmoid, hiperbolik tanjant, lineer ve Elliot aktivasyon fonksiyonlarının çeşitli geribeslemelerde elde edilen en başarılı ağları, kullanılan girdi yapısı da belirtilerek, gizli katman hücre sayısına göre eğitim ve tahmin uygulamalarının RMSE değişimleri Şekil 5, Şekil 6 ve Şekil 7'de gösterilmektedir. Ayrıca Tablo 2'de bu ağlara ait en düşük RMSE değerleri görülmektedir. Eğitimler neticesinde eğitim başarısının bir ifadesi olarak RMSE dikkate alındığında eğitim başarısının tahmin başarısıyla ilişkili olduğu görülmektedir. En başarılı sonucun bir gün öncesine ait verinin yanı sıra tahminin yapıldığı ayın da girdi olarak kullanıldığı, $o(t-1)$ geribeslemeli ve lineer aktivasyon fonksiyonlu 8 gizli katman hücrelerine sahip ağdan elde edildiği Şekil 5 ve Tablo 2'den görülmektedir. Bu ağa ait ardışık 591 günlük tahmin sonuçları, gerçek verilerle birlikte Şekil 8'de gösterilmiştir. En başarılı ağ için RMSE değeri eğitim ve test aşamalarında sırasıyla 0.158258 ve 1.482981 olarak elde edilmiştir.




Şekil 5. (a) Eğitim verileri, (b) Test verileri için $o(t-1)$ geri beslemeli modelde RMSE'nin gizli katman hücre sayısına göre değişimi



Şekil 6. (a) Eğitim verileri, (b) Test verileri için $o(t-1)$, $o(t-2)$ geri beslemeli modelde RMSE'nin gizli katman hücre sayısına göre değişimi



Şekil 7. (a) Eğitim verileri, (b) Test verileri için $o(t-1)$, $o(t-2)$, $o(t-3)$ geri beslemeli modelde RMSE'nin gizli katman hücre sayısına göre değişimi



Şekil 8. Gerçek veriler ve en iyi ağ sonuçlarının karşılaştırılması

6. Değerlendirme

Bu çalışma kapsamında zaman serileri kullanılarak çeşitli NARX ağları ile kısa süreli günlük uçuş elverişlilik süresi tahminleri gerçekleştirilmiştir. Eğitim başarısı yüksek olan ağların test başarısının da genellikle yüksek olduğu sonucuna ulaşılmıştır. Geribesleme sayısının artırılması eğitim başarısını ve dolayısıyla test başarısını düşürmektedir. Aktivasyon fonksiyonları arasında ise en başarılı sonuçları her geribesleme düzeyinde lineer fonksiyon vermektedir. Sonuç olarak bir gün öncesine ait verinin ve tahminin yapıldığı ayın girdi olarak kullanıldığı, $o(t-1)$ geribeslemeli ve lineer aktivasyon fonksiyonuna sahip 8 gizli katman hücrelerinden oluşan ağ, sırasıyla 0.158258 ve 1.482981 eğitim ve test RMSE değerleriyle en başarılı ağ olarak tespit edilmiştir.

Tablo 2. Eğitim ve Test verilerine ait RMSE

o	f	x	L	Eğitim	Test
1	Sigmoid	t-1	15	0.182160	1.689597
	Tanh	t-1	28	0.182550	1.645792
	Lineer [†]	t-1;ay	8	0.158258	1.482981
	Elliot	t-1	54	0.194536	1.778107
2	Sigmoid	t-1..4	37	0.323060	3.019011
	Tanh	t-1	25	0.332237	3.212662
	Lineer	t-1;t-2	4	0.300565	2.863755
	Elliot	t-1..3	29	0.309213	2.909381
3	Sigmoid	t-1..4	16	0.371193	3.498167
	Tanh ^{††}	t-1..4	35	0.391350	3.718544
	Lineer	t-1	30	0.361578	3.423207
	Elliot	t-1;t-2	56	0.362642	3.491622

[†] En iyi eğitim ve test sonucu

^{††} Ay girdili 31 gizli katman hücreli ağ yapısı daha iyi test sonucu vermektedir. (RMSE=3.694165)

7. Teşekkür

Yazarlar, Öğretmen Pilot Erdoğan BÖCÜ'ye katkılarından dolayı teşekkür etmektedirler.

8. Kaynakça

- [1] Devlet Hava Meydanları İşletmesi (2016). *AIP*. [Online]. Available: <http://www.ssd.dhmi.gov.tr>. (Visited on 04/01/2016).
- [2] EADS Socata (1988). *TB20 Pilot's Information Manual*. Fransa.
- [3] *Cessna 172S, Skyhawk SP Model 172S Specifications and Descriptions* (2008). A.B.D: Cessna.
- [4] Xie, Hang, Hao Tang, and Yu-He Liao (2009). "Time series prediction based on NARX neural networks: An advanced approach". In: *2009 International Conference on Machine Learning and Cybernetics*. Vol. 3, pp. 1275–1279.
- [5] Lin, Tsungnan et al. (1996). "Learning long-term dependencies in NARX recurrent neural networks". In: *IEEE Transactions on Neural Networks* 7.6, pp. 1329–1338.
- [6] Diaconescu, Eugen (2008). "The use of NARX neural networks to predict chaotic time series". In: *Wseas Transactions on computer research* 3.3, pp. 182–191.
- [7] Ham, Fredric M. and Ivica Kostanic (2003). *Principles of Neurocomputing for Science&Engineering*. McGrawHill Education. ISBN: 7-111-12409-X.
- [8] Haykin, Simon (1998). *Neural Networks: A Comprehensive Foundation*. 2nd. Upper Saddle River, NJ, USA: Prentice Hall PTR. ISBN: 0132733501.
- [9] International Civil Aviation Organization (2007). *Annex 3 to the Convention on International Civil Aviation, Meteorological Service for International Air Navigation*.
- [10] Anadolu Üniversitesi Havacılık ve Uzay Bilimleri Fakültesi (2016). *LTBY Havaalanı*. [Online]. Available: <http://ecas.anadolu.edu.tr/havaalani>. (Visited on 04/01/2016).
- [11] Devlet Hava Meydanları İşletmesi (2004). *Meteoroloji Ders Kitabı*. Ed. by Seyrüsefer Dairesi Başkanlığı. Ankara.
- [12] U.S. Department of Transportation Federal Aviation Administration Flight Standards Service (2007). *Instrument Flying Handbook*.
- [13] Elliott, D.L. (1993). "A better activation function for artificial neural networks". In: *ISR Technical Report TR 93-8*.
- [14] Sibi, P., S.Allwyn Jones, and P. Siddharth (2013). "Analysis of different activation functions using back propagation neural networks". In: *Journal of Theoretical and Applied Information Technology* 47.3, pp. 1264–1268.