

ULAŞTIRMA TALEPLERİNİN YAPAY SİNİR AĞLARI YARDIMI İLE TAHMİNİ

Yusuf Kağan DEMİR¹, Haluk GERÇEK²

SUMMARY

One of the main problems of the transportation planning is the modelling of human behaviour under different conditions. In order to establish a good mathematical model, careful data and information collection process is needed. Many modelling technics are available for transportation demand forecasting. Regression analysis is simple, but it generally does not represent the behaviour of the observed case, especially if data is not sufficient and/or reliable. This paper compares the results of the regression analysis and the neural networks, a recently developing modelling technic, used to predict the trip productions of the zones in Denizli-Aydın Motorway corridor.

ÖZET

Ulaştırma planlamasının ana sorunlarından biri, değişik koşullar altında insan davranışının modellenmesidir. Bunun için özenli ve yoğun bir veri toplama çalışmasına gerek vardır. Yolculuk verileri genel olarak anketler yoluyla elde edilir ve pahalıdır. Regresyon analizi, talep modellerinde yaygın biçimde kullanılır. Ancak verilerin sayısının yetersiz olması durumunda regresyon analizi ile başarılı bir modelleme yapmak zorlaştırmaktadır. Bildiride, önce genel olarak yapay sinir ağlarının yapısı incelenmiş ve geri yayılmalı en küçük kareler yöntemi öğrenme düzenine değinilmiştir. Ardından son yılların çok kullanılan ve oldukça ilgi gören yöntemlerinden olan yapay sinir ağları ile regresyon analizinin aynı veri kümeleri için buldukları sonuçlar karşılaştırılmıştır. Bunun için Denizli-Aydın Otoyolu trafik etünde kullanılmak amacıyla toplanan veriler kullanılmıştır.

1. GİRİŞ

Mühendislik hesaplarının tümünde amaç incelenen olayı en iyi temsil edebilecek modeli kurmaktır. Verilerin kesinliği arttığında ve sayısı çoğaldığında olayı temsil etmek için kullanılan modelin güvenilirliği artmaktadır. Ancak, gerçekte ölçüm hataları ve diğer etkenler verilerin güvenilirliğini düşürmektedir. Daha güvenilir veriler, daha fazla zaman ve daha yüksek maliyetler anlamına gelmektedir. Ulaştırma planlamasının temel hedeflerinden biri model kurarak, gelecekteki ulaşırma taleplerini tahmin etmek ve buna bağlı olarak ortaya çıkacak sorunları çözmek için alınması gereken önlemleri belirlemektir. Modellenmek istenen olay insan davranışı olduğundan veriler anket yöntemleri ve sayımlarla elde edilmektedir. Modelin kurulması için en çok kullanılan yöntem ise regresyon analizidir. Değişkenlerin birden fazla olduğu durumlarda çoklu regresyon analizi yapılmaktadır. Yöntemin uygulanması son derece basit ve kısadır.

¹ Araş. Gör., İ.T.Ü. Fen Bilimleri Enstitüsü.

² Prof.Dr., İ.T.Ü. İnşaat Fakültesi, Ulaştırma Anabilim Dalı.

Buna karşılık, olay parametreleri arasında korelasyon ilişkisinin bulunması çoklu regresyon analizini olumsuz etkilemekte, bu da benzerlik ilişkisi bulunan veriler arasından çoğu zaman birini tercih etmeyi zorunlu kılmaktadır.

Yapay sinir ağları son on yıl içerisinde oldukça ilgi gören bir modelleme tekniğidir. Biyolojik sinir sisteminin çalışma düzenini örnek alarak işler. Mühendislik uygulamalarında görüntü tanımında, modelleme ya da optimizasyon gibi benzer konuların çözümünde kullanılmaktadır. Kullanım alanlarına göre her sinir yapısı farklılıklar gösterir. Genel olarak sinir ağları iki grupta toplanabilir. Bunlardan birincisi öğrenme ve uyarlama yeteneğine sahip olan 'yenilemeli' ya da 'geri yayılmalı', ikincisi ise 'ileri beslemeli' sinir ağlarıdır. Birinci gruptaki sinir ağları her yeni veri girişinde çıkan sonuçlara göre kendilerini yenilerler. İkinci gruptakiler ise geri dönüp hata düzeltilmeleri yapamazlar.

Sinir ağları modelleri de diğer modellerde olduğu gibi veriye gerek gösterirler. Modeli oluşturmak için regresyon analizinde kullanılan veriler sinir ağlarında 'eğitim verileri' olarak adlandırılır. Mevcut verilerin bir bölümü, daha sonra kurulan modeli sınamak için, 'test verileri' olarak ayrılır.


Sinir ağları; petrol şirketlerinin arama maliyetlerinin düşürülmesi, bankaların kredi ödeme risklerinin hesaplanması, hisse senedi analizleri, tıp, spor (at yarışı, araba yarışları vb.), bilim ve mühendislik alanlarında karmaşık modellerin yaratılması, doğrusal ve doğrusal olmayan model davranışları, çok değişkenli eğri uyumları, akışkan modellemesi, iklim modellemesi, filtreler gibi geleneksel istatistik ve regresyon analizinin yetersiz kaldığı birçok konuda kullanılmaktadır.

2. YAPAY SİNİR AĞLARI

2.1. Yapısı

Sinir ağlarının temeli biyolojik sinir sistemine dayanır. İnsanın çevresinden algıladığı yüksek miktardaki veriyi nasıl anında değerlendirip tepki gösterdiğini ve öğrenmenin nasıl gerçekleştiğini saptamak amacıyla yapılan çalışmalar, yapay sinir ağları için temel oluşturmuştur. Çalışmalarda, sinirlerin fiziksel yapısının 'synapsis', 'hücre' (cell body) ve 'akson' olmak üzere üç ana bölümden oluştuğu saptanmıştır (Şekil 1). Synapsis, deneyimlerin saklandığı birimlerdir ve sinirlerin dentrit¹ çıkıntılarının birleştiği bölgeye verilen isimdir. Synapsisler bellek görevi yapar ve diğer sinirlerden sürekli bilgi alırlar. Hücreler, diğer adıyla 'soma', sinirlerin merkezi işlem birimidir. Görevleri, synapsislerden gelen bilgilerin değerlendirilip aksone aktarılmasıdır. Akson ise soma ile diğer sinirler arasında bir iletişim hattı görevi yapar. Her sinirin ortalama olarak 10.000 kadar synapsis bağlantısı vardır. Bu da sinir sistemi genelinde büyük bir bilgi akış kapasitesini ifade eder.


¹ Bir sinirin, diğer sinirlerle bağlantısını sağlayan hücre uzantıları.



Şekil 1: Biyolojik Bir Sinirin Yapısı [1]


2.2. Yapay Sinir Ağlarının Matematiksel Yapısı

Yapay sinir ağı biyolojik bir sinir sisteminin matematiksel ifadesidir. Çalışma düzenini biyolojik sinir sisteminden alır. Şekil 2. biyolojik bir sinirin çalışma mekanizmasının matematik ifadesidir.



Şekil 2: Yapay Sinir Ağlarının Çalışma Sistemi [1]

Yapay sinir ağlarına giren (a_n) ve çıkan (y_p) veriler vektörel olarak ifade edilirler (Şekil 3). YSA en az iki tabakadan oluşur ve her tabaka, YSA'daki tüm sayısal işlemlerin gerçekleştiği ve biyolojik sinir sisteminde somanın görevini yapan işlem birimlerini (İB) içerir. Aynı tabakada bulunan işlem birimleri arasında bağlantı yokken, ardışık tabakalardaki İB birbirlerine linklerle bağlanmışlardır (Şekil 3).




Şekil 3: Bir YSA Mimarisi

İB'ni birbirine bağlayan her link bir sinir ağırlık katsayısına sahiptir. Kolaylık açısından bu katsayılar matris şeklinde gösterilirler (Şekil 3). Bu katsayılar eğitim sırasında en uygun duruma gelinceye kadar değişirler. İB kendi giriş ve ağırlık katsayılarının bir fonksiyonudur.

$$u(t) = F(x(t), w(t)) \quad (1)$$

(1) deki F fonksiyonu olarak kullanılan değişik fonksiyonlar vardır. En çok kullanılan 'doğrusal bileşim' [linear combination] fonksiyonudur. Bu fonksiyon, vektörel iç uzay çarpımıdır (2). İki vektörün karşılaştırmasını yaparak benzerliğini ölçer. Bu, biyolojik sinir sistemindeki bellek özelliğinin matematiksel olarak ifadesidir. Başka bir benzerlik fonksiyonu ise Euclidian benzerlik ölçümüdür (Şekil 4).



Şekil 4: a) Doğrusal Bileşim b) Euclidian Benzerliği

Karşılaştırma işlemi yapıldıktan sonra elde edilen benzerlik ölçümleri İB lere gönderilir ve burada dönüşüm fonksiyonundan (f) geçirilirler. Bu fonksiyon, kullanılan amaca göre çeşitlilik gösterir ve seçimi bize bağlıdır. Her olayın doğal davranışını bulan


$$y_j = f \left(\sum_{i=0}^n x_i w_{ij} \right) = f (x \bullet w_j) \quad (2)$$

en iyi sinir mimarisini bulmak kadar fonksiyonu saptamak da önemlidir.

2.2.1. Dönüşüm (Etkinlik,İB) Fonksiyonları

Şekil 5'de, bazı dönüşüm fonksiyonlarının grafikleri görülmektedir. Bunlardan en çok kullanılan doğrusal ve sigmoid fonksiyonlardır.

Şekil 5: Dönüşüm Fonksiyonları Grafikleri



Sigmoid fonksiyon yamaç fonksiyonun sürekli halidir ve monotonik artarak belirli limitler içerisindeki değerlere doğrusal olmayan artışla 0 ile 1 arasındaki değerler atar (Şekil 5 d). Sinir ağlarını oluşturan ögeler ve karşılaştırma bağlantı ağırlıkları ile etkinlik fonksiyonları YSA'nın bir model oluşturmaları için yeterli değildir. Tüm bu fonksiyonları kullanacak ve gerektiğinde kendini doğru tahmine doğru değiştirecek bir düzene gerek vardır. Bu düzeni öğrenme algoritmaları sağlar. Bir çok öğrenme algoritması vardır ve kullanılan amaca göre algoritma seçimi değişir. Örneğin bunlardan biri, Klopff tarafından 1986 yılında geliştirilen ve görüntü tanımlaması sırasında ortaya çıkan desen sıralamasındaki geçici değişimi yakalamaya yarayan Hebbian öğrenimidir [2]. Başka öğrenme yöntemi, bu çalışmada kullanılan, tahmin edilen değerlerle elimizdeki değerler arasındaki hata farklarının kareleri toplamı en küçük olacak şekilde bağlantı ağırlıklarını değiştiren 'geri yayılmalı en küçük kareler yöntemi' [2].

2.2.2. Bir YSA Geri Yayılmalı ve Hata Düzeltmeli Öğrenme Düzeni

Geri yayılmalı hata düzeltme tekniğinin aşamaları şöyledir [3].

- 1) Daha önceden mimarisi belirlenen YSA'nın bağlantı ağırlıklarına, herhangi bir rasgele motoru yardımıyla, rasgele sayılar atanır.
- 2) Hata, gözlenen değerlerle modelden bulunan değerlerin farkının karelerinin toplamı olarak ifade edilir.

$$E = \sum_{k=1}^L \sum_{j=1}^q (b_{kj} - z_j)^2 \quad (3)$$

- 3) Hatanın bağlantı ağırlıklarına göre türevi alınır. Bundan amaç, hatanın minimize edilmeye çalışılmasıdır.

$$\frac{\partial E}{\partial w_{ij}} = \frac{\partial}{\partial w_{ij}} \left[\sum_{k=1}^L \sum_{j=1}^q (b_{kj} - z_j)^2 \right] \Rightarrow \frac{\partial E}{\partial w_{ij}} = 2 \sum_{k=1}^L (b_{kj} - z_j) f'(z_j) y_i \quad (4)$$

- 4) Alınan türevden bulunan w_{ij} ağırlıklarına bağlı hata miktarındaki değişim yine bu ağırlıklara dağıtılır. Bunun için ;

$$w_{ij}^{\text{yeni}} = w_{ij}^{\text{eski}} + \eta \frac{\partial E}{\partial w_{ij}} \quad (5)$$

çiftliği kullanılır. Burada η değişim miktarını kontrol eden katsayıdır. Bu katsayının seçimi bize bağlıdır ve büyük seçilmesi halinde iterasyon süresi kısalabilir. Ancak bu pek tavsiye edilen bir seçim değildir. Bunun nedeni, hatanın salınımının çok sık olduğu bir bölgede yerel minimum noktasının atlanabilmesidir. Çok küçük seçilmesi ise güvenli bir yöntem olmasına karşı eğitim süresini arttırır.

5) w_{ij} ağırlıklarına dağıtılan hata bu kez V_{hi} ağırlıklarına dağıtılır. Bunun için önce yukarıda olduğu gibi toplam hatanın w_{ij} lere göre değil V_{hi} ağırlıklarına göre türevi alınır. Bunu için zincir kuralı kullanılır.

$$\frac{\partial E}{\partial V_{hi}} = \frac{\partial E}{\partial z_j} \frac{\partial z_j}{\partial y_i} \frac{\partial y_i}{\partial x_h} \frac{\partial x_h}{\partial V_{hi}} \Rightarrow \frac{\partial E}{\partial V_{hi}} = 2 \sum_{k=1}^L \sum_{j=1}^q (b_{kj} - z_j)^2 (-1) f'(z_j) w_{ij} f'(y_i) a_{kh} \quad (6)$$

6) Bu hata, 4. adımda olduğu gibi, V_{hi} katsayılarına dağıtılır.

$$V_{hi}^{yeni} = V_{hi}^{eski} + \eta \frac{\partial E}{\partial V_{hi}} \quad (7)$$

Bu işlemlerden sonra birinci tur tamamlanmış ve ilk iterasyon gerçekleşmiştir. Rasgele atanan katsayılar değiştiğinden yeni eğitim verileri YSA ya sokulur ve ikinci tur için toplam hata miktarı bulunur. Hata miktarı belirlenen sınırlar altına düştüğünde iterasyon durdurulur ve eğitim tamamlanmış olunur.

3. YSA'nın Ulaştırma Taleplerinde Kullanımı Üzerine Bir Çalışma

Tablo 1'de Denizli-Aydın Otoyolunun trafik etüdü için toplanmış veriler görülmektedir.

Tablo 1: Planlama Verileri

Nüfus	Gsyih (Milyon TL)	Oto Sayısı	Toplam Yolculuk (Yolculuk /Gün)
304,470	362,280	16,034	13,528
826,695	1,407,162	45,816	50,739
896,150	1,645,318	48,305	80,598
1,378,397	2,552,512	101,578	12,097
1,458,339	2,572,825	79,750	39,794
1,541,542	1,475,348	70,667	57,317
3,848,861	5,893,493	327,782	118,460
4,301,315	10,454,994	286,347	87,041
7,146,413	11,896,318	545,262	138,741
9,044,861	12,286,705	352,338	149,569
13,068,696	31,745,562	969,243	146,216

Tablo 2: Veri Kümesi İçin Korelasyon Matrisi

	Nüfus	Gsyih	Oto sayısı	Toplam Yolculuk
Nüfus	1			
Gsyih	0.957	1		
Oto sayısı	0.9543	0.9690	1	
Toplam Yolculuk	0.8606	0.7485	0.8111	1

Tablo 1'deki veriler Aydın-Denizli otoyolunun Kuyucak-Denizli kesimi için sürdürülmekte olan ön proje kapsamında hazırlanan Trafik Ön Etüd Raporundan alınmıştır[4]. Bu raporda, proje konusu otoyol kesimi tamamlandığında üzerinde oluşması beklenen trafik yüklerinin ve kompozisyonun öngörülmesi amacıyla yapılmış olan çalışmanın sonuçları verilmiştir. Hedef yılı (2025) için yapılan bu öngörülere bağlı olarak, otoyol ve bağlantı yolları ile kavşakların projelendirilmesinde, gelecekte ortaya çıkması beklenen trafik taleplerini karşılayabilecek kapasitede ve gereksiz yatırımları önleyecek en uygun çözümler belirlenebilecektir [4].

Tablo 1'deki illere ait değerler, illerin kendilerine ait olan değerler olmayıp bölge bazındaki değerlerdir. Veriler analize sokulmadan önce, tüm parametrelerin değerlerinin sıfır olduğu kukla değerlerden oluşan bir satır eklenmiştir. Bundan amaç YSA analizi yapılırken, modelin tüm verileri sıfır olduğunda yolculuk sayısının sıfır noktasından başlatmasıdır. Tablo 1'deki veri kümesinin korelasyon matrisi (Tablo 2) bulunmuş ve verilerin iç bağımlılığına bakılmıştır. Tahmin ettirici veriler arasında 1'e yakın ilişki iki veri arasındaki korelasyonun çok yüksek olduğunu ve modele ikisinden birinin sokulmasının yeterli olduğunu göstermektedir. Tahmin ettirici veriler arasındaki ilişkinin sıfıra yakın olması istenirken tahmin ettirici veri ile tahmin edilen arasındaki ilişkiyi temsil eden korelasyon katsayısının -1 ya da 1'e yakın olması arzu edilir. Bu örnekte toplam yolculukla en fazla ilişki içinde olan değişken nüfustur.

3.1 Yapay Sinir Ağı

Analizlerde çok tabakalı sinir modeli kullanılmıştır. Öğrenme algoritması olarak BPLSM (back propagation least square method) 'geri yayılmalı en küçük kareler yöntemi' kullanılmıştır. Sistemi işletmek amacıyla **Propagator**¹⁶ isimli paket program kullanılmıştır. Bu program C de yazılmış ve derlenmiştir. Program saniyede 100 iterasyon yapabilmektedir. Sistem uygun olan en az hata miktarına ulaştığında durdurularak ağırlık katsayıları MS Excel¹⁷ de hazırlanan tabloda yerine konulmuş ve tahmin değerleri ile beklenen değerler karşılaştırılmıştır.

3.2. Regresyon Analizi

Bağımsız değişkenler birden fazla olduğunda çoklu regresyon yöntemi kullanılmış yine bu yöntem için MS Excel¹⁸ içinde bulunan fonksiyonlardan

¹ Bu programın demosu 'http://www.esee.umbe.edu/~zwa/Gator/Description.html' adresinden elde edilebilir. Programla ilgili açıklamalar ilgili web sayfasında yer almaktadır.

faydalanılmıştır. Bulunan regresyon denklemi ve YSA'nın bulduğu değerler modeli oluşturmak için kullanılan verilerle karşılaştırılmış bağımsız değişkenler karşısında modelin davranışını görmek için hazırlanan test kümeleri kullanılmıştır.

3.3. Verilerden YSA ve Regresyon Kullanarak Talep Modeli Oluşturulması

Tablo 1'deki nüfus, gayri safi yurtiçi hasıla ve otomobil sayısı verileri yapay sinir ağlarında öğretmen veriler olarak kullanılmadan önce 0 ile 1 arasında normalize edilmiştir. Bunun nedeni nöronlarda kullanılan, doğrusal olmayan sigmoid fonksiyonun diğer nöronlardan gelen toplulaştırılmış verileri 0 ile 1 arasına atamasıdır. Eğer değerler normalize edilmeden fonksiyona sokulursa sigmoid eğrisinin özelliğinden dolayı (Şekil 6.d) belli bir değerden sonra tüm girdiler 1'e atanacaktır. Bu durum, uygun olmayan bir model kurulmasına ya da öğrenmenin kararsız bir yapıya dönüşmesine neden olabilir. Tablo 1'deki değerler normalize edilirken her satırdaki en yüksek değer yerine nüfus 30 milyona, Gsyih 60 milyona, oto sayısı 2.5 milyona, toplam yolculuk ise 1 milyona bölünmüştür. Bunun nedeni, tahmin amacıyla koyacağımız verilerin YSA analizinde kullanılan öğretmen verilerden daha yüksek olduğunda modeli şaşırtmaması içindir. (Örneğin 2010 yılındaki tahmin için nüfusun 20 milyon, Gsyih'nin 40 milyon, araç sayısının 1.5 milyon olacağını öngörülebilir).

Kullanılan yapay sinir ağı çok tabakalı 3x5x3x1 sistemlidir. Regresyon analizinde veriler normalize edilmeden çoklu regresyon yapılmış ve sonuçta,

$$\text{Toplam yolculuk} = 0.02499 * \text{Nüfus} - 0.01113 * \text{Gsyih} + 0.200049 * \text{Oto sayısı}$$

bağıntısı bulunmuştur. Bu bağıntıda görüldüğü gibi Gsyih, toplam yolculuğu azaltıcı bir etkiye sahiptir. Halbuki Gsyih'in yolculuğu artırması gerekmektedir.

3.4. Model sonuçları ve modellerin test edilmesi

Tablo 1'deki verilerden aşağıda yöntemlere göre üç model kurulmuştur.

1-YSA modeli


2-Nüfus, Gsyih ve toplam oto sayısını baz alan **regresyon** modeli

3-Yalnızca nüfusu baz alan **regresyon** modeli


Model sonuçları Şekil 7, 8 ve 9'da görülmektedir.

Bağımsız değişkenlerden ikisi sabit tutulup diğeri değiştirilerek modellerin değişken karşısındaki reaksiyonunu ölçmek için üç test kümesi oluşturulmuştur.


Şekil 7'de öğretmen veriler yardımıyla bulunmuş modellerin yine öğretmen verilere ait beklenen değerler ve model tahminlerinin karşılaştırılması görülmektedir.



Şekil 7: Modellerin Öğretmen Verileri Tahminleri



Şekil 8: 1 Nolu Test Kümesi İçin Model Tahminleri



Şekil 9: 2 Nolu Test Kümesi İçin Model Tahminleri

Şekilden de görüldüğü gibi çoklu regresyon, nüfus artışına karşın verilerdeki yerel düşüşlere uyum sağlamıştır. Çoklu regresyon modelinin analiz için kullanılan verileri tahmin etmekte başarısız olduğu söylenemez (Şekil 7). Ancak eğilimine bakıldığında belli bir nüfus artışından sonra yolculuğun sabit kaldığı görülmektedir. Doğrusal regresyon modelinde ise yalnızca nüfusla yapılan regresyon analizi, çokluya göre daha fazla hata vermiş olsa da trend ve model olarak daha anlamlı gözükmemektedir. Bunun nedeni .ç bağımlılığı olan verilerin elenmesidir. YSA modeli ise hem hata oranı düşük tahminler yapmıştır, hem de artan nüfus ve Gsyih 'ye göre yükselen bir trende sahip olmuştur.

İlk testte amaç, bulunan modellerin nüfus değişkeni karşısındaki davranışlarını ölçmek ve karşılaştırmaktır. Tüm regresyon modelleri nüfus değişkenine karşı 6 milyonuncu değerden sonra çok duyarlı hale gelmekte ve hızla artışa geçmektedirler. Bu bir sorun yaratmıyor gibi gözüke de öğretmen verilerimiz içerisinde 13 milyon nüfusa sahip veriye ait yolculuk yaratımı 146,216 iken, 14 milyon nüfus ve çok daha küçük Gsyih ve Oto sahipliğine karşın , çoklu regresyon 300,000 ,doğrusal regresyon ise 218,400 yolculuk vermiş ve modelin doğruluğunu tehlikeye düşürmüştür. YSA ise aynı kesit için 69,182 yolculuk vermiştir. Ayrıca çoklu regresyon test kümesine ait ilk veri için eksi yolculuk vermiştir (Şekil 9).

İki nolu testte, regresyon analizi Gsyih artışı karşısında devamlı azalan bir yolculuk vermiştir. Bunun nedeni, regresyon katsayıları incelendiğinde kolayca görülebilir. Katsayısı negatif olan Gsyih, sabit Nüfus ve Oto sayısı karşısında arttıkça yolculuk miktarını düşürülecektir. Bu durumda regresyon analizinin uygun model olarak alınamayacağı belirginleşmektedir. YSA ise, tersine, Gsyih karşısındaki davranışıyla daha uygun bir model vermiştir.

Regresyon analizi iki no.lu testi geçememiş ve modelin kullanılamayacağı anlaşılmıştır. Bu nedenle, üç no.lu testi yapmanın artık anlamı kalmamıştır. Gsyih artmasına karşın, yolculuk yaratımının düşmesi regresyon modelinin uygun olmadığını açıkça göstermektedir.

4. SONUÇLAR

Şekil 7.8 ve 9'da görüldüğü gibi Tablo 1'deki veriler için regresyon analizi kullanılarak uygun bir matematik model elde edilememiştir. Verilerin iç bağımlılığının etkisinden kurtulmak için bağımsız değişkenlerin elenmesiyle yapılan doğrusal regresyon, çoklu regresyona göre daha kabul edilebilir olsa da R-kare testlerinden aldığı düşük testler nedeniyle verilerin doğal davranışını temsil etmede başarılı olamamış ve testler sırasında verilen değerler karşısında çok yüksek yolculuk sayıları vermiştir. Çoklu regresyon daha yüksek bir R-kare testine sahip olsa da, Gsyih karşısında gösterdiği eğilim, modeli kabul edilebilir olmaktan çıkartmaktadır. Ayrıca tahmin değerleri doğrusal regresyona göre çok daha yüksektir. Bir diğer dikkat çeken nokta, regresyon modellerinin öğretmen verileri tahmin etmekte pek zorlanmadıklarıdır. Bu, regresyon modellerinin uygun olduğu anlamına gelmemelidir. Bu durum, testlerde ortaya çıkmıştır. YSA ile bulunan değerler kabul edilebilir limitler içinde çıktığı gibi davranış olarak beklenen eğilimi göstermiştir.

KAYNAKLAR

1. Gupta , M.M., Rao, D.H. , “On The Principles of Neural Networks”, Fuzzy Sets and Systems, 61 (1994), 1-18.
2. Sanchez, E ., Lau, C. , Artifical Neural Networks, IEEE Press.
3. Sönmez, İ., Şen Z., “Yapay Sinir Ağları Yardımıyla Meteorolojide Sıcaklık Öngörüsü”, İ.T.Ü. Meteoroloji Mühendisliği Bölümü.
4. Gerçek, H., Demir, O., “Aydın-Denizli Otoyolu (Kuyucak-Denizli Kesimi) Trafik Ön Etüd Raporu” , 1997,s.32.
5. Demir, Yusuf K., “Yapay Sinir Ağlarıyla Ulaştırma Taleplerinin Tahmini”, Yüksek Lisans Tezi , İ.T.Ü. ,Ekim 1997.

