

YAPAY SINIR AĞLARI VE ÇOKLU REGRESYON ANALİZİNİN KARŞILAŞTIRILMASI

Arş. Grv. Oğuz AKBİLGİÇ
Arş. Grv. Timur KESKİNTÜRK
İ. Ü. İşletme Fakültesi,
Sayısal Yöntemler Anabilim Dalı

Bu çalışmada Yapay Sinir Ağları (YSA) bir tahminleyici olarak ele alınmış ve tahminleme başarısı çoklu doğrusal regresyon analizi ile karşılaştırılmıştır. YSA öncelikle, Regresyon Analizi'nde kullanılan temel yöntemlerden olan En Küçük Kareler (EKK) tekniği ile, daha sonra verilerin aykırı değer içermesi durumu ele alınarak, Robust Regresyon Tekniklerinden Huber, Tukey ve Andrew'in M-Kestiricileri ile karşılaştırılmıştır. Karşılaştırma kriteri olarak Hata Kareler Ortalaması (HKO) ve model seçim kriterlerinden ICOMP (Information Complexity) Kriteri kullanılmıştır.

Anahtar Kelimeler: Yapay Sinir Ağları, Regresyon Analizi, ICOMP.

THE COMPARISON OF ARTIFICIAL NEURAL NETWORKS AND REGRESSION ANALYSIS

In this study, Artificial Neural Networks (ANN) is taken into account as an estimator and its success on forecasting is compared with multiple linear regression analysis. First, ANN is compared with Least Squares (LS) Technique, which is one of the basic techniques used for regression analysis. As a consequence, it is compared between ANN and Huber, Tukey, and Andrew's M-Estimators, which are techniques of Robust regression, by adding outliers to data. Mean Squares Error (MSE) and ICOMP (Information Complexity) are used as comparison criteria.

Keywords: Neural Networks, Regression Analysis, ICOMP.

GİRİŞ

İnsan öğrenme sisteminin taklit edilmesi esasına dayanan YSA, birçok alanda olduğu gibi istatistik alanında da geleneksel istatistiksel tekniklere bir alternatif olmuştur. Bu bağlamda, YSA ile geleneksel istatistiksel tekniklerin karşılaştırılması önemli bir hale gelmiştir.

Birçok yazar tarafından YSA ve regresyon analizinin karşılaştırılması konusu ele alınmıştır. Hruschka (1993) pazarlama konusunda tüketici tepkisinin tahminlenmesi üzerine karşılaştırmalı bir çalışma yapmıştır. Bu çalışmada, sadece tek gizli katmanlı yapay sinir ağı modelinin bile doğrusal regresyondan daha iyi sonuçlar verdiğini ortaya koymuştur. Gray ve MacDonell (1997) ise EKK, Robust Regresyon ve YSA'nı karşılaştıran deneysel bir çalışma yapmış ve YSA'nın diğer tekniklere göre daha iyi sonuçlar verdiği görülmüştür. Shuhui, Wunsch, Hair ve Giesemann (2001) belirli bir yerde kurulacak rüzgar tribünü ile elde edilebilecek gücün tahmin edilmesine yönelik yaptıkları çalışmada YSA'nın regresyon modellerinden daha iyi tahminleyici olduğunu bulmuşlardır (Kumar, 2005).

Walzack ve Sincich, üniversite adaylarının profillerinden yola çıkarak, öğrencileri üniversiteye kayıt yaptıracak ve kayıt yaptırmayacak öğrenciler olarak iki gruba ayırabilmek için YSA ve lojistik regresyon analizi uygulamışlardır. Yapılan çalışma küçük bir özel üniversitede uygulanmış ve YSA'nın öğrencileri belirtildiği gibi iki gruba ayırmada lojistik regresyondan daha başarılı olduğu görülmüştür (Walzack ve Sincich, 1999). Wang ve Elhag ise YSA ve çoklu regresyon analizini köprülerin risk skorlarını belirlemek için kullanmışlar ve yapay sinir ağlarının, köprü riskinin modellenmesi konusunda daha iyi olduğu sonucuna varmışlardır (Wang ve Elhag,

2007).

Bu çalışmada, yapay sinir ağları ve çoklu doğrusal regresyon analizinin tahmin başarıları karşılaştırılmıştır. Karşılaştırma kriteri olarak HKO ve model seçim kriterlerinden ICOMP kriteri kullanılmıştır. İlk olarak aykırı değer içermeyen bir seri üzerinde YSA ve EKK, daha sonra ise aynı seri üzerinde aykırı değerler üretilerek YSA ve robust regresyon teknikleri HKO ve ICOMP kriteri açısından karşılaştırılmıştır.

Çalışmanın birinci bölümünde YSA hakkında genel bilgiler verilmiştir. İkinci bölümde Robust regresyon ağırlıklı olmak üzere regresyon analizine yer verilmiştir. Üçüncü bölüm, model seçimi konusuna ayrılmış ve bazı temel model seçim kriterleri tanıtılmaya çalışılmıştır. Dördüncü bölüm olan uygulama bölümünde ise örnek veri setleri için YSA ve diğer tekniklerle tahminleme yapılmış, sonuçlar karşılaştırmalı olarak ele alınmıştır. Sonuç kısmında ise uygulamada elde edilen sonuçlar değerlendirilmiş ve konu ile ilgili yapılabilecek ileri çalışmalara değinilmiştir.


1 YAPAY SİNİR AĞLARI

İnsanın düşünme ve öğrenme yapısını anlamak ve onu taklit ederek benzer yapıda bilgisayar programları geliştirmek 1950'li yıllardan beri araştırma konusu olarak bilimsel alanda yerini almıştır. Yapay zeka olarak adlandırılan bu alanda son yıllarda özellikle bilgisayar kullanımının da artmasıyla yeni teknikler geliştirilmiştir. Bunların en önemlilerinden biri olan YSA, ilk olarak McCulloch ve Pitts (1943) tarafından ele alınmıştır. Daha sonra bu alandaki çalışmalar devam etmiş, ancak Minsky ve Papert (1969) yaptıkları çalışma ile YSA'nın XOR gibi çok basit bir problemi çözemeyeceğini ortaya koymalarından sonra çalışmalar yavaşlamış ve bu alana ilgi azalmıştır.

Buna rağmen YSA konusunda çalışmalar bazı araştırmacılar tarafından devam ettirilmiştir. Özellikle XOR probleminin çözülmesi ile YSA çalışmaları tekrar hız kazanmıştır. Doksanlı yıllardan sonra popüleritesi artan YSA, günümüzde halen birçok alanda başarıyla kullanılmaktadır.

YSA için yapılmış birçok tanım vardır. En genel haliyle “Yapay sinir ağları, paralel bağlı çok sayıdaki basit elemanın, gerçek dünyanın nesnelileriyle biyolojik sinir sisteminin benzeri yolla etkileşim kuran hiyerarşik bir organizasyondur” (Kohonen, 1987).

Proses elemanı da denilen yapay hücreler birbirine hiyerarşik olarak bağlıdır ve paralel olarak çalışabilmektedirler. Bağlantıların bir değeri vardır ve öğrenme yoluyla elde edilen bilgi, bu ağırlıklarda saklıdır. Bundan dolayı bir dağıtık hafızadan bahsedilmektedir. Proses elemanlarının tümü, bağlantılarıyla beraber yapay sinir ağını oluşturmaktadır (Öztemel, 2003). Şekil 1’de örnek bir yapay sinir ağı görülmektedir.



Şekil 1 Yapay sinir ağı örneği

Yapay sinir ağı genel olarak gösterilen bir veri setine karşılık bir veri seti kümesi üretmektedir. Bu bağlamda genel olarak bir YSA modeli, verilerin girildiği bir girdi katmanı, girilen verilerin işlendiği bir gizli katman ve sonuçların elde edildiği bir çıktı katmanı olmak üzere üç katmandan oluşur. YSA modelinin diğer önemli bileşeni ise katmanlar arasındaki bağlantılardır. Her bir bağlantı bir ağırlık değerine sahiptir.

Verilen girdilere karşılık uygun çıktıları vermek üzere ağı eğitilmesi, bu bağlantılar üzerindeki ağırlıkların değiştirilmesi ile sağlanır. Ağ eğitildikten sonra benzer girdiler için genelleme yaparak çıktı üretmesi beklenir. Eğitim sırasında oluşan ağırlıklar bu bilginin saklandığı değerlerdir. Bu ağırlıkların tam olarak neye karşılık geldiği bilinmemektedir. Bu yönüyle YSA içeriği tam olarak çözülememiş bir yapıya sahiptir ve bu açıdan eleştirilmektedir.

YSA’da öğrenme çok önemlidir ve doğru öğrenme modelinin seçimi çıktı değerlerinin doğruluk derecesini arttırmaktadır. Donald Hebb’in 1949 yılında yayınladığı “The Organization of Behavior” adlı kitapta Hebb kuralı olarak adlandırılan öğrenme kuralı ile ilk adım atılmıştır. Yapılan birçok çalışmada farklı öğrenme kuralları geliştirilmiştir. Amaç, probleme yönelik olarak en iyi katsayı değerlerinin belirleneceği öğrenme kuralının ortaya konulmasıdır (Elmas, 2003).

Öğrenme kuralının yanında, ağı girdi ve çıktı katmanı dışında kaç gizli katmandan oluşacağı, katmanlardaki nöron sayıları, verilerin ne kadarlık kısmının eğitim için kullanılacağı gibi parametreler kullanıcı tarafından belirlenmektedir.

YSA’nın kullanım alanı oldukça geniş olmakla birlikte özellikle fonksiyon uydurma, sınıflama, veri ilişkilendirme, kümeleme, zaman serileri analizi, sinyal filtreleme, veri sıkıştırma, doğrusal olmayan sistem modelleme, optimizasyon alanlarında kullanılmaktadır (Öztemel, 2003). Kullanım alanı oldukça geniş olan YSA ile geleneksel istatistiksel tekniklerin de karşılaştırıldığı birçok çalışma yapılmıştır. Regresyon analizi de bu karşılaştırmaya konu olan başlıca istatistiksel tahmin tekniklerindedir.

2 REGRESYON ANALİZİ

İlişki analizi olarak da adlandırılabilir. regresyon analizi, herhangi bir değişkenin, bir veya daha fazla değişkenle arasındaki ilişkinin matematik bir fonksiyon şeklinde yazılmasıdır. Tahmin yanında, bağımlı değişkeni etkileyen açıklayıcı değişkenlerin saptanmış olmasından dolayı politika belirlemede de kullanılabilir (Orhunbilge, 2002).

Regresyon analizin için önerilmiş birçok yöntem vardır. En küçük kareler (Orhunbilge, 2002), Ağırlıklı en küçük kareler (Draper ve Smith, 1998), Robust regresyon için Huber (Chen ve Pinar, 1998), Andrew (Ortiz ve diğerleri, 2006) ve Tukey'in (Ortiz ve diğerleri, 2006) M-kestiricileri, Gauss-Markov (Newbold, 2000) bunlardan bazılarıdır. Adı geçen istatistiksel yöntemlerin yanında genetik algoritma (Pan ve diğerleri, 1995), yapay sinir ağları (Stern, 1996) gibi bazı sezgisel yaklaşımlar da regresyon analizine alternatif olarak tahminlemede kullanılmaktadır.

Genel olarak çok değişkenli doğrusal regresyon modeli, girdi ve çıktılar arasındaki neden sonuç ilişkisini modellemek üzere aşağıdaki gibi gösterilir.

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \quad (1)$$

Burada Y , bağımlı (çıktı) değişkeni, X_i 'ler ($i=1,2,\dots,n$) bağımsız (girdi) değişkenleri, β_i 'ler ($i=1,2,\dots,n$) regresyon parametrelerini, ε , tesadüfi hatayı ve n ise bilinmeyen parametre sayısını ifade etmektedir.

Model parametrelerinin kestirilmesinde genellikle EKK yöntemi kullanılmaktadır. EKK, $t=1,2,\dots,T$ ile T farklı örnek noktası gösterilmek üzere aşağıdaki biçimde, kısıtsız bir optimizasyon problemi olarak yazılabilir (Wang and Elhag, 2007).

$$\text{Min} \sum_{t=1}^T (Y_t - (\beta_0 + \beta_1 X_{1t} + \beta_2 X_{2t} + \dots + \beta_n X_{nt}))^2 \quad (2)$$

Gerçek hayatta karşılaşılan birçok uygulamada hataların normal dağılımı varsayımı sağlanmaz. Hatalı bir ölçüm değeri ya da y_i değerlerindeki bir aykırı değer EKK kestiricisini ve dolayısıyla tahmin değerlerini olumsuz yönde etkiler. Aykırı değerler, EKK ile elde edilen regresyon doğrusunun aykırı değerler yönünde kaymasına neden olur. Bu nedenle aykırı değerler, EKK analizi önünde ciddi bir sorun olarak yer alır. Bu sorunun üstesinden gelmenin yollarından birisi Robust Regresyondur.

Robust regresyon, aykırı değerlerden fazla etkilenmemiş regresyon katsayılarını belirlemeye çalışır. Bu amaçla kullanılan M-kestiriciler EKK'daki hata kareler yerine hataların başka bir fonksiyonunu kullanma esasına dayanır. M-kestiricilerin genel görünümü aşağıdaki gibidir:

$$\hat{\beta}_R = \min_{\beta} \sum_{i=1}^n \rho(r_i) = \min_{\beta} \sum_{i=1}^n \rho\left(\frac{y_i - x_i' \beta}{s}\right) \quad (3)$$

Buradaki $\rho: \mathfrak{R}^1 \rightarrow \mathfrak{R}^1$ gerçel değerli bir fonksiyon ve s ise aşağıdaki formülle hesaplanan sapmadır.

$$s = \frac{\text{median}|r_i - \text{median } r_i|}{0.6745} \quad (4)$$

Denklemin 3'ün k tane ilk kısmi türevlerinin alınması ile aşağıdaki gibi birlikte çözülmesi gereken k tane eşitlik elde edilir:

$$\sum_{i=1}^n \psi\left(\frac{y_i - x_i' \hat{\beta}}{s}\right) x_{ij} = 0, \quad j=1,2,\dots,k \quad (5)$$

Burada $\psi = \rho'$, skor fonksiyonu olarak adlandırılır. Bu eşitliklerin birlikte çözülmesi ile M-kestiricileri, W ağırlık matrisi olmak üzere $\hat{\beta}_R = (X'WX)^{-1} X'Wy$

formülü ile hesaplanır. Buradan hesaplanan $\hat{\beta}_R$ değerleri yeni bir başlangıç ve $(X'WX)^{-1}$ ifadesinin yeniden hesaplanmasını gerektiren yeni ağırlıklar verir. Bu iterasyon yakınsaklık sağlanana ve kesin $\hat{\beta}_R$ değerleri elde edilene kadar devam eder.

Başlıcaları Huber, Andrew ve Tukey olmak üzere bu konuda birçok M-kestirici ortaya atılmıştır. Her bir M-kestiriciye ait $\rho(t)$, $\psi(t)$ değerlerinin hesaplanışı sırasıyla aşağıda verilmiştir:

Huber'in minimax Kestiricisi

$$\rho(t) = \begin{cases} \frac{t^2}{2} & |t| \leq b \\ \frac{b^2}{2} & |t| > b \end{cases} \quad (6)$$

$$\psi(t) = \begin{cases} t & |t| < b \\ b \operatorname{sign}(t) & |t| \geq b \end{cases}$$

Andrew'in Sinüs Dalgası Fonksiyonu

$$\rho(t) = \begin{cases} \frac{t^2}{2} & |t| \leq b \\ \frac{b^2}{2} & |t| > b \end{cases} \quad (7)$$

$$\psi(t) = \begin{cases} \sin(t) & -\pi \leq t < \pi \\ 0 & \text{diğer durumlar} \end{cases}$$

Tukey'in İkili Ağırlıklar (Bi-weight)

$$\rho(t) = \begin{cases} \frac{t^2}{2} & |t| \leq c \\ \frac{a^2}{2} & |t| > c \end{cases} \quad (8)$$

$$\psi(t) = \begin{cases} t(1 - (t/c)^2)^2 & -\pi \leq t < \pi \\ 0 & \text{diğer durumlar} \end{cases}$$

Açıktır ki bir M-kestiricisi için $\rho(t) = t^2/2$ ve $\psi(t) = t$ olarak belirlenirse EKK kestiricisi elde edilir. Yukarıdaki eşitliklerde yer alan a ve c birer sabittir ve genellikle ayarlama sabitleri olarak adlandırılırlar.

2 MODEL SEÇİMİ

Regresyon analizinde karşılaşılan problemlerden birisi model seçimidir. Verileri en iyi açıklayan modelin seçimi için geliştirilmiş birçok bilgi kriteri vardır. Bunların başlıcaları AIC (Akaike Bilgi Kriteri) (Akaike, 1974), BIC (Bayesian Bilgi Kriteri) (Schwarz, 1978) ve Bozdoğan'ın bilgi karmaşıklığı indeksi ICOMP'tur (Bozdoğan, 1988, 2000). Bu kriterlerin hepsi, parametre sayısına bağlı bir ceza fonksiyonu kullanarak, en az parametrelili ve bağımsız değişkeni en iyi açıklayan regresyon modelinin seçilmesinde kullanılırlar. En iyi model, en küçük bilgi kriteri değerini verendir. Sözü edilen bu bilgi kriterleri ceza terimleri açısından farklılık gösterirler (Liu, 2006).

AIC de sadece parametre sayısı cezalandırılırken, BIC de bu ceza terimi, gözlem sayısının logaritması ile ağırlıklandırılmıştır (Bozdoğan, 1988). Ancak bu iki kriterde bağımsız değişkenler arasında çoklu doğrusal bağlantı olması durumuna ait bir ceza terimi yoktur. ICOMP ise bu eksiklikten yola çıkarak, ceza terimine varyans-kovaryans matrisini de katarak, çoklu doğrusal bağlantılı model için ICOMP değerinin yüksek çıkmasını sağlar. Dolayısıyla çoklu doğrusal bağlantılı modelin seçilmesi engellenmiş olur. Bu nedenle çalışmada, model seçim kriteri olarak ICOMP kullanılmıştır (Bozdoğan, 2000). Sözü edilen kriterlerin formülasyonları aşağıdaki gibidir.

$$AIC = -2 \ln L(\hat{\theta}_k) + 2k \quad (9)$$

$$SBIC = -2 \ln L(\hat{\theta}_k) + k \ln n \quad (10)$$

$$ICOMP = -2 \ln L(\hat{\theta}_k) + s \ln \operatorname{tr}(I^{-1}(\hat{\theta}_k)/s) - \ln |I^{-1}(\hat{\theta}_k)| \quad (11)$$

Yukarıdaki formülasyonlarda k, parametre sayısı, n, örneklem büyüklüğü, $\hat{\theta}_k$, parametre kestirimi, $I^{-1}(\hat{\theta}_k) = \operatorname{Var}(\hat{\theta}_k)$, Fisher Bilgi Matrisinin tersi ve s,

$rk I^{-1}(\hat{\theta}_k)$ şeklindedir.

4 UYGULAMA

Çalışmamızda çoklu doğrusal regresyon analizi tekniklerinden en küçük kareler ve robust regresyon ile yapay sinir ağları iki bağımsız değişkenli model için karşılaştırılmıştır. Modelin bağımsız değişkenleri 100 ortalama ve 100 varyanslı normal dağılıma uyacak şekilde tesadüfi olarak üretilmiştir. Örnek birim sayısı, rasgele olarak üretilen bağımsız değişken değerlerinin normallik varsayımını sağlamasını garanti edebilmek için 100 olarak belirlenmiştir. Ayrıca modelin hatalar serisi de, regresyon analizinin varsayımlarından olan “hataların sıfır etrafında normal dağılması” varsayımını sağlaması için 0 ortalamalı 100 varyanslı normal dağılıma uyacak şekilde üretilmiştir. Oluşturulan teorik modelin regresyon katsayıları ise sırası ile 100, 1, 1 olarak belirlenmiştir. Buna göre oluşturulan teorik modelin değişkenleri ve model aşağıdaki gibi oluşturulmuştur. Açık ki, bağımlı değişken Y , 300 ortalama ve 300 varyans ile normal dağılır.

$$X_1 \approx N(100,100)$$

$$X_2 \approx N(100,100)$$

$$e \approx N(0,100)$$

$$Y = 100 + X_1 + X_2 + e \quad (12)$$


Verilere

http://www.isletme.istanbul.edu.tr/kisisel_dosyalar/file_184_289_otsimsonuciari.xls adresinden ulaşılabilir.

Öncelikle yukarıda açıklanan dağılım ve örnek birim sayısından bağımsız değişkenler ve hata serileri oluşturularak teorik modelde yerine koyulmuş ve teorik Y değerleri elde edilmiştir. Buradan

hareketle uygulama çalışması aşağıdaki gibi yürütülmüştür.

Çalışmaya ait uygulama MATLAB 7.0 programında yapılmıştır. En küçük kareler yöntemi için *regress*, yapay sinir ağları için *newff* fonksiyonları kullanılmıştır. Yapay sinir ağı, iki nöronlu girdi katmanı, 20 nöronlu bir gizli katman ve bir nöronlu sonuç katmanı olan ileri beslemeli ve geri yayılım algoritmali olacak şekilde yapılandırılmıştır (Şekil 2).



Şekil 2 Oluşturulan yapay sinir ağı


İlk olarak ilgili bağımsız değişken değerleri kullanılarak bağımlı değişkenin tahmini değerleri, EKK ve YSA ile tahmin edilmiş ve ilgili modeller için HKO ve ICOMP değerleri Tablo 1’de verilmiştir.

Tablo 1 EKK ve YSA karşılaştırması


	HKO	ICOMP
EKK	92.7261	758.8478
YSA	65.2367	723.4038

Tablo 1 incelendiğinde, HKO ve ICOMP değerleri açısından YSA’nın daha küçük, dolayısıyla daha iyi tahmin değerleri ürettiği görülmektedir. Tahmin değerleri ve hatalara ilişkin grafikler Şekil 3-6’da verilmiştir.


Şekil 3 EKK tahminleri ile gerçek değerlerin karşılaştırılması




Şekil 4 EKK hatalarının dağılımları



Şekil 5 YSA tahminleri ile gerçek değerlerin karşılaştırılması



Şekil 6 YSA hatalarının dağılımları




Uygulamanın bu kısmında bağımlı değişkenin aykırı değerler içermesi durumu için YSA ve robust regresyon teknikleri karşılaştırılmıştır. Bunun için mevcut veri setinde 15'inci ve 75'inci Y değerleri 500, 50'inci ve 90'ıncı Y değerleri 100 olarak değiştirilmiştir. Yeni oluşturulan veri seti için YSA ve Huber, Andrew ve Tukey'in M-kestiricileri ile bağımlı değişken değerleri tahmin edilmiş ve bu tahmin değerlerinden hareketle hesaplanan HKO ve ICOMP değeri Tablo 2'de verilmiştir.

Tablo 2 Robust teknikler ve YSA karşılaştırması


	HKO	ICOMP
Huber	181.632936	591.0747
Andrew	181.632948	591.0747
Tukey	181.632940	591.0751
YSA	180.541841	584.3988

Tablo 2 incelendiğinde, HKO ve ICOMP değerleri açısından YSA'nın daha iyi sonuçlar ürettiği görülmektedir. YSA bile birlikte Robust teknikler içerisinde en iyi sonucu veren Huber'in tahmin değerleri ve hatalarına ilişkin grafikler Şekil 7-9'da verilmiştir.


Şekil 7 YSA ve Huber'e ait tahminler ile gerçek değerlerin karşılaştırılması



Şekil 8 Huber hatalarının dağılımları



Şekil 9 YSA hatalarının dağılımları



Uygulama çalışmasının buraya kadar olan kısmı, üretilen 100 birimlik tek bir veri seti için, aykırı değer olması ve olmaması durumunda, YSA'nın karşılaştırıldığı istatistiksel tekniklerden daha iyi sonuçlar verdiğini göstermiştir. Ancak üretilen veriler tesadüfi olduğu için tek bir veri setinde YSA'nın daha iyi sonuç vermiş olması da tesadüfi olabilir. Bu tesadüfilikten kurtulmak için uygulamanın bu kısmında 1000 defa yeni veriler üretilmiş ve bu yeni veriler için yukarıdaki gibi tahminler yapılmış ve bu 1000 denemede hangi tekniğin kaç defa daha en iyi sonucu ürettiği Tablo 3 ve Tablo 4'te verilmiştir.

Tablo 3 EKK ve YSA'nın 1000 simülasyon için karşılaştırması

	HKO	ICOMP
EKK	0	0
YSA	1000	1000

Tablo 3'den görüleceği gibi bağımlı değişken aykırı değer içermemesi durumunda yapılan 1000 simülasyonun tamamında YSA, çoklu dorusal regresyon analizi için hem HKO hem de ICOMP kriteri açısından EKK' dan daha iyi tahminler üretmiştir.

Tablo 4 YSA ve robust tekniklerin 1000 simülasyon için karşılaştırması

	HKO	ICOMP
Huber	185	163
Andrew	92	84
Tukey	210	239
YSA	513	514

Tablo 4'de bağımlı değişkenin aykırı değerler içermesi durumu için yapılan 1000 simülasyonun sonuçları görülmektedir. Bu simülasyonlar sonucunda YSA, HKO kriteri açısından 513, ICOMP kriteri açısından da 514 defa karşılaştırılan robust tekniklerden daha iyi tahminler ortaya koymuştur.

SONUÇ

Çalışmada öncelikle üretilen bir veri seti için YSA, EKK ve Robust regresyon tekniklerinden Guber, Andrew ve Tukey'in M-kestiricileri ile karşılaştırılmıştır. Bu karşılaştırmalarda YSA, diğer tekniklerden daha iyi sonuçlar üretmiştir. Daha sonra elde edilen sonucun doğruluğunu kontrol edebilmek için, YSA ile EKK tekniklerini karşılaştırmak üzere 1000 denemelik bir simülasyon çalışması yapılmıştır. YSA'nın hem HKO hem de ICOMP kriteri açısından 1000 simülasyonun tamamında, EKK'dan daha iyi tahminler ortaya koyduğu görülmüştür. Aynı verilerde bağımlı değişken değerlerinde aykırı değerler üretilerek, YSA ve robust regresyon teknikleri karşılaştırılmıştır. Bu karşılaştırma sonucunda YSA ve Huber, Andrew ve Tukey'in kestiricileri, HKO kriterine göre sırasıyla **513**, 185, 92, 210 defa, ICOMP kriterine göre ise **514**, 163, 84, 239 defa en iyi tahmini vermiştir. Dolayısıyla YSA'nın aykırı değerlerin varlığı durumunda da diğer istatistiksel tekniklere iyi bir alternatif olabileceği söylenebilir.

Çalışmada yapay sinir ağı tasarımında bir optimizasyon çalışması yapılmamıştır. Gizli katman sayısı, gizli katmanda bulunacak nöron sayıları gibi ağ parametreleri, yapılan sınırlı sayıdaki denemeler sonucu belirlenmiştir. Ağ topolojisinde yapılacak, gizli katman sayısını artırmak, katmanlardaki nöron sayısını değiştirmek, ağda kullanılan transfer fonksiyonlarını değiştirmek gibi birtakım değişikliklerle YSA ile elde edilen tahminler daha da iyileştirilebilir.

KAYNAKÇA

- Akaike, H., **A new look at the statistical model identification**, *IEEE Transactions on Automatic Control* 19 (6): 716–723, 1974.
- Bozdoğan , H, **ICOMP: A New Model-Selection Criterion**, In Classification

- and Related Methods of Data Analysis, pp. 599-608, 1988.
- Bozdoğan , H, **Akaike's Information Criterion and Recent Developments in Information Complexity**, Journal of Mathematical Psychology 44, 62-91, 2000.
- Chen, B., Pinar M. Ç., **On Newton's Method for Huber's Robust M-Estimation Problems in Linear Regression**, Swets & Zeitlinger, Vol. 38 No. 4 pp. 674-684, 1998.
- Draper, N.R., Smith, H., **Applied Regression Analysis**, Wiley, 1998.
- Elmas, Ç., **Yapay Sinir Ağları**, Seçkin Yayıncılık, 2003.
- Kohonen, T., 1987, **State Of The Art In Neural Computing**, IEEE First International Conference on Neural Networks.
- Kumar, U. A., Comparison of Neural Networks and Regression Analysis: A New Insight, Expert Systems with Applications, 29, 424-430, 2005.
- Liu, Y. X., Zhang, J., Schaeffer, L. R., Yang, R.Q., Zhang, W.L., **Short Communication: Optimal Random Regression Models for Milk Production in Dairy Cattle**, American Dairy Science Association, 89:2233-2235, 2006.
- McCulloch, W., Pitts, W., 1943, **A Logical Calculus of the Ideas Immanent in Nervous Activity**, Bulletin of Mathematical Biophysics, 7:115 - 133.
- M. Minsky and S. A. Papert, 1969, **Perceptrons: An Introduction to Computational Geometry**, Cambridge, MIT Press.
- Newbold, Paul, 2000, **İşletme ve İktisat için İstatistik**, İstanbul, Literatür.
- Orhunbilge, Neyran, 2002, **Uygulamalı Regresyon ve Korelasyon Analizi**, İstanbul, İ.Ü. İşletme Fakültesi.
- Ortiz, M. C., Sarabia, L. A., Herrero, A., **A Useful Alternative for the Detection of Outlier Data in Chemical Analysis**, Talanta, 70, 499-512, 2006.
- Öztemel, E., **Yapay Sinir Ağları**, Papatya Yayıncılık, 2003.
- Pan, Z., Chen, Y., Kang, L., Zhang, Y., **Parameter Estimation By Genetic Algorithms For Nonlinear Regression**, Optimization Techniques and Applications, Proc. of ICOPA'95, Vol.2, 946-953, 1995.
- Saraç, T., 2004, **Yapay Sinir Ağları**, Seminer Projesi, Gazi Üniversitesi Endüstri Mühendisliği Anabilim Dalı.
- Schwarz, G., **Estimating the dimension of a model**, Annals of Statistics 6 (2): 461-464, 1978.
- Stern, H. S., **Neural Networks in Applied Statistics**, Technometrics, 38, 3, 205-214, 1996.
- Walzack, S., Terry, S., **A Comparative Analysis of Regression and Neural Networks for University Admission**, Information Sciences, 119, 1-20, 1999.
- Wang, Y.M., Elhag, T.M.S., **A Comparison of Neural Network, Evidential Reasoning and Multiple Regression Analysis in Modelling Bridge Risks**, Expert Systems with Applications, 32, 336-348, 2007.