



**ETLİK PİLİÇLERDE BÜYÜME EĞRİSİNİN YAPAY SİNİR AĞLARI
VE GOMPERTZ BÜYÜME EĞRİSİ MODELİ İLE TAHMİN
EDİLMESİ VE KARŞILAŞTIRILMASI**

NAGİHAN ÖZKAN

**YÜKSEK LİSANS TEZİ
ZOOTEKNİ ANA BİLİM DALI
DR. ÖĞR. ÜYESİ EMİNE BERBEROĞLU**

**TOKAT-2019
Her hakkı saklıdır**

**T.C.
TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ZOOOTEKNİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**ETLİK PİLİÇLERDE BÜYÜME EĞRİSİNİN YAPAY SINIR AĞLARI
VE GOMPERTZ BÜYÜME EĞRİSİ MODELİ İLE TAHMİN
EDİLMESİ VE KARŞILAŞTIRILMASI**

NAGİHAN ÖZKAN

**TOKAT
Ağustos - 2019**

Her hakkı saklıdır

Nagihan ÖZKAN tarafından hazırlanan “**Etlik Piliçlerde Büyüme Eğrisinin Yapay Sınır Ağları ve Gompertz Büyüme Eğrisi Modeli ile Tahmin Edilmesi ve Karşılaştırılması**” adlı tez çalışmasının savunma sınavı 24 TEMMUZ 2019 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü **ZOOTEKNİ ANA BİLİM DALI**’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.


Jüri Üyeleri

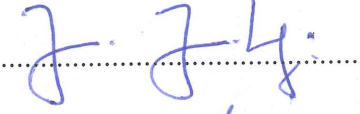
İmza

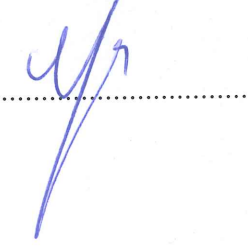
Danışman
Dr. Öğrt. Üyesi Emine BERBEROĞLU
Gaziosmanpaşa Üniversitesi

Üye
Prof. Dr. Soner ÇANKAYA
Ondokuz Mayıs Üniversitesi

Üye
Dr. Öğrt. Üyesi Yalçın TAHTALI
Gaziosmanpaşa Üniversitesi

.....


.....


.....


ONAY



Prof. Dr. Cetin GEKİC
Fen Bilimleri Enstitüsü Müdürü

TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdığı yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.

NAGİHAN ÖZKAN

20 Ağustos 2019



ÖZET

YÜKSEK LİSANS TEZİ

ETLİK PİLİÇLERDE BÜYÜME EĞRİSİNİN YAPAY SİNİR AĞLARI VE GOMPERTZ BÜYÜME EĞRİSİ MODELİ İLE TAHMİN EDİLMESİ VE KARŞILAŞTIRILMASI

NAGİHAN ÖZKAN

TOKATGAZİOSMANPAŞA ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

ZOOTEKNİ ANA BİLİM DALI

(TEZ DANIŞMANI:DR. ÖĞR. ÜYESİ EMİNE BERBEROĞLU)

Bu çalışmada doğrusal olmayan problemlerin çözümünde, etlik piliçlerde en sık kullanılan Gompertz modeli ve YSA (Yapay Sinir Ağı) ile büyüme eğrileri tahminlenmiş ve karşılaştırılmıştır.

Yöntemlerin karşılaştırılmasında; belirleme katsayısı (R^2), ortalama mutlak sapma (OMS), ortalama mutlak yüzde hata (OMYH), ve hata kareler ortalaması (HKO) istatistikleri kullanılmıştır. Elde edilen sonuçlara göre; en büyük R^2 değerine sahip olan yöntemin incelenen modeller içerisinde en iyi model olduğu saptanmıştır. Araştırmada HKO değerleri sırasıyla YSA ve Gompertz modeli için 5625 ve 2950, tahmin tutarlılığını ölçmede kullanılan hata ölçütlerinden OMYH değeri ise sırasıyla 0.27 ve 0.17 olmak üzere yakın değerler tespit edilmiştir, OMS değerleri ise sırasıyla 0.5 ve 1.2 olarak saptanmıştır. YSA model ile tespit edilen OMS değeri daha düşük bulunmuştur. R^2 değerleri YSA ve Gompertz modeli için sırasıyla 0.98 ve 0.99 olarak tespit edilmiştir. YSA ve Gompertz modelinden elde edilen R^2 değerlerinin ve OMYH değerlerinin birbirine çok yakın olduğu tespit edilmiştir. HKO değerinin; Gompertz modelinde YSA'na göre daha iyi sonuçlar verdiği, görülmüştür. Sonuç olarak; YSA modelin büyümeyi açıklamada başarılı olduğu ve bu konuda en iyi modellerden olan Gompertz modeline alternatif bir model olarak kullanılabileceği düşünülmektedir.

2019, 84 SAYFA

Anahtar Kelimeler: Etlik piliç, YSA, Gompertz büyüme eğrisi, Canlı ağırlık

ABSTRACT

MASTER THESIS COMPARISON AND PREDICTION WITH GOMPERTZ GROWTH CURVE AND ARTIFICIAL NEURAL NETWORKS MODELS IN BROILER CHICKENS

NAGİHAN ÖZKAN

**TOKAT GAZIOSMANPASA UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES**

DEPARTMENT OF ZOOTECHNICAL

SUPERVISOR:ASST. PROF. DR. EMİNE BERBEROĞLU

In this study, growth curves were estimated and compared with Gompertz model and ANN (Artificial Neural Network) which is most commonly used in broiler chickens in solving nonlinear problems.

In comparison of methods; determination coefficient (R^2), mean absolute deviation (MAD), mean absolute percent error (MAPE), and mean squares error (MSE) statistics were used. According to the results obtained; the method with the highest R^2 value was found to be the best model among the studied models. In the study obtained, MSE values were found to be 5625 and 2950 for ANN and Gompertz model, MAPE values were 0.27 and 0.17, and MAD values were 0.5 and 1.2, respectively. The MAD value determined by ANN model was found to be lower. R^2 values were determined 0.98 and 0.99 for ANN and Gompertz model, respectively. It was determined that the R^2 values obtained from ANN and Gompertz models and MAPE values are very close to each other. It has been shown that MSE value in the Gompertz model gives better results than ANN. As a result; the ANN model is thought to be successful in explaining growth and can be used as an alternative model to the Gompertz model, which is one of the best models in this respect.

2019, 84 PAGE

KEYWORDS: Broiler chickens, Artificial neural networks, Gompertz growth curve, Live weigh

ÖNSÖZ

Tezimi hazırlarken yardımlarını esirgemeyen, bana çalışmamın her aşamasında deneyim ve bilgileri ile yol gösteren danışman hocam Dr. Öğr. Üyesi Emine BERBEROĞLU'na, ilgisini ve desteğini esirgemeyen hocam Prof. Dr. Şenay SARICA'ya, katkılarından dolayı Dr. Öğr. Üyesi Yalçın TAHTALI'ya, sevgisi ve desteği ile hep yanımda olan eşim Fatih ÖZKAN'a ve canım evlatlarım Asude ÖZKAN ve Muhammed Ali ÖZKAN'a ve desteklerinden dolayı tüm aileme teşekkürleri borç bilirim.



NAGİHAN ÖZKAN

AĞUSTOS 2019

İÇİNDEKİLER

Sayfa

ÖZET	i
ABSTRACT	ii
ÖNSÖZ	iii
İÇİNDEKİLER	iv
SİMGELER VE KISALTMALAR	vi
ŞEKİL LİSTESİ	viii
ÇİZELGE LİSTESİ	ix
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	3
2.1. Yapay Sinir Ağları Kaynak Özetleri.....	3
2.2. Büyüme Eğrisi Kaynak Özetleri	7
3. MATERYAL VE YÖNTEM	14
3.1. Materyal	14
3.2. Yöntem.....	14
3.2.1. Yapay sinir ağları.....	14
3.2.2. YSA'nın genel özellikleri	14
3.2.3. Biyolojik sinir hücresi.....	16
3.2.4. Yapay sinir hücresi	17
3.2.5. Yapay sinir ağının yapısı	21
3.2.6. Yapay sinir ağlarının eğitilmesi	22
3.2.7. Gompertz modeli	25
3.3.8. Tahminin hata testi.....	28
4. BULGULAR VE TARTIŞMA	31
4.1. Gompertz Modele Ait Bulgular	31
4.2. YSA'na Ait Bulgular	35
5. SONUÇ	70
6. KAYNAKLAR	72
7. EKLER	77

7.1. Matlab Programına Ait Ekran Görüntüleri	77
7.2. SPSS(17.0) Programına Ait Ekran Görüntüleri.....	81
ÖZGEÇMİŞ	85



SİMGELER VE KISALTMALAR

Simgeler	Açıklama
%	Yüzde
R^2	Belirleme Katsayısı
P	Önem Seviyesi
R_d	Düzeltilmiş Belirleme Katsayısı
X_i	Girdiler
W_i	Ağırlıklar
Σ	Toplama Fonksiyonu
F(NET)	Aktivasyon Fonksiyonu
n	Toplam Girdi Sayısı
Y	Bağımlı Değişken
A	Asimtotik Ağırlık
β	İntegrasyon Sabiti
exp	Doğal Logaritma Tabanı
t	Zaman
k	Büyüme Oranı
m	Bükülme Noktası

Kısaltmalar	Açıklama
BY	Buzağılama Yılı
HKO	Hata Kareler Ortalaması
LS	Laktasyon Süresi
OMS	Ortalama Mutlak Sapma
OMYH	Ortalama Mutlak Yüzde Hata
SKT	Sapmaların Kareleri Toplamı
SP	Servis Periyodu
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

Şekil	Sayfa
Şekil 3.1. Biyolojik sinir hücre yapısı (Çayıroğlu, 2003).....	17
Şekil 3.2. Yapay sinir hücre yapısı.....	18
Şekil 3.3. Sigmoid aktivasyon fonksiyon modeli (Çayıroğlu, 2003).....	20
Şekil 3.4. Yapay sinir ağı yapısı (Çayıroğlu, 2003).....	21
Şekil 4.1. Gompertz model ile tahminlenen ve gözlenen ortalama değerlerin değişimi.....	32
Şekil 4.2. Birinci uygulamaya ait regresyon saçılım grafikler.....	47
Şekil 4.3. İkinci uygulamaya ait regresyon saçılım grafikleri.....	48
Şekil 4.4. Üçüncü uygulamaya ait regresyon saçılım grafikleri.....	49
Şekil 4.5. Dördüncü uygulamaya ait regresyon saçılım grafikleri.....	50
Şekil 4.6. Beşinci uygulamaya ait regresyon saçılım grafikleri.....	51
Şekil 4.7. Altıncı uygulamaya ait regresyon saçılım grafikleri.....	52
Şekil 4.8. Yedinci uygulamaya ait regresyon saçılım grafikleri.....	53
Şekil 4.9. Sekizinci uygulamaya ait regresyon saçılım grafikleri.....	54
Şekil 4.10. Dokuzuncu uygulamaya ait regresyon saçılım grafikleri.....	55
Şekil 4.11. Onuncu uygulamaya ait regresyon saçılım grafikleri.....	56
Şekil 4.12. On birinci uygulamaya ait regresyon saçılım grafikleri.....	57
Şekil 4.13. On ikinci uygulamaya ait regresyon saçılım grafikleri.....	58
Şekil 4.14. On üçüncü uygulamaya ait regresyon saçılım grafikleri.....	59
Şekil 4.15. On dördüncü uygulamaya ait regresyon saçılım grafikleri.....	60
Şekil 4.16. On beşinci uygulamaya ait regresyon saçılım grafikleri.....	61
Şekil 4.17. On altıncı uygulamaya ait regresyon saçılım grafikleri.....	62
Şekil 4.18. On yedinci uygulamaya ait regresyon saçılım grafikleri.....	63
Şekil 4.19. On sekizinci uygulamaya ait regresyon saçılım grafikleri.....	64
Şekil 4.20. On dokuzuncu uygulamaya ait regresyon saçılım grafikleri.....	65
Şekil 4.21. Yirminci uygulamaya ait regresyon saçılım grafikleri.....	66
Şekil 4.22. Yirmi birinci uygulamaya ait regresyon saçılım grafikleri.....	67
Şekil 4.23. YSA modeli ile tahminlenen ve gözlenen ortalama değerlerin değişimi.....	68

ÇİZELGE LİSTESİ

<u>Çizelge</u>	<u>Sayfa</u>
Çizelge 3.1. Bazı toplama fonksiyonları (Çayiroğlu, 2003).....	19
Çizelge 3.2. Doğrusal olmayan büyüme modelleri.....	27
Çizelge 4.1. Gözlenen ve Gompertz modeli ile tahminlenen haftalık CA değerleri ortalaması.....	31
Çizelge 4.2. Gompertz modele ait parametre değerleri ve parametrelere ait standart hata değerleri.....	32
Çizelge 4.3. Gompertz modele ait tahmin ölçütleri.....	34
Çizelge 4.4. YSA uygulama veri seti dağılımı.....	36
Çizelge 4.5. YSA analizi ile belirlenen modele ait HKO ve R ² değerleri.....	39
Çizelge 4.6. Gözlenen ve YSA modeli ile tahminlenen haftalık CA değerleri ortalaması.....	68
Çizelge 4.7. YSA modele ait tahmin ölçütleri.....	69

1. GİRİŞ

Büyüme eğrilerinin; canlıya ait ölçülerin zaman içerisindeki değişimini göstermek, uygulanan farklı bakım ve besleme koşullarının hayvanların gelişimine etkilerini belirlemek, aranan özellikler bakımından farklılıkların olup olmadığına karar vermek, en uygun kesim yaşını belirlemek, ileriye yönelik yapılacak seleksiyon çalışmalarına temel oluşturmak, ölçümün yapılamadığı durumlarda değişkeni tahmin edebilmek gibi amaçlarla kullanılabilirdiği belirtilmektedir (Lambe ve ark., 2006).

Büyüme; kalıtsal bir özellik olmakla birlikte, zaman içerisinde canlının ağırlık ve boyutlarındaki artış olarak tanımlanır. Kalıtsal bir özellik olan büyümenin ırklar, türler ve bireyler arasında farklılık gösterebildiği ve bu farklılıkların da matematik ile açıklanabileceği belirtilmektedir (Emsen ve ark., 2004).

Büyümeye ait parametreler yorumlanırken, kullanılacak matematiksel modele ve incelenen özelliğe göre farklılıklar olabilmektedir. Aynı özellik farklı büyüme modelleri ile açıklanmaya çalışıldığında, elde edilen parametreler özelliği bir modelde iyi temsil edilirken başka bir modelde bunu sağlamayabilir. Bunun en iyi göstergesi de bir özelliğe uygulanan iki farklı modelin birbirine karşılık gelen parametreleri arasındaki korelasyonların beklenen yönde ve yüksek düzeyde olmasıdır (Köyceyiz, 2003).

Yapay sinir ağı (YSA) ile hayvansal üretimde çalışmalar yapılmış ve çeşitli araştırmalarda da YSA'dan yararlanılmıştır. Kanatlı üretiminde yapılan çalışmalarda, etlik piliçlerde asitesin (Roush ve ark., 1996) ve pulmoner hipertansiyon sendromunun (Kirby ve ark., 1997) tahmin edilmesinde, aynı zamanda etlik piliçlerde verim özelliklerinin tahmin edilmesinde de YSA'dan faydalanılmıştır (Salle ve ark., 2003; Ajakaiye ve ark., 2006; Ahmadi ve ark., 2007; Gevrekçi ve ark., 2011).

YSA kullanarak çözülecek olan tarım problemlerinde başarı sağlanabilmesi için çözümü istenen problemin modellenmesinin iyi yapılması gerekmektedir. Bu modelleme ile problemi çözebilmek için yapılacak en önemli işlem söz konusu olay ile ilgili örneklerin belirlenip toparlanmasıdır. YSA da örneklerin dışında bir ön bilgiye ihtiyaç

duyulmamaktadır. Örnek bulmak, bilgi bulmaktan daha kolay yapılabilecek bir işlemdir. YSA uygulamalarının pratik olması ve maliyet gerektirmemesi bakımından daha ucuz bir yöntemdir. Problemi çözebilmek için; yalnızca bir program ve örneklerin belirlenmesi yeterli olmaktadır. YSA'nın çalışması geleneksel sistemlerden daha hızlıdır ve zamanı çok verimli kullanır. YSA da örneklerin bulunması, sinir ağlarının oluşturulması ve YSA'nın eğitilmesi işlemleri çok kısa bir zaman diliminde mümkün olabilmektedir. YSA'nın kendi kendine öğrenebilme özelliği bulunmaktadır. Bu sayede YSA daha önce karşılaşmadığı bir örneği kullanarak kendi eğitimini yapabilmektedirler. Yeni bir bilginin ortaya çıkması veya ortamda bazı değişikliklerin olması durumunda yeniden eğitilebildikleri gibi bazı durumlarda da ağların eğitilmesine gerek duyulmamaktadır (Akkaya, 2007).

Bu çalışmanın amacı; doğrusal olmayan problemlerin çözümünde, etlik piliçlerde en sık kullanılan Gompertz modeli ile bu yönteme alternatif olabileceği düşünülen YSA ile büyüme eğrilerini tahminlemek ve bu iki modeli karşılaştırmaktır. Ayrıca bu çalışma ile YSA'nın tarımsal alanda da kullanılabilirliğine dikkat çekerek tarımsal alanda kullanımını arttırmak ve bu alanlardaki problemlerin çözümüne de bir alternatif yöntem olabileceğini göstermektir.

2. KAYNAK ÖZETLERİ

2.1. Yapay Sinir Ağları Kaynak Özetleri

Elizondo ve ark., (1994a), yaptıkları çalışmada YSA'dan faydalanarak güneş ışınlarındaki radyasyon miktarını hesaplamışlardır. YSA önce eğitim daha sonra ise test aşamalarından geçirilmiştir. Günlük güneş radyasyonunu belirlemek için geliştirdikleri YSA modeli ile; günlük elde edilen yerel yağış miktarına, günün uzunluğuna, havanın en düşük ve en yüksek sıcaklığına, yılın gününe ve günlük temiz gökyüzü radyasyonuna bağlı olarak tahmin etmişlerdir. Ağın eğitimi sırasında 1978 yılından itibaren topladıkları verileri kullanmışlardır. Modelin test edilmesi sonucunda ise gerçek radyasyonla kıyaslanabilecek düzeyde sonuç elde etmişlerdir.

Elizondo ve ark., (1994b), yaptıkları çalışmada ABD de soya fasulyesinin fizyolojik olgunlaşma ve çiçeklenme tarihlerini tahmin etmek için bir YSA modeli oluşturmuşlardır. Bu çalışma için oluşturulan YSA modelini bir çıkış, üç ara ve dört giriş katmanı şeklinde oluşturmuşlardır. Giriş verisi için foto periyodu ve ekimden sonra çiçeklenmenin kaçınıcı gün olduğu, maksimum ve minimum sıcaklıklar girilmiştir; çıkış verisi olarak ise ya olgunlaşma günü ya da çiçeklenme günü ağa bilgi olarak vermişlerdir. Oluşturdukları YSA modeli ile yapmış oldukları denemeler sonucunda ise YSA'nın yaklaşık 2-4 gün hata ile tahmin yapabildiğini göstermişlerdir.

Williams ve ark., (1996), yaptıkları çalışmada güneş radyasyonunun değerlendirilmesini yapmak için YSA modelini iki çıkış, altı ara ve üç giriş katmanlarından oluşturmuşlardır. Giriş değişkenlerini; yağış, karasal radyasyon ve günlük maksimum ve minimum sıcaklık farkı gibi üç veri değeri oluşturmuştur. Deneyler radyasyon tahmininin soğuk aylarda daha hassas olduğunu göstermiştir. Analitik yöntemle göre YSA'nın daha hassas sonuçlar verdiğini gözlemlemişlerdir (Akkaya, 2007).

Parmar ve ark., (1997), yaptıkları çalışmada yerfistığında aflatoksinin önlenmesinde ve hasat öncesi kirlenme sürecine dahil olabilecek faktörlerin tanımlanması ve bu süreci etkileyen faktörlerin etkilerinin değerlendirilmesi amacıyla bir YSA modeli geliştirmişlerdir. Modele giriş verisi olarak; kuraklık süresi, toprağın sıcaklığı,

toplanmış ısı üniteleri ve bitki yaşı değişkenleri dahil edilmiştir. Toplanmış ısı üniteleri 23-29 °C arasında değişen toprak sıcaklıklarını baz alarak hesaplamışlardır. Elde edilen en hassas sonucun ise toplanmış ısı değerinin 25 °C olarak alındığı ve sekiz ara katmanı kullanıldığında elde edildiğini gözlemlemişlerdir.

Patel ve ark., (1998), yaptıkları çalışmada, yumurtaların sınıflandırılmasında YSA'dan ve bir uzman sistemden (bir bilgi alanındaki problemleri çözmede kullanılan bilgisayar yazılımlarıdır) yararlanmışlardır. Çalışmada uzman sistemi, bilgi tabanı olarak YSA'nın çıktı değerlerinde ve yumurtaların sınıflandırılmasında nasıl karar verileceğini bulmak için kullanmışlardır. Bu çalışma için bir model oluşturmuşlardır ve YSA tarafından kontrolü yapılan yumurtaların dağıtımlarının da rastgele olacak şekilde modellenmesini sağlamışlardır. Uzman sistemi örnek yumurtaların sınıflandırılmasında kullanmışlardır. Bu sistem ile yumurtaları beş grup olarak sınıflandırmışlar ve insanlar tarafından yapılan sınıflandırma ile karşılaştırmışlardır. Sonuç olarak uzman sistem ve YSA modeli ile yapılan yumurta sınıflandırması ve kontrolünün, insanlar tarafından yapılan sınıflandırma ve kontrolden daha iyi sonuçlar verdiğini belirtmişlerdir.

Moshou ve ark., (2001), yaptıkları çalışmada kendini organize edebilen YSA ile bitkileri sınıflandırmışlardır. Çalışmada ağır eğitimi süresince hatalı bilgileri düzeltmek için ağı tekrar eğitmişlerdir. Yaptıkları model ile genellemeyi iyi bir şekilde yapma ve hızlı şekilde sonuca ulaşmada modelin başarılı olduğunu gözlemlemişlerdir. Modeli, klasik bir sınıflandırma modeli olan Bayes ile karşılaştırmışlar ve önerilen modelin daha iyi sonuçlar verdiğini bildirmişlerdir.

Sharma ve ark., (2003), yaptıkları çalışmada YSA'dan yararlanarak kanalizasyon sularındaki azot miktarını tahmin etmişlerdir. YSA'na; günlük yağış ve kar yağışı miktarını, yılın günleri, toplam yağışı, toplam azot miktarı, en düşük ve en yüksek sıcaklıkları giriş verisi olarak almışlardır. Çıktı olarak ise; atık su miktarını ve bu suyun her mg'daki azot miktarı değerlerini almışlardır. Çalışmada radyal temelli fonksiyon (Radial Basis Function-RBF) ve hızlı geriye yayılım ağı (Fast back-propagation-FBP) YSA modelini geliştirerek, yeraltından dışarı çıkan atık suların ve bu sulardaki azot

konsantrasyonunun belirlenmesi için simülasyon geliştirmişlerdir. Sonuç olarak; RBF modelinin daha iyi sonuç verdiğini bildirmişlerdir.

Aitkenhead ve ark., (2003), yaptıkları çalışmada, YSA modeli kullanarak yabancı otların mahsullerden ayrılmasını sağlamışlardır. Çalışmada bitkilerin tanıtılması için öncelikle ağı eğitmişlerdir. Eğitimin sonucunda ağa daha sonra gösterilen ve ağın önceden hiç görmediği bitkilerin %75'ini tanıdığını bildirmişlerdir. Bu çalışma ile kendini eğitebilen YSA modelini kullanarak, kimyasal kullanılmadan mahsullerin yabancı otlardan ayrılmasını sağlamışlardır (Akkaya, 2007).

Yang ve ark., (2003), yaptıkları çalışmada, YSA modeli kullanarak yabancı otları yok etmek için sprej sistemini geliştirmişlerdir. Bu sistem için; eş zamanlı görüntü toplama ve bu görüntüyü işleyebilme sistemine ihtiyaç duymuşlardır. Yabancı otları tanımlamak ve yoğunluklarını belirleyebilmek için kamera sistemi kullanmışlar, görüntüyü işlemek için ise YSA modelinden yararlanmışlardır. Bulanık mantık metodunu da kullanarak yaptıkları çalışmanın sonucunda yabancı otları yok etme sistemini geliştirmeye çalışmışlardır.

Moshou ve ark., (2004), yaptıkları çalışmada bitkisel hastalıkların tespit edilip, iyileştirilmesi için bir YSA modeli geliştirmişlerdir. Bu çalışmada buğday hastalıklarından biri olan "yellow rust" için havadan ilaçlama yapabilen araç geliştirmeyi amaçlamışlardır. Ayrıca YSA modelini sınıflama için veri işlemede kullanmışlar ve bitkisel hastalıkların tanımlanmasında iyi sonuçlar elde ederek bu çalışmayı teşvik edici olarak gerçekleştirmişlerdir.

Park ve ark., (2005), yaptıkları çalışmada, ürün verimini, farklı toprak ve arazi yönetimi şartlarında tahmin etmek için, Regresyon analizi, doğrusal model ve YSA modelinden yararlanmışlardır. YSA modeli ile ürün veriminin tahminlenmesinde iyi sonuçlar ortaya koymuşlardır. Ancak; çalışmanın sonucunda kullanılan üç tekniğin de birbirlerine göre avantaj ve dezavantajlarının bulunduğunu bu sebeple birlikte kullanıldığında daha güvenilir sonuçlar elde edilebileceğini bildirmişlerdir.

Roush ve ark., (2006), yaptıkları çalışmada; çevre kontrollü kümeste yetiştirilen etlik piliçler (Ross x Ross) üzerinde yaptıkları çalışmalarında, canlı ağırlıkları günlük olarak belirlemişlerdir. Elde ettikleri veriler ile de Gompertz ve YSA modellerini karşılaştırmışlardır. Modellerin doğruluğunu, hata kareler ortalaması (HKO), ortalama mutlak sapma (OMS), ortalama mutlak yüzde hatası (OMYH) ile belirlemişlerdir.

Yazıcı ve ark., (2007), yaptıkları çalışmada insan beynindeki biyolojik sinir ağı, nöronlar ve YSA'nın genel yapısını tanıtmışlar daha sonra YSA'nın istatistiksel yöntemler ile ilişkilerini araştırmışlardır. YSA'nın bir istatistiksel analiz yöntemi olarak fayda ve sakıncalarını tartışmışlardır. Genel olarak YSA modellerinin bazı klasik istatistiksel yöntemlerin genelleştirilmiş hali olduğunu bildirmişlerdir.

Takma ve ark., (2012), yaptıkları çalışmada, Siyah Alaca ineklerinin laktasyon süt verimlerine; servis periyodu, buzağılama yılı ve laktasyon süresinin etkisini belirlemek için YSA ve çoklu regresyon modeli belirlemişler aynı zamanda modellerin uyum yeteneklerini karşılaştırmışlardır. YSA modelinde tekrarladıkları denemeler sonucunda seçtikleri modele göre, ara katman sayısını bir ve bu ara katmandaki düğüm sayısını ise üç olarak belirlemişlerdir. Modellerin karşılaştırılması yapıldığında ise kullanılan süt verimlerini tahmin etmede YSA modelinin karşılaştırması yapılan çoklu doğrusal regresyon modeline göre daha iyi sonuçlar verdiğini gözlemlemişlerdir. Sonuç olarak YSA modelinin regresyon analizine bir alternatif olabileceğini bildirmişlerdir.

Taner ve ark., (2012), yaptıkları çalışmada, Türkiye'de yetiştirilen altı adet yulaf çeşidinin fiziksel özelliklerini belirlemişlerdir. Ayrıca YSA ile yulaf çeşitlerinin sınıflandırılabilmesi için model geliştirmişlerdir. İncelenen özelliklerin (bin dane ağırlığı, küresellik, dane hacmi, geometrik ortalama çap, porozite ve renk, hacim ağırlığı, özgül ağırlık, yüzey alanı) hepsini istatistiksel açıdan önemli bulmuşlardır.

Yavuz ve ark., (2013), yaptıkları çalışmada, YSA modeli ve istatistiksel normalizasyon tekniklerini birlikte kullanarak Adana İli için hava sıcaklığını tahmin etmişlerdir. Sonuçta; YSA'nın veri normalizasyon teknikleri ve öğrenme ile geleceğe yönelik tahminler yapabilmede başarıyla kullanılabileceğini ortaya koymuşlardır.

Taner ve ark., (2015), yaptıkları çalışmada, makarnalık buğday çeşitlerini sınıflandırma amacıyla bir YSA modeli geliştirmişlerdir. Ülkemizde yetiştirilen 11 çeşit makarnalık buğdayın fiziksel özelliklerinden olan yüzey alanı, bin dane ağırlığı, dane hacmi, özgül ağırlık, geometrik ortalama çap, hacim ağırlığı, küresellik, porozite ve renk gibi özellikleri model ile belirlemişler ve özelliklerin tümünde çeşitlere göre istatistiksel farklılıkların olduğunu tespit etmişlerdir.

2.2. Büyüme Eğrisi Kaynak Özetleri

Murthy ve ark., (1972), yaptıkları çalışmada, 69 dişi, 52 erkek Malya ve 61 dişi, 113 erkek Nellore kuzularına ait büyüme verilerini büyüme eğrilerini belirlemek için kullanmışlardır. Elde ettikleri sonuçlara göre, Malya ve Nollere kuzularının dişi ve erkeklerinde 4 haftalık yaşa kadar olan dönemde büyümenin benzer oranda olduğunu, 34 haftalık yaşa kadar ise erkek kuzuların dişi kuzulardan daha hızlı büyüme gösterdiklerini bildirmişlerdir (Yeni, 2003).

Bhadula ve ark., (1980), yaptıkları çalışmada, büyümeyi belirlemek için; doğrusal, ikinci derece ve üssel fonksiyonlardan yararlanmışlardır. Muzaffarangi ve Carriedale x Muzaffarangi melezi kuzularda 0-32 hafta süresinde 4'er hafta arayla vücut ağırlığı ölçümlerini yapmışlardır. Çalışma sonucunda doğrusal ve ikinci dereceden fonksiyonlar için R^2 değerini 0.95, üssel fonksiyon için ise 0.91 olarak tespit edildiğini bildirmişlerdir.

Mukundan ve ark., (1982), yaptıkları çalışmada, Malabari keçileri ve bunların Saanen ırkı ile melezlerinde, 0-1 yaş ta elde ettikleri vücut ağırlığı ölçümlerini üssel, doğrusal ve ikinci dereceden fonksiyonlar ile incelemişlerdir. Sonuç olarak; Saanen ve Malabari keçileri için sırasıyla R^2 değerlerini 0.969 ve 0.998 olarak bulmuşlardır. Elde ettikleri sonuca göre ise doğrusal modelin en iyi model olduğunu bildirmişlerdir (Yeni, 2003).

Mukundan ve ark., (1984), yaptıkları çalışmada, Malabari keçileri ve Saanen ırkı ile melezlerinin 0-3, 3-6, 6-9 ve 9-12 aylık yaşları arasında kalan dönemlerdeki büyüme eğrilerini belirlemişlerdir. Çalışma sonucunda en iyi gelişme oranının 3-6 aylar arasında

sağlandığını, bunu 0-3 ve 6-9 aylar arasındaki gelişmenin izlediğini bildirmişlerdir. 0-1 yaş arasındaki gelişmenin ise genotip ve yılın etkisiyle önemli derecede etkilendiğini bildirmişlerdir (Yeni, 2003).

Yamaki ve ark., (1991), yaptıkları çalışmada, Poll Dorset, 1421 Suffolk, Southdown ve Cheviot ırkı kuzularının CA ait verilerini incelemişlerdir. Sonuç olarak; bu 4 ırka ait büyüme eğrilerinin benzer olduğunu tespit etmişlerdir. Gelişme oranını Suffolk kuzularında en yüksek bulmuşlardır, bunu Cheviot, Poll Dorset ve Southdown kuzularının izlediğini bildirmişlerdir. Sütten kesim ağırlığı ve doğum ağırlığı bakımından ise en yüksek değeri Suffolk'ların gösterdiğini bildirmişlerdir.

Gonzales ve ark., (1992), yaptıkları çalışmada, Spanish Black Mountain oğlaklarında 0-98 günlük yaşa kadar 15 gün ara ile ağırlıklarını tespit ederek büyüme eğrilerini belirlemişlerdir. Aralık–Ocak aylarında doğan 59 oğlak ve Eylül-Ekim aylarında doğan 68 oğlağa ait büyüme eğrilerini karşılaştırmışlardır. Çalışmanın sonucunda gelişme oranının; doğumun gerçekleştiği mevsimden, doğumun tipinden ve cinsiyetten önemli ölçüde etkilendiğini bildirmişlerdir (Yeni, 2003).

Bathaei ve ark., (1996), yaptıkları çalışmada, Brody modelini kullanarak 1239 Mehraban yağlı kuyruklu koyunların kuzularına ait büyüme eğrisi modelini belirlemişlerdir. Gelişme oranı, ergin ağırlık ve 0-48 ayda ölçülen CA'ları en küçük kareler metodu ile tahmin etmişlerdir. Doğum tipi, yıl ve cinsiyetin tüm büyüme eğrisini tanımlayan parametrelere önemli derecede etki ettiğini, ananın kuzulama yaşı, kuzunun cinsiyeti, kuzulama yılı ve doğum tipinin ise sütten kesim öncesi (90. güne kadar) gelişimini önemli derecede etkilediğini ve sütten kesim sonrası gelişimi ise sadece doğum tipi ile kuzunun cinsiyetinin etkilendiğini tespit etmişlerdir.

Friggens ve ark., (1997), yaptıkları çalışmada, British ve European kuzularının gelişmesini incelemişlerdir, ergin ağırlığı tahmin etmek ve büyüme eğrisini çizmek için Gompertz modelini kullanmışlardır. Cinsiyet ve ırkın büyüme oranı üzerine önemli etkileri bulunduğunu bildirmiştir.

Tekel (1998), yaptığı çalışmada, İvesi kuzularından 15 gün ara ile 6 ay boyunca elde ettiği CA ait verileri kullanarak büyüme eğrilerini belirlemiştir. Büyüme eğrilerinin belirlenmesinde kuzulardan 15 günde bir elde ettiği CA ait verileri; ana ağırlığı, cinsiyet ve doğum tipi olmak üzere üç makro çevre faktörüne göre düzelterek kullanmıştır. Sonrasında ise her bir kuzuya ait R^2 'leri hesaplamış ve büyüme eğrilerini çizmiştir. Çalışmada kullanılan tüm kuzulara ait verilerin doğrusal büyüme modeline daha iyi uyum sağladığını tespit etmiştir. Doğrusal model için regresyon katsayılarında homojenlik kontrolünü yapmış ve her kuzu için ayrı ayrı tahmin edilen regresyon doğrularının homojen olmadığını görmüş ve bu sebeple de ortak bir regresyon doğrusunun çizilemeyeceğini bildirilmiştir (Yeni, 2003).

Çıtak ve ark., (1998), yaptıkları çalışmada, Kilis keçilerine ait cidago yüksekliği ve CA verilerini kullanarak monomoleküler büyüme fonksiyonu ile büyümeyi tanımlamaya çalışmışlardır. Çalışma sonucuna göre CA ve cidago yüksekliği için tahmin edilen modele ait R^2 'leri sırasıyla 0.9703 ve 0.9972 olarak bildirmişlerdir. Ayrıca; cidago yüksekliği için belirlenen modelin tahminlere daha yakın olduğunu bildirilmişlerdir. CA ise, zamanla daha fazla değişiklik göstermesi sebebiyle, tahminlenen modelden sapmaların olduğunu bildirmişlerdir.

Kuzu (2002), yaptığı çalışmada; Kilis keçisi oğlaklarında 0-6 aylık yaşa kadarki dönemde, göğüs derinliği, vücut uzunluğu, CA, cidago yüksekliği, kürekler arkası göğüs genişliği ve göğüs çevresi ölçümlerine ait verileri kullanarak monomoleküler büyüme fonksiyonu ile büyüme verilerini hesaplamış ve büyüme eğrilerini çizmiştir. Sonuç olarak; CA ve değişik vücut ölçülerindeki değişimleri tanımlamada monomoleküler fonksiyonunun uygun bir model olabileceğini bildirmişlerdir.

Narinç ve ark., (2007), yaptıkları çalışmada, kapalı sistemde yetiştirilen yavaş ve hızlı gelişen etlik piliçlerde büyümeyi incelemişlerdir. 63. güne kadar haftalık olarak CA kaydetmişler ve doğrusal olmayan büyüme eğrisi modellerinden Gompertz modeli ile büyüme analizini yapmışlardır. Çalışma sonucunda; Gompertz modelin etlik piliçlerde büyüme verilerini en iyi şekilde açıkladığını bildirmişlerdir.

Topal ve ark., (2008), yaptıkları çalışmada; Broiler de doğrusal olmayan büyüme eğrisi modelleri ile karşılaştırmayı amaçlamışlardır. Bu modeller; Lojistik, Gompertz, Weibull, Von Bertalanffy ve Morgan-Mercer-Flodin (MMF) modelleridir. Sonuç olarak; Broiler de büyüme eğrisinin açıklanmasında MMF, Weibull ve Gompertz modelinin faydalı olabileceğini önermektedirler.

Narinç ve ark., (2009), yaptıkları çalışmada, Japon bıldırcınlarında (*Coturnix coturnix Japonica*) 4. haftada yüksek CA göre; 4 kuşak boyunca uygulanan seleksiyonun, CA ortalamaları, Gompertz büyüme eğrisi parametre değerleri, bükülme noktası yaşı ve ağırlıkları üzerine olan etkilerinin belirlenmesini amaçlamışlardır. Aynı zamanda parametreler arasındaki korelasyonların ortaya konmasını ve cinsiyet faktörünün etkisinin saptanmasını hedeflemişlerdir. CA değerleri bakımından cinsiyet ve hat faktörlerinin etkisini önemli bulmuşlardır.

Yıldız ve ark., (2009), yaptıkları çalışmada, Karacabey Merinosu x Kıvırcık melezi kuzuların 0-101 günlük yaşlar arası döneme ait CA verilerini kullanarak çeşitli büyüme eğrisi modellerine ilişkin parametrelerin tahminini ve büyüme modellerinin karşılaştırılmasını amaçlamışlardır. Çalışmada; doğrusal, lojistik ve gompertz modellerini kullanmışlardır. Kullandıkları modellerden hangisinin daha uygun olup olmadığına karar vermek için R^2 değeri ile tüm modellere ait CA ortalamalarının gözlenen ve tahminlenen değerleri arasındaki sapmalarının kareleri toplamını (SKT) kullanmışlardır. Sonuç olarak; erkek ve dişi kuzularda SKT sonucuna göre Gompertz modelin, Logistik ve doğrusal modele göre daha iyi uyum gösterdiği ve R^2 değeri sonucuna göre ise modeller arasında anlamlı bir farklılığın görülmediğini belirtmişlerdir. Doğrusal olmayan modeller ile basit doğrusal modelin benzerlik gösterdiği durumlarda basit modelin tercih edilmesinin daha uygun olacağını bildirmişlerdir.

Şekeroğlu ve ark., (2013), yaptıkları çalışmada, tesadüfen dağıtımı yapılmış 248 adet Ross 308 etlik piliçine ait 3 yerleşim sıklığında 0-42. güne kadar haftalık olarak elde ettikleri CA ağırlıkları kullanarak, Gompertz modeli ile büyüme eğrisini tahmin etmişlerdir. 9, 13 ve 17 etlik piliç/m² yerleşim sıklığında etlik piliçlere ait parametre

değerlerini sırasıyla A (Asimtotik ağırlık) parametresi için; 4198.46, 3807.45 ve 3999.92 g olarak ($P<0.05$); k (büyüme oranı) parametresi için; 0.055, 0.058 ve 0.052 olarak ($P<0.01$) tahmin etmişlerdir. Bu üç yerleşim yerleşim sıklıklarında R^2 sırasıyla 0.998, 0.997 ve 0.996 olarak bulmuşlardır. Çalışmanın sonucunda A, R^2 ve HKO'ya göre 9 etlik piliç/m² olan yerleşim sıklığındaki etlik piliçlerde büyümenin daha iyi olduğunu bildirmişlerdir.

Şahin ve ark., (2014), yaptıkları çalışmada, doğrusal olmayan modelleri kullanarak Anadolu mandalarının CA değişimini açıklamak ve en iyi matematiksel modeli belirlemeyi amaçlamışlardır. Bu amaçla; 2011-2012 yılları arasında Tokat il ve ilçelerinde yetiştirilen 331 baş dişi ve 309 baş erkek olmak üzere toplam 640 adet Anadolu mandası malaklarına ait CA kayıtlarından yararlanmışlardır. Çalışmalarında, doğrusal olmayan büyüme eğrisi modellerinden Richards, Brody, Gompertz ve Lojistik modelleri kullanmışlardır. En iyi modelin belirlenmesinde kriter olarak R^2 ve hata HKO sonuçlarını dikkate almışlardır. Erkek ve dişi malaklarda büyümeyi açıklayan en iyi modelin Richards modeli olduğunu bildirmişlerdir. R^2 değeri yüksek ve HKO değeri düşük olan modelin ise büyümeyi tanımlamada kullanılan en iyi model olduğunu bildirmişlerdir.

Karadavut ve ark., (2014), yaptıkları çalışmada, bildircinlerde büyümeyi tanımlamak için tek, iki ve üç aşamalı lojistik modeli kullanmışlardır. Bu model için çalışmalarında bir günlük yaşta denemeye alınan 50 adet erkek, 50 adet dişi bildircin civcivlerinin CA artışlarını kullanmışlardır. CA artışları cinsiyete göre deneme sonuna kadar 3 gün ara ile ölçülmüştür ve büyüme döneminin her aşaması için HKO, oto korelasyon, büyüme eğrisi fonksiyonunun hata varyansı ve R^2 bakımından karşılaştırmalarını yapmışlardır. Sonuç olarak, bildircinlerde canlı ağırlık artışı (CAA) bakımından büyüme eğrisi parametrelerinin bir seleksiyon kriteri olarak ta kullanılabilceğini bildirmişlerdir.

Soysal ve ark., (2015), yaptıkları çalışmada, mandalarda yaş ile CA ilişkisini farklı büyüme modelleri ile belirleyerek en uygun büyüme eğrisi modelini seçmeyi amaçlamışlardır. Çalışmalarında bir yıl boyunca CA kayıtları tutulan toplam 54 baş erkek ve dişi mandayı kullanmışlardır. Modelleme olarak ise Von Bertalanffy,

Gompertz, Richards ve Logistic modellerini kullanmışlardır. Tüm modeller için parametre değerleri hesaplamışlar, modeller arasındaki karşılaştırmayı, düzeltilmiş belirleme katsayısı (R_d), HKO, Akaike (AIC), R^2 ve Schwarz Bayesyan (BIC) uyum kriterlerine göre yapmışlardır. Çalışmalarının sonucunda tüm modellerde yüksek bir uyum olduğunu belirtmekle birlikte en iyi uyumun dışı mandalarda Richards modeli ve erkek mandalarda ise Von Bertalanffy modelinin olduğunu bildirmişlerdir.

Eleroğlu ve ark., (2016), yaptıkları çalışmada, ticari etlik piliçlerdeki büyümeyi doğrusal olmayan modeller kullanarak karşılaştırmayı amaçlamışlardır ve bu araştırma için Ross 308 hattına ait 240 adet günlük yaştaki erkek ve dışı etlik civcivleri kullanmışlardır. Büyüme eğrilerini karşılaştırmak amacıyla da Gompertz ve Lojistik modelleri kullanmışlardır. Gompertz modelden elde ettikleri bükülme noktası ağırlığı (BNA) değeri, katalog değerine Lojistik modele göre daha yakın olduğunu tespit etmişlerdir.

Mohammed (2015), yaptığı çalışmada, doğrusal olmayan Gompertz, Lojistik ve Bertalanffy modellerini karşılaştırmıştır. Araştırma 90 günlük Ross 308 civcivleri kullanılarak yapılmıştır. 6 hafta boyunca birer hafta aralıklarla civcivlerin tartımlarını yapmıştır. Çalışma sonucunda bütün R^2 'leri 0.999 olarak bulmuştur. Buna karşılık HKO ise en düşük Gompertz modelde 1068.6 olarak bulmuştur. Logistic ve Bertalanffy modellerinde ise sırasıyla 1107.5 ve 2013.7 olarak bulmuştur. Bu çalışmanın sonucunda Gompertz modelin daha düşük HKO değeriyle büyümeyi tanımlamada diğer iki modele göre daha uygun olduğu kanısına varmıştır.

Michalczuk ve ark., (2016), yaptıkları çalışmada, Gompertz, Lojistik ve Richards modellerini karşılaştırmışlardır. 9 haftaya kadar 487 erkek ve 493 dışı civcivde elde edilen CA tartım sonuçları kullanılarak büyüme modellerini karşılaştırmışlardır. Çalışma sonucunda dişilerde Gompertz model ile hesaplanan R^2 değerini 0.998, erkeklerde ise 0.996 olarak bulmuşlardır.

Adenaike ve ark., (2017), yaptıkları çalışmada, beş büyüme fonksiyonunu karşılaştırmışlardır. Bunlar; Brody, Lojistik, Gompertz, Von Bertalanffy ve Richards

modelleridir. 10 haftaya kadar gnlk olarak civcivleri tartarak elde ettikleri CA dođrusal olmayan byme modellerini kullanarak yař-vcut ađırlıđı iliřkisini deđerlendirmiřlerdir. Btn tavuk ekotiplerinin byme eđrilerinin R^2 'leri 0.998'in zerinde bulmuřlardır.



3. MATERYAL VE YÖNTEM

3.1. Materyal

Bu arařtırmada kullanılan materyali; Gaziosmanpařa Üniversitesi Tarımsal Uygulama ve Arařtırma Merkezi etlik piliç ünitesinde bireysel kafeslerde beslenen 121 adet Ross 308 etlik piliç oluřturmaktadır. Arařtırmada bu piliçlerden elde edilen 0-6 haftalık canlı ağırlık verileri kullanılmıřtır.

3.2. Yöntem

3.2.1. Yapay sinir ağıları

YSA çeřitli problemlere çözüm üretmek amacıyla insan beynindeki bilgi işleme sisteminin taklit edilerek geliřtirilmesi ile oluřturulan bilgisayar yazılımlarıdır. İnsan beynindeki mevcut biyolojik bir sinir ağıının örnek alınması sonucu oluřturulmuř YSA hafızaya alma, öğrenme, deęiřkenler arasındaki iliřkileri ortaya koyma ve öğrendiklerini yeni bilgiler üretmek genelleme yapabilme yeteneklerine sahiptirler. İstatistiksel yöntemler ile birçok alanda başarıyla uygulanabilen YSA teknolojisi arasında önemli iliřkiler bulunmaktadır (Yazıcı ve ark., 2007).

Biyolojik sinir sisteminin çalışma řekli örnek alınarak gerçekteřtirilen YSA nöronların çeřitli řekillerde birbirlerine baęlanmasıyla oluřmuř ağılardır. Oluřan bu ağılar; bilgiyi saklama, öğrenebilme ve veriler arasındaki iliřkiyi belirtebilme özelliğine sahiptirler. Bir dięer deyiřle, YSA, normalde insanların yařayarak veya deneyerek sahip olduęu öğrenme yeteneęini gerçekteřtirebilmektedir (Öztemel, 2003).

3.2.2. YSA'nın genel özellikleri

YSA, insan beynine ait fonksiyonel özelliklere benzer řekilde, öğrenebilme, optimizasyon, analiz yapma, sınıflandırma, genelleme ve iliřkilendirme gibi konularda

başarılı bir şekilde uygulanabilmektedir. Bu doğrultuda YSA'nın genel özellikleri aşağıdaki şekilde özetlenebilir (Öztemel, 2003).

1. Doğrusal olmama; YSA'nın doğrusal olmamasının sebebi işlem elamanı olan hücrenin de doğrusal yapıda olmadığından kaynaklanmaktadır. Bu durumda hücrelerin birleşmesi ile oluşan YSA da doğrusal değildir. YSA da doğrusal olmama özelliği bütün ağa yayılmış şekildedir. Ancak bu durum YSA'nın doğrusal olmayan karmaşık problemlerin çözümünde en önemli araç olmasını sağlamaktadır (Tozkan, 2004).

2. Öğrenme; YSA örnekleri kullanarak öğrenirler ve bu öğrenme işlemini yapılabilmesi için örneklerin belirlenerek, ağa gösterilmesi böylece istenen çıktılara karşılık ağın çıktı oluşturarak eğitilmesi sağlanmaktadır. Ağın elde edeceği başarı, seçilen örnekler ile doğru orantılı olmaktadır. Şayet ağa doğru bilgiler gösterilemezse ağ yanlış çıktılar üretebilmektedir (Öztemel, 2003).

3. Genelleme; YSA önceden görmediği örnekler hakkında bilgi üretebilmektedir. YSA genelleme yapabilme özelliği sayesinde eğitildiği sırasında kendisine verilen örneklerden genellemeler çıkarabilir bu sayede yeni örnekler hakkında da bilgi üretebilirler. Bozuk ya da daha önce hiç karşılaşmadığı verilerle dahi çalışabilir ve yeni bilgiler üretebilir. Bu durum YSA'nın genelleme özelliğini yansıtır (Tozkan, 2004).

4. Uygulanabilirlik; YSA, eğitimi sırasında uygulandığı problemdeki değişikliklere göre ağırlıklarını yenileyebilmektedir. Ağın eğitimi sırasında değişiklikler devam etsede ağ eğitimine devam edebilir. Bu özelliği sayesinde YSA, denetim, uyarlamalı örnek tanıma, sistem tanılama ve sinyal işleme gibi birçok alanda etkin şekilde kullanabilmektedir (Tozkan, 2004).

5. Hata Toleransı; YSA'nın paralel şekilde dağılmış bir yapıya sahip olmasının nedeni çok sayıda hücrenin çeşitli şekillerde birbirleriyle bağlanmasından kaynaklanmaktadır. Bu durum da ağın sahip olduğu bilgi, ağdaki bütün bağlantılar üzerine dağılabilmektedir. Bu durumda, eğitimi tamamlanmış bir YSA da bazı bağlantılarının ya da bazı hücrelerin etkisiz hale gelmesi durumunda dahi ağın doğru bilgi üretmesine


bir etkisi olmamaktadır. Bu nedenle, YSA geleneksel yöntemlere göre hatayı daha iyi tolere edebilmektedir (Tozkan, 2004).

3.2.3. Biyolojik sinir hücresi

İnsan beyinde hemen hemen 10 milyar sinir hücresi bulunduğu ve bu sinir hücrelerinin de aralarında bağlantı yaptığı, yapmış olduğu bu bağlantı sayısının ise 60 trilyon kadar olduğu tahmin edilmektedir. Girdi bilgilerini sinirler duyu organları aracılığı ile alarak taşıyıcı sinirler aracılığı ile işler ve kendinden sonraki sinire aktarırlar bu sayede girdi sinyalinin sinir sisteminin merkezine kadar ulaşmasını sağlarlar. Merkezi sinir sistemine ulaşan bu sinyaller ağ tarafından yorumlanarak tepki sinyallerini üretirler ve üretilen bu sinyaller de tepkilerin oluşacağı organlara sinirler aracılığı ile ulaştırılırlar. Bu işlem sonucunda duyu organlarından gelen bilgilere karşılık tepki organlarına sinir sistemi aracılığı ile uygun işaretler gönderilmiş olur (Çayıroğlu, 2003).

YSA biyolojik sinir ağlarının bir modellemesi olduğu için, YSA'nın yapısını anlamak için ilk önce biyolojik sinir sisteminin yapısını incelemek gerekmektedir. Biyolojik sinir sisteminin yapı taşı olan nöronlar dört ana bölümden oluşmaktadır. Bunlar; çekirdek, akson, dendrit, ve bağlantılar şeklindedir (Şekil 3.1.) (Çayıroğlu, 2003).

Biyolojik sinir sisteminin yapısını oluşturan elemanların işleyişi şu şekildedir; dışarıdan dendritler aracılığı ile alınan sinyaller çekirdeğe iletilir ve burada toplanır. Çekirdekte toplanan sinyaller ise diğer hücrelere iletmek üzere aksone gönderilir. Akson ise aldığı bu sinyalleri uçlarında bulunan sinaps bağlantılarını kullanarak başka sinir hücrelerine doğru iletilmesini sağlamaktadır. Sinapslar sinyali iletirken bilgiyi aktarmadan, ön işleminden geçirilerek değerlendirilir ve diğer sinir hücrelerine bu şekilde aktarılır. Bu fikrin temeline bakılırsa, "öğrenme" işlemi sinapslarda gerçekleşmektedir (Yılmaz, 2015).



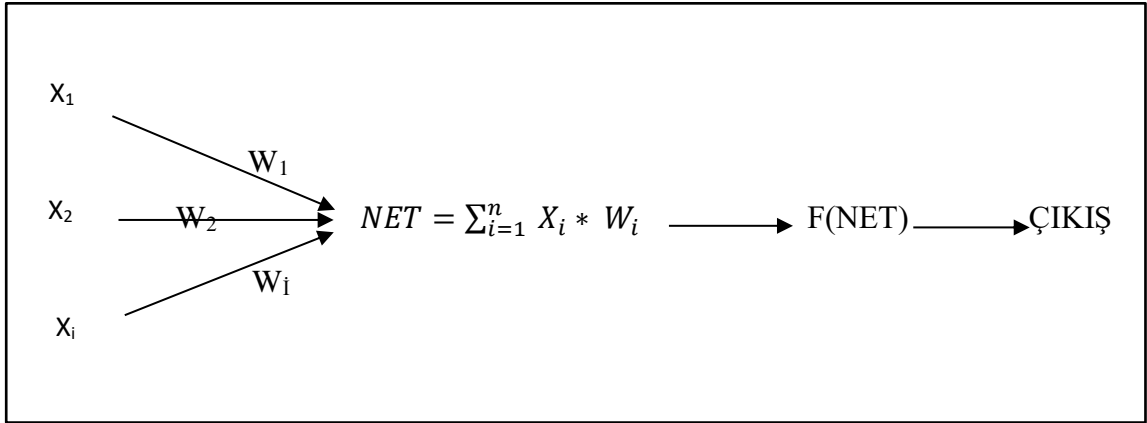
Şekil 3. 1. Biyolojik sinir hücre yapısı (Çayıroğlu, 2003)

3.2.4. Yapay sinir hücresi

Sinir hücreleri biyolojik sinir ağlarının yapı bileşenleridir ve benzer şekilde YSA da yapay sinir hücreleri bulunmaktadır (Şekil 3.1). YSA, insanlarda bulunan biyolojik sinir ağında olduğu gibi nöronlardan ve nöronlar arasındaki bağlantılardan oluşur. Bilgi, çevreden öğrenme süreciyle bir ağ tarafından elde edilir. Bu bilgileri biriktirmek için hücreler arası bağlantıları sağlayan sinaptik ağırlıkları olarak ta bilinen bağlantılar kullanılır (Haykin, 1999).

Sinir hücreleri arasındaki bağlantılar insan beyni tecrübe kazandıkça zamanla değişebilmektedir. Bu bağlantılar zayıflayabilir, kuvvetlenir veya yeni bağlantılar kurulur ve sonuç olarak insan beyninde öğrenme işlemi gerçekleşir. YSA da aynı şekilde insan beyninde olduğu gibi tecrübeye dayanarak öğrenme işlemi gerçekleştirilebilir. YSA'nın bu süreçteki öğrenmesi ise hücreler arasındaki bağlantının kuvvetlenmesi veya zayıflaması ile olmaktadır. Hücreler arasındaki bu bağlantı ağırlıklarının değiştirilmesi ile bağlantıların zayıflama veya kuvvetlenmesi sağlanır (Yılmaz, 2015).

YSA'nın çalışma sisteminde esas teşkil eden en küçük birimler, işlem elemanı olarak ya da yapay sinir hücresi olarak adlandırılır. En basit haliyle yapay sinir hücresi yapısı, Şekil 3.2'de görüldüğü gibi; girdiler (X_i), ağırlıklar (W_i), toplama fonksiyonu (NET), aktivasyon fonksiyonu ($F(\text{NET})$) ve çıkış olmak üzere beş ana bileşenden oluşmaktadır.



Şekil 3.2. Yapay sinir hücre yapısı

1. Girdi; yapay sinir hücresine dışarıdan ya da bir önceki katmandan iletilen bilgilerdir. Bu bilgiler giriş verisi olarak yapay sinir hücrelerine bağlantı aracılığıyla gönderilirler (Özveren, 2006; Yavuz ve ark., 2013).

2. Ağırlıklar; yapay hücreye gelen bilgilerin nöron üzerindeki etkisini ve önemini ifade eder. Ağırlıklar, hücre tarafından alınan girdilerin sinir üzerine olan etkisini belirleyen uygun katsayılarıdır. Ağırlıkların değerleri pozitif ve negatif olabileceği gibi sıfır da olabilir. Şayet girdinin ağırlığı sıfır ise bu ağırlık çıktı üzerine herhangi bir etki etmemektedir (Çayiroğlu, 2003; Elmas, 2003; Öztemel, 2003). YSA'nın bir problemi çözebilmesi için gerekli olan bilgiyi hazırlayan bölüm de yine ağırlıklardır (Kuyucu, 2012).

3. Toplama fonksiyonu; hücreye gelen girdilerin ağırlıklarla çarpılması ile net girdinin hesaplanmasıdır.

$$NET = \sum_{i=1}^n X_i * W_i$$

(3.1)

\sum : Toplama fonksiyonu

X_i : Girdi değeri

W_i : Ağırlık değeri

n : Hücreye gelen toplam girdi


Çizelge 3.1’de YSA da kullanılan bazı toplama fonksiyonları görülmektedir. Bazen gelen girdilerin değerini bazen de gelen girdilerin sayısını dikkate almak gerekir. Bir problemin çözümünde en uygun toplama fonksiyonunu belirlemek için geliştirilmiş bir yöntem yoktur. Toplama fonksiyonu genellikle yapılan deneme sonucunda belirlenmektedir. Bazı durumlarda ise hücreye ait toplama fonksiyonunun aynı olması gerekmez, böyle durumlarda karar tamamen tasarımcındır (Çayıroğlu, 2003).

Çizelge 3.1. Bazı toplama fonksiyonları (Çayıroğlu, 2003)

(Toplam) $NET = \sum_{i=1}^n X_i * W_i$	Ağırlıklar girdiler ile çarpılır ve elde edilen değerler toplanarak net girdi hesaplanır.
(Çarpım) $NET = \prod_{i=1}^n X_i * W_i$	Ağırlıklar girdiler ile çarpılır ve elde edilen değerler birbirleriyle çarpılarak net girdi hesaplanır.
(Maksimum) $NET = Max (X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpılırlar daha sonra içlerinden en büyük olanı net girdi olarak kabul edilir.
(Minimum) $NET = Min (X_i * W_i)$	n adet girdi içinden ağırlıklar girdilerle çarpılırlar daha sonra içlerinden en küçük olanı net girdi olarak kabul edilir.
(Çoğunluk) $NET = \sum_{i=1}^n Sgn(X_i * W_i)$	n adet girdi içinden girdiler ağırlıklarla çarpılırlar daha sonra pozitif ve negatif olanların sayısı hesaplanır. Büyük olan sayı ise hücrenin net girdisi olarak kabul edilir.
(Kümülatif Toplam) $NET = NET(eski) + \sum_{i=1}^n X_i * W_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır. Önceden hücreye gelen bilgilere yeni hesaplanan girdi değerleri eklenmek suretiyle hücrenin net girdisi hesaplanır.

3. Aktivasyon fonksiyonu; bir hücrenin girdiye karşılık üreteceği çıktıyı belirler ve bunu da hücreye gelen net girdiyi işleyerek yapar (Çayıroğlu, 2003). Girdi ve çıktı arasındaki eğrisel eşleşme yine bu fonksiyon tarafından sağlanmaktadır. Ağın performansı,

fonksiyonunun doğru seçilmesi ile önemli ölçüde ilişkilidir (Hwang ve ark., 1997). Günümüzde yaygın olarak kullanılan çok katmanlı algılayıcı modelde genel olarak hatayı minimuma indiren sigmoid fonksiyonu aktivasyon fonksiyonu olarak kullanılmaktadır (Öztemel, 2003). Geri yayılım algoritmasında ayrıca; aktivasyon fonksiyonu olarak 0 ile 1 arasında gerçel değer üreten sigmoid fonksiyonu kullanılmaktadır. Geri yayılım algoritmasındaki sigmoid fonksiyon sayesinde reel çıkışlar sağlanabildiğinden yakın iki değer arasında dahi doğru karar verilebilmektedir. Bu sayede doğrusal olmayan problemlerin çözümünde geri yayımlı öğrenme kaçınılmaz olmaktadır (Nabiyev, 2003).



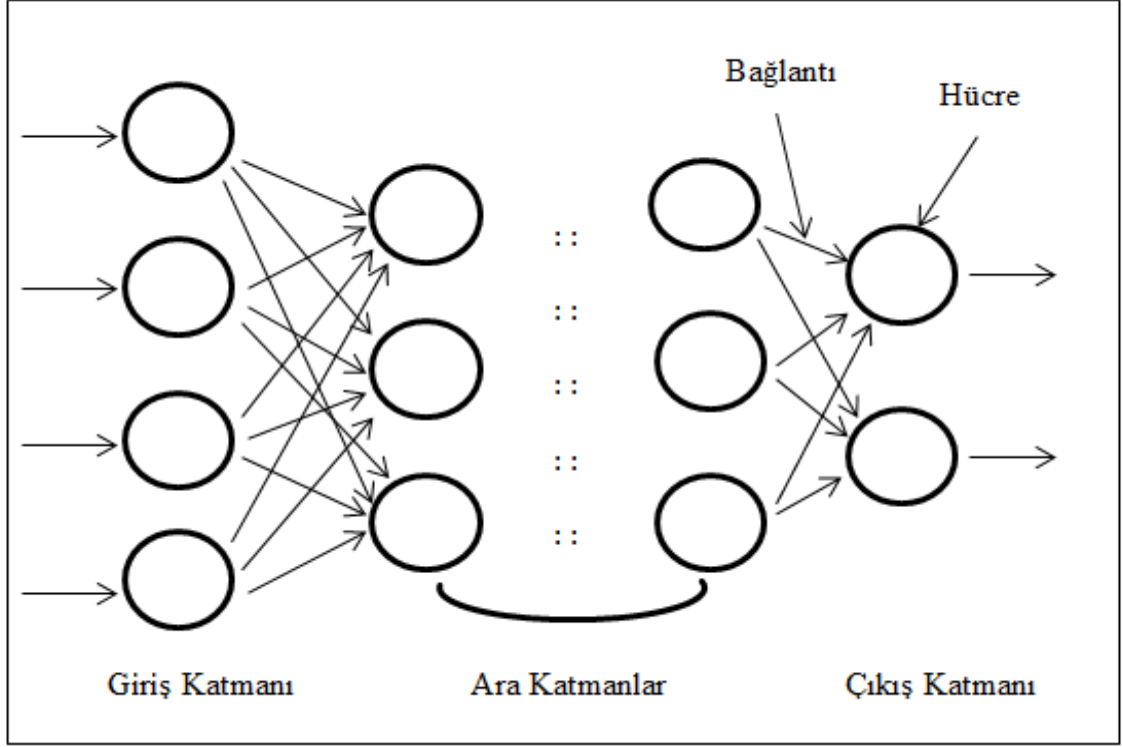
Şekil 3.3. Sigmoid aktivasyon fonksiyon modeli (Çayıroğlu, 2003)

$f(x) = \frac{1}{1+e^{-NET}}$ Burada NET işlem sürecine giren elemana gelen NET girdi değerini ifade etmektedir. Bu değer ise toplama fonksiyonunun kullanılması ile belirlenmektedir (Öztemel, 2003).

5. Çıkış; aktivasyon fonksiyonundan çıkan değer ise hücrenin çıktı değeridir. Her hücrenin birden fazla girdisi olabilir ancak çıktısı tektir. Elde edilen bu değer isteğe göre ya YSA çıktısı olarak dışarıya aktarılır veya tekrar ağı içinde kullanılabilir. Çıktı kendinden önce gelen istenilen sayıda hücreye bağlanabilir (Çayıroğlu, 2003).

3.2.5. Yapay sinir ağı yapısı

YSA yapay sinir hücrelerinin birbirlerine bağlanması sonucunda oluşan yapılardır. YSA üç katmandan oluşmaktadır. Bunlar; giriş, ara ve çıkış katmanı olmak üzere üç temel katmandan oluşur (Öztemel, 2003).



Şekil 3.4. Yapay sinir ağı yapısı (Çayıroğlu, 2003)

Şekil 3.4'te görüldüğü gibi YSA katmanları yapay sinir hücrelerinden oluşmaktadır. Aynı katmanlardaki hücreler arasında çok sayıda bağlantı kurulabilirken, aynı katmandaki hücreler arasında ise bağlantı kurulmamaktadır (Yılmaz, 2015). Dışarıdan gelen veriler ilk olarak giriş katmanındaki sinir hücreleri tarafından alınarak giriş katmanına gönderilir. Daha sonra ise gelen bilgiler, ara katmana doğru iletilir. Bazı YSA'da birden fazla ara katman bulunurken, bazılarında ise ara katman bulunmayabilir. Ara katmanın bulunmadığı durumlarda, veriler doğrudan çıkış katmanına iletilirler. Ara katmanlardaki sinir hücrelerinin sayısı, ağı giriş ve çıkış katmanını ile bu katmanlarda bulunan hücrelerin sayısına bağlı değildir (Yılmaz, 2015). Ara katmanda gerçekleşen işlemde ağı kendisi sorumludur. Bu katman bir bakıma ağı zeka içeren bölümdür ve bu katmandaki nöron sayısının fazla olması ağı ezberlemeye yönlendirir. Ağı ezberlemesi insan beynindeki bilgi tutmaya benzer. Ağı ezberlemesi değil öğrenmesi

istenilen bir durumdur. Bu sayede ağ öğrenme işlemi sayesinde yapılan herhangi bir değişikliği tolere edebilecektir aksi taktirde küçük bir değişiklikte ağ bilgiye dayalı bir probleme çözüm üretemeyecektir (Nabiyev, 2003).

Çok sayıda ara katmanın bulunduğu ağlarda YSA modeline göre katmanların kendi aralarındaki sinir hücresi sayıları da farklılıklar gösterebilmektedir, bu durum ise oluşturulan YSA modeline göre değişmektedir. Ara katmanların sayısındaki fazlalık ve bu katmanlarda bulunan yapay sinir hücrelerinin sayılarının da fazla olması demek hesaplamaların da o kadar karmaşık ve uzun sürmesi anlamına gelmektedir (Yılmaz, 2015).

Bu tür modeller hesaplama süresini ve karmaşıklığını arttırmasına rağmen YSA daha karmaşık problemlerin çözümünde de kullanılabilmesine imkan vermektedir. YSA da giriş ve çıkış katmanlarındaki nöron sayılarının belirlenmesi probleme göre belirlenebilmektedir, ancak ara katmanlardaki nöron sayısını belirlemek için, probleme göre veya genel bir çözüm yöntemi olarak, doğru sayıyı verecek herhangi bilimsel bir yöntem henüz geliştirilememiştir (Çuhadar ve ark. 2005). Ara katman ve bu katmanlardaki nöron sayısı doğru sonucu verecek şekilde deneme yanılma yöntemiyle ayarlanmaya çalışılmaktadır (Takma ve ark., 2012; Yılmaz, 2015).

3.2.6. Yapay sinir ağlarının eğitilmesi

Bir YSA öğrenirken girdi setindeki değişiklikleri değerlendirir daha sonra ağa verilen girdilere karşılık olacak çıktı değerini üretir. YSA'nın eğitilmesi sırasında dış ortamdan alınan verilerin aktivasyon fonksiyonuna iletilmesi ve sonra buradan bir çıkış oluşturulması ile olmaktadır. Öğrenme süresince YSA ağırlıklarını en doğru çıktıya ulaşabilmek için sürekli olarak değiştirmektedir. Ağırlıklar her bir iterasyonda tekrar düzenlenerek en uygun çıktıya ulaşıncaya kadar bu işlem devam eder. YSA gerçek sonuçlarla ulaşabilmek için ağa verilen sonuçlar ile kendi çıkardığı sonuçları karşılaştırarak ağırlıklarını tekrar tekrar düzenlemektedir. Bu süre içerisinde ağırlıkların yenilenmek suretiyle istenilen sonuca ulaşıncaya kadar geçen zamana ise "öğrenme" denilmektedir (Yılmaz, 2015).

YSA eğitilmesinde ağa verilen girdi bilgilerine karşılık gelen çıktı bilgileri verilerek ağın girdi-çıkıtı arasındaki ilişkiyi öğrenmesi sağlanır ve böylece ağın eğitimi gerçekleştirilmiş olunur. YSA bilgi akış biçimi bakımından ileri beslemeli ve geri yayımlı olarak iki şekilde gruplandırılabilir. İleri beslemeli ağlarda bilgi akışı ileri yönde olmakta ve bir katmandan sadece kendinden sonraki katmanlarla bağ oluşturmaktadır. Aynı zamanda ileri beslemeli ağlarda bir girdi, genel olarak bir veya iki ara ve çıktı katmanı bulunmaktadır. İleri beslemeli ağlara ayrıca, çok katmanlı ileri beslemeli ağlar da denilmektedir. Geri yayımlı ağ yapısında ise, bilgi akışı ileriye doğru olabileceği gibi geriye de doğru olarak da gerçekleşir (Asilkan ve ark., 2009). YSA eğitiminde ayrıca öğrenme hızını belirgin şekilde arttıran Levenberg- Marquardt (LM) iterasyon yöntemi etkin olarak kullanılmaktadır (Çavuşlu ve ark., 2012). Ayrıca YSA'ndaki öğrenme sistemleri de danışmanlı, danışmansız ve takviyeli öğrenme sistemleri olmak üzere üç çeşittir (Takma ve ark., 2012).

Danışmanlı öğrenme

Bu sistemde ağa verilen giriş değerlerine karşılık gelen çıktı değerleri de ağa verilir. Ağ kendisine verilen girdilere karşılık gelen çıktı değerlerini oluşturabilmek için kendi ağırlıklarını sürekli yeniler ve böylece ağın oluşturduğu çıktılar ile beklenen çıktılar arasındaki hata hesaplanarak ağın yeni ağırlıklarının belirlenmesi işlemi bu hata payına göre düzenlenmeye çalışılır (Çayıroğlu, 2003).

Ağırlıkları güncellemek için hata payı hesaplanır, bu hesaplama için ağın tüm çıktıları ile beklenen çıktıları arasındaki fark alınır ve bu farka göre de her hücreye düşen hata payı bulunarak her hücrenin kendine gelen ağırlıkları güncellemesi sağlanır (Çayıroğlu, 2003).

Geri yayılım algoritması, danışmanlı öğrenme kurallarından biridir ve bu algorithmada iki türlü bağlantı bulunmaktadır. Bunlardan ilki ileri yönlü olan bağlantıdır ve ağırlıkların kullanılması ile girişlere karşılık gelecek çıkışlar elde edilir. Geriye doğru olan ikinci bağlantıda ise çıktı katmanında meydana gelen hatanın en aza indirilmesini sağlamak için ağırlıkların geriye doğru düzenlenmesinin sağlanmasıyla gerçekleştirilir.

İleri besleme işlemi giriş katmanına gelen verilerin ilk ara katmana aktarılması işlemidir. Bu aşamalarda katmanlardaki işlemci eleman sayısının da önemi ortaya çıkmaktadır. YSA giriş katmanında bir işlem yapılmadığından uygulanan probleme göre giriş katmanındaki işlemci elemanı sayısı değişebilmektedir (Takma ve ark., 2012).

Danışmansız öğrenme

Bu sistemde ağa sadece giriş verileri gösterilirken, beklenen çıktı verileri ağa gösterilmez. Ağ beklenen çıktı bilgisinden haberi olmadan, sadece girişte verilen bilgileri analiz ederek örneklerin her birini kendi içinde sınıflandırır ve kendi kendine kurallar oluşturur (Çayıroğlu, 2003). Örneklerin kendi arasındaki ilişkiyi sistemin kendi kendine öğrenmesi beklenir. Ancak sistemin öğrenme işlemi bittikten sonra çıktıların ne anlama geldiğinin belirlenmesi işleminin ise kullanıcı tarafından yapılması gerekir. Sınıflandırma problemlerinde çoğunlukla kullanılan bir yöntemdir (Öztemel, 2003).

Takviyeli öğrenme

Bu sistemde ise ağın her iterasyon sonunda elde ettiği sonuca göre ağa bilgi verilir. Bu bilgi iterasyon sonucun iyi veya kötü olup olmadığını ağın öğrenmesini sağlar. Ağ bu bilgilere bakarak kendini doğru sonuca ulaşıncaya kadar yenilemeye devam eder. Böylece ağ girdi verisiyle hem öğrenmeye hem de sonuç çıkararak işlem yapmaya devam eder (Çayıroğlu, 2003).

Bu öğrenme şeklinde ağa bir eğitici yardım eder, ancak eğitici her girdi setine karşılık gelecek çıktı setini sisteme göstermez. Çıktı setini ağın kendisinin üretmesini bekler ve eğitici sinyal üreterek çıktının doğru mu yoksa yanlış mı olduğunu ağın öğrenmesini sağlar böylece ağ gelen bu sinyalleri de dikkate alarak öğrenme sürecine devam eder (Öztemel, 2003).

İnsan beyni doğumdan itibaren gelişmeye devam ettiği süreç içerisinde çevresinden duyu organlarıyla algıladığı davranışları yorumlar ve yaşamaya devam ettikçe tecrübe kazanır. Edinilen bu tecrübeleri diğer davranışlarında da kullanır. Beyin yaşam boyu

gelişmeye ve tecrübe kazanmaya devam eder. Böylece olaylar karşısında nasıl tepki verebileceğini de tahmin edebilir. Ancak daha önce karşılaşmadığı olaylar karşısında ise tecrübesiz kalabilmektedir. Aynı insanlarda olduğu gibi YSA'nın öğrenme sürecinde de dış ortamdan alınan veriler, aktivasyon fonksiyonundan geçer ve girişlere karşılık çıkış üretilir. Üretilen bu çıktılar tecrübeye dayalı ağa verilen çıktı verileri ile karşılaştırılarak hatanın bulunması sağlanır. Çeşitli öğrenme yöntemleri kullanılıp hata azaltılarak gerçek çıkışa yaklaşılabilir. Bu süreçte YSA'nın ağırlıkları da öğrenme devam ettikçe yenilenir ve her bir çevrimde doğru çıktıya ulaşılmaya çalışılır. Şayet YSA doğru çıktıya ulaşır ise ağırlık değerleri saklanır (Çayıroğlu, 2003).

YSA öğrenme işlemini tamamladıktan sonra ağa daha önce karşılaşmadığı girdi değerleri verilir, ağın çıkışıyla gerçek çıkışın hatası incelenir. YSA ilk kez karşılaştığı yeni örneklerle de doğru yaklaşıyorsa öğrenme işlemini gerçekleştirmiş demektir. Ayrıca ağın öğrenip öğrenmediği test edilirken genelde eldeki verilerin %80 ağa verilir ağın eğitilmesi sağlanır daha sonra verinin kalan %20'lik kısım ağa verilir ağın davranışı incelenir. Ağa verilen örnek sayısı optimum değerden fazla ise ağın öğrenmediği, ezberleme yaptığı anlaşılmaktadır (Çayıroğlu, 2003).

3.2.7. Gompertz modeli

Belirli bir zaman diliminde canlının ağırlık ve beden ölçülerindeki artış büyüme olarak tanımlanabilmektedir. Fizyolojik açıdan ise büyüme spermin yumurtayı döllemesinden sonra zigotun oluşması ile başlamaktadır. Genellikle büyümeyle karıştırılan bir terim olan gelişme ise canlının vücut şeklinin ve yapısının değişikliğe uğrayarak bazı fonksiyonları yapabilecek düzeye gelmesi olarak tanımlanabilir (Çolak ve ark, 2006).

Büyüme eğrilerinin hayvancılık alanında kullanımı Brody (1945)'nin çalışmaları ile hız kazanmış ve gelişen bilgisayar teknolojisi kullanımı ile uygun yazılımlarda geliştirilmiş böylece büyüme eğrilerinin tahmin edilmesindeki matematiksel zorluklar da büyük ölçüde aşılmıştır (Akbaş, 1995).

Doğrusal olmayan modellerin kullanılması ile yapılan arařtırmaların; ileriye yönelik ıslah alıřmaları iin bir rehber olduėunu, byonce yetiřtiricilikte yapılacak olan seleksiyonlarda istenilen fenotipik ve genetik karakterlere ulařılabileceėini, elde edilen genotiplerin ise evre faktrleriyle nasıl bir etkileřime gireceėini bu durumun ise byme eėrileri ile aıklanabileceėi grlmřtr (Yıldız ve ark., 2009).

Byme eėrilerinin yetiřtiricilikteki kullanım amaları ise řu řekilde zetlenebilir; belirli bir takım zelliėe ait llerin zaman ierisindeki deėiřimini gstermek, arařtırması yapılan zellikler ynnden farklılıkların olup olmadıėına karar verebilmek, hayvanların farklı řekillerdeki bakım ve beslemelerinin geliřimlerine olan etkilerini belirlemek, bazı dnemlerde lm yapılamayan deėiřkenin deėerini tahmin etmek, en uygun kesim yařını belirleyebilmek iin elde edilen verilerden ileriye yönelik kararlar verebilmek, byme eėrileri ve byme hızı zerine yapılan seleksiyon alıřmalarına temel saėlamak, hayvanların genel saėlık durumlarının belirlenmesi gibi yetiřtiricilikte kullanım amaları bulunmaktadır. (Yakupoėlu, 1999; Doėan, 2003; Lambe ve ark., 2006; Yıldız ve ark., 2009; elikoėlu ve ark., 2014).

Efe (1990)'ye gre; byme eėrilerinin řekli; evre řartlarına, canlının cinsiyetine, ırkına, yařına, trne ve llen karakterinin yapısına gre farklılıklar gsterebilmektedir (olak ve ark., 2006).

Akapınar ve ark., (1999)'na gre bymenin bir zelliėi olan CAA ilk bir iki gnlk dnemde doėal olarak dřk seyretmekte iken giderek ykselen artıřla pik seviyeye ulařır, ergin aėa yaklařan CAA azalarak durur. Canlının ulařabileceėi byme sınırı ve byme hızı tre gre farklılıklar gsterebilmektedir. Byonce her trn kendine ait zelliėi bir byme eėrisi oluřturabilmektedir. Kalıtım derecesi, uygun bakım-besleme kořulları da azami byme ve geliřme dzeyine ulařmada etkili faktrlerdir (elikoėlu, 2012). Zaman ierisinde meydana gelen CAA byme eėrisi modelleri ile aıklanabilmektedir (Eleroėlu ve ark., 2016). Tavuk, bıldırcın ve hindilerde bymeyi aıklayan en iyi model Gompertz modeli olmaktadır (Anthony ve ark. 1986, 1991a, 1991b).

Canlının büyümesi durgunluk evresine geldiğinde ise asimtotik (maksimum) bir sonuç değeri ile eğrinin şekli tamamlanmaktadır (Akbaş, 1995; Akbaş, 1996; Yakupoğlu, 1999). Yakupoğlu (1999); Hayvancılıkta yaygın olarak kullanılan sigmoidal büyüme eğrisi modellerinin; Çizelge 3.2. de gösterilen modeller olduğunu ifade etmiştir.

Çizelge 3.2. Doğrusal olmayan büyüme modelleri

Model İsmi	Matematiksel Model
Brody Büyüme Modeli	$Y = A[1 - \beta * \exp(-k*t)]$
Bertalanffy Büyüme Modeli	$Y = A[1 - \beta * \exp(-k*t)]^3$
Gompertz Büyüme Modeli	$Y = A * \exp[-\beta * \exp(-k * t)]$
Lojistik Büyüme Modeli	$Y = A[1 + \beta * \exp(-k*t)]^{-1}$
Richard Büyüme Modeli	$Y = A[1 - \beta * \exp(-k * t)]^m$

Çizelgede belirtilen modellere ait ifadeler;

Y : Bağımlı büyüme değişkeni

A : Asimtotik ağırlık

β : Doğum sonrası kazanılan ağırlığın, ergin CA oranı (integrasyon sabiti)

exp : Doğal logaritma tabanı (e=2,718)

t : Zamanı ifade etmektedir

k : Büyüme hızı

m : Bükülme noktası

şeklinde ifade edilmektedir.

Gompertz modelin SPSS programında hesaplanmasında başlangıç parametrelerinin belirlenmesi şöyledir;

$$k = \frac{(y_2 - y_1) / (t_1 - t_2)}{A} \quad (3.1)$$

$$y(0) = (A \exp(-\beta)) \quad (3.2)$$

$$y(0) = A * e^{-\beta}$$

$$e^{-\beta} = \frac{y(0)}{A}$$

$$\beta = \log_e \frac{y(0)}{A}$$

$$\beta = -\log_e y(0) + \log_e A$$

$y(0)$, büyümenin başlangıcında bağımlı değişkenin değerini ifade etmektedir. A ise bağımlı değişkenin genetik ve çevre şartlarında ulaşabileceği belirlenen mümkün maksimum değeri ifade etmektedir.

A , β ve k parametreleri büyüme eğrisi modelleri ile ortak olarak tahmin edilebilen parametrelerdir. Büyüme eğrilerinin tahminlenmesinde kullanılan doğrusal olmayan modellerde belirtilen A katsayısı asimtotik ağırlığı ifade etmektedir. Asimtotik ağırlık ise laktasyon, gebelik ve çevresel faktörlerin etkisi ile hayvanın kısa dönemde CA'ında meydana gelecek değişimden bağımsız olarak hayvanın ulaşabileceği en yüksek ağırlığıdır. Ergin CA ifade eden bu parametrenin birimi kg veya g'dır ve bütün büyüme eğrisi modellerinde ortak olarak tahmin edilir. Hayvanın t yaşta belirlenen CA hiçbir zaman A parametresinden fazla olamaz. β ise doğum sonrasında kazanılan ağırlığın ergin CA oranıdır ve bu parametre ağırlık (y_t) ve zamanın (t) başlangıç değeri kullanılarak tahmin edilir. k parametresi; maksimum büyüme oranının ergin ağırlığa oranını gösterir ve CA hangi hızla ergin ağırlığa yaklaştığını gösterir (Şahin ve ark., 2014).

Yapılan çalışmada ele alınacak modelin seçimi önem arz etmektedir. Seçilen modele dikkat edilmediğinde canlının büyümesi yanlış yorumlanabilmekte bunun sonucunda da o genotipe ait verim özellikleri gerçek verim değerinden farklı olabilmektedir. Bu nedenle ele alınan modelle hesaplanacak tahmini sonuçla gerçek verim değeri arasındaki sapmanın oldukça düşük olması gerekmektedir. Gerçek değerler ile tahmin edilen değerler arasındaki farklılığın yaşa göre değişimi o büyüme modeline ait sapmaların sistematik eğilimini göstermektedir (Akbaş, 1995).

3.3.8. Tahminin hata testi

Tahminlemedeki amaç; veri setine en iyi uyumu sağlayan regresyon denkleminin tespit edilmesidir. Hatayı minimum yapan değer en iyi uyumu sağlayan değerdir. Doğrusal olmayan büyüme eğrisi modellerindeki parametreler gerçekleştirilen iterasyon ile tahmin edilmektedir. Parametrelerin tahmin edilmesini sağlayacak bazı paket programlar kullanılmaktadır. Bu programlardan bazıları ise; SPSS, SAS, Minitab,

Statistica'dır. Bu çalışmada, üç parametrelili bir model olan Gompertz modelinin parametre tahminlerinin yapılması için SPSS 17.0 for windows programı kullanılmıştır. YSA ile model tahmini için ise MATLAB programından yararlanılmıştır.

En iyi tahmin modelini belirlemek için; Gompertz modeliyle tahminlenen veriler ile YSA modelinden tahminlenen verileri karşılaştırmak amacıyla; R², OMYH, OMS ve HKO ölçütleri kullanılmıştır. Araştırmada kullanılan tahmin yöntemlerinin karşılaştırılmasında ölçüt olarak R² değerleri kullanılmıştır. Elde edilen sonuçlara göre; en büyük R² değerine sahip olan yöntemin incelenen modeller içerisinde en iyi model olduğuna karar verilmektedir. Tahminin doğruluğunu test ederken hatanın küçük olması tercih edilmelidir. Çünkü tahmin hatası ile tahmin doğruluğu arasında ters orantı bulunmaktadır. Yani tahmin hatası ne kadar küçükse modelin doğruluk derecesi de o kadar yüksektir. Bu sebeple, en iyi model seçilirken yapılacak olan tahmin modellerini karşılaştırmada en küçük hata değerine sahip model tercih edilmelidir (Asilkan ve ark., 2009; Yavuz ve ark., 2013).

Matematiksel ifadeleri şöyledir;

$$R^2 = \frac{\sum(\hat{y}_t - \bar{y})^2}{\sum(y_t - \bar{y})^2} \quad (3.3)$$

$$OMS = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n} \quad (3.4)$$

$$OMYH = \frac{\sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{n} * 100 \quad (y_t \neq 0) \quad (3.5)$$

$$HKO = \frac{\sum_{t=1}^n (\hat{y}_t - y_t)^2}{n} \quad (3.6)$$

y_t : t döneminde gözlenen değer

\hat{y}_t : t dönemi için model ile tahminlenen değer

n : Toplam gözlem sayısı

OMYH istatistiđi yzde olarak ifade edilmesinden dolayı benzer yzntemlere gze stn olarak kabul edilmektedir (uuhadar ve ark., 2009, Yavuz ve ark., 2013). Witt ve Witt (1992) ve Levis (1982) OMYH deđerlerini kategorilere ayırdıđında; %10'un altında tespit edilen modelleri "uok iyi", %10-%20 arasında tespit edilen modelleri "iyi", %20-%50 arasında tespit edilen modelleri "kabul edilebilir", %50'nin üzerinde tespit edilen modelleri ise "hatalı" olarak kabul etmiřlerdir (uuhadar ve ark., 2009).



4. BULGULAR VE TARTIŞMA

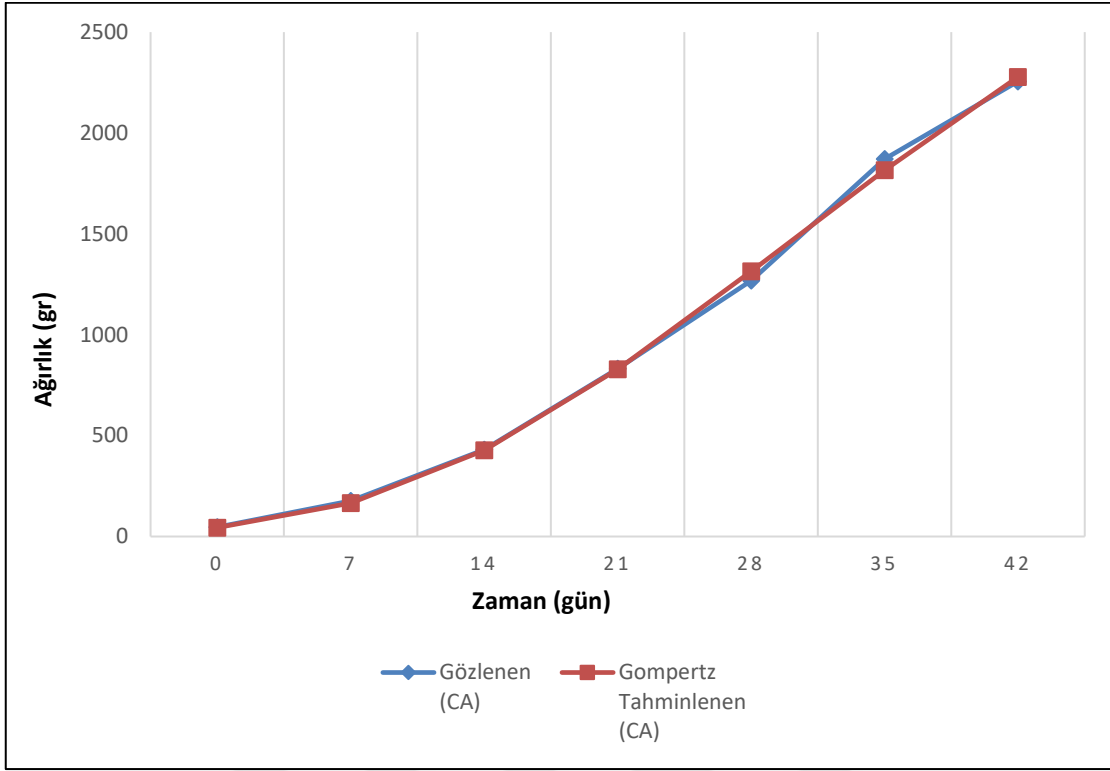
4.1. Gompertz Modele Ait Bulgular

Ross 308 etlik piliçlerinden 0-42. günler arasında haftalık alınan CA değerlerinin ortalaması ile Gompertz modeli ile tahminlenen CA değerlerinin ortalaması Çizelge 4.1’de verilmiştir.

Çizelge 4.1. Gözlenen ve Gompertz modeli ile tahminlenen haftalık CA değerleri ortalaması

Yaş (Gün)	Gözlenen (CA)	Gompertz Tahminlenen (CA)
0	46.6	44.1
7	177.1	165.8
14	430.5	427.5
21	831.9	828.7
28	1268.4	1314.2
35	1871.1	1815.2
42	2256.8	2278.8

Çizelge 4.1’de; gözlenen CA değerleri ile Gompertz modelinden tahminlenen CA değerlerinin haftalık değişimi verilmiştir. Gompertz modelinden tahmin edilen ağırlıkların gözlenen CA değerlerine yakın olduğu görülmektedir. Çizelge 4.1’in daha iyi anlaşılabilmesi için modelden tahmin edilen ve gözlenen CA ortalama değerlerine ait büyüme eğrisi grafiği Şekil 4.1’de verilmiştir.



Şekil 4.1. Gompertz modeli ile tahminlenen ve gözlenen ortalama değerlerin değişimi

Şekil 4.1’de model ile tahminlenen ve gözlenen değerlerin büyüme eğrilerinin 21. güne kadar yakın olduğu; 28. günde modelin pozitif yönde 35. günde ise negatif yönde küçük bir sapma ile tahmin yaptığı görülmektedir. Gözlenen ve modelden tahminlenen değerlere ait grafik (Şekil 4.1) incelendiğinde doğrusal olmayan modellerde kullanılan sigmoid model ile benzer olduğu görülmektedir. Bu durum CA’ya ait büyüme eğrileri modellenirken doğrusal olmayan modellerin kullanılması gerekliliğinin bir göstergesidir.

Çizelge 4.2. Gompertz modele ait parametre değerleri ve parametrelere ait standart hata değerleri

Model	A	$S_{\bar{x}a}$	β	$S_{\bar{x}b}$	k	$S_{\bar{x}k}$
Gompertz	3999	585.7	4.6	0.39	0.05	0.008

A: Asimtotik ağırlık, **β :** İntegrasyon sabiti **k:** Büyüme oranı, $S_{\bar{x}a}$: A parametresine ait standart hata, $S_{\bar{x}b}$: β parametresine ait standart hata, $S_{\bar{x}k}$: k parametresine ait standart hata

Modele ait tahmin edilen parametre deęerleri izelge 4.2’de grlmektedir. Narin ve ark., (2007)’nin, standart hızda ve orta hızda gelişen etlik pililerden cinsiyete gre 63. gne kadar A , β , k parametre deęerlerini sırasıyla standart hızda gelişenlerde 6359, 4.95, 0.037; orta hızda gelişenlerde 4879, 4.58, 0.031; diřilerde 4850, 4.55, 0.034; erkeklerde 6389, 4.98 ve 0.034 olarak Gompertz modeli ile tahmin etmişlerdir. Eleroęlu ve ark., (2016)’nin etlik pililerde yapmış oldukları alıřmada Gompertz modelinden tahmin ettikleri A , β , k parametre deęerlerini sırasıyla 4364.53, 4.62 ve 0.356 olarak bulmuşlardır. Mohammed (2015)’in yaptığı alıřmada ise etlik pililerden Gompertz modeli ile tahmin ettiği parametre deęerleri sırasıyla 2973, 4.76 ve 0.05 olarak bildirmiřtir. řekeroęlu ve ark., (2013)’nin yaptıkları alıřmada etlik pililerde  yerleşim sıklığından tahmin ettikleri A parametre deęerleri sırasıyla 4198.46, 3807.45, 3999.92; β parametre deęerleri 4.83, 4.78, 4.56 ve k parametresi iin tahmin ettikleri deęerler sırasıyla 0.055, 0.058, 0.052 olarak bildirilmişlerdir. izelge 4.2’de modelden tahmin edilen A , β , k parametre deęerleri ise sırasıyla 3999, 4.6 ve 0.05 olarak bulunmuřtur.

A parametresi iin tahmin edilen deęer Narin ve ark., (2007) ile Eleroęlu ve ark., (2016)’nin elde ettiği A parametresi tahminlenen parametre deęerinden yksek bulunmuřtur. Mohammed (2015)’in elde ettiği A parametre deęeri ise tahminlenen parametre deęerinden dřk bulunmuřtur. řekeroęlu ve ark., (2013)’nin tahmin ettikleri nc yerleşim sıklığındaki pililerden tahmin ettikleri parametre deęeri alıřmadan tahmin edilen deęer ile rtřmektedir.

Model ile tahmin edilen β parametresi deęerinin řekeroęlu ve ark., (2013), Eleroęlu ve ark., (2016) ve Mohammed (2015)’in elde ettiği β parametre deęerleri ile benzer olduęu, Narin ve ark., (2007)’nin elde ettikleri deęerin ise yksek olduęu; k parametresinin ise Mohammed (2015) ve řekeroęlu ve ark., (2013)’nin tahmin ettikleri k parametre deęerleri ile rtřtę, Narin ve ark., (2007)’nin elde ettikleri deęerlerden yksek, Eleroęlu ve ark., (2016)’nin elde ettiği deęerden ise dřk olduęu tespit edilmiştir.

Tahmin edilen deęerlerin birbirinden farklı olmasının sebebinin; CA deęerlerinin farklı sürelerde alınmış olmasından ve farklı bakım ve besleme koşullarından kaynaklandığı düşünölmektedir. Çünkü zamanla birlikte CA artışı devam etmektedir. Büyüme eğrisi modellerinde tahmin edilen bu parametreler büyüme eğrilerinin açıklanmasında önemli yere sahiptir.

Çizelge 4.3. Gompertz modele ait tahmin ölçütleri

Model	HKO	OMS	OMYH (%)	R ²
Gompertz	2950	1.2	0.17	0.99

HKO: Hata kareler ortalaması, **OMS:** Ortalama mutlak sapma, **OMYH:** Ortalama mutlak yüzde hata, **R²:** Belirleme katsayısı

Gompertz modeline ait bu tahmin ölçütleri Çizelge 4.3'te verilmiştir. Çizelge 4.3 incelendiğinde HKO, OMYH, OMS ve R² deęerlerinin sırasıyla 2950, 1.2, 0.2 ve 0.99 olarak tespit edilmiştir. Eleroęlu ve ark., (2016)'nın yaptıkları çalışmada HKO deęeri 729.53 olarak, Mohammed, (2015)'in yaptığı çalışmada HKO deęerini 1068.6 olarak bildirmiştir. Bu çalışmada elde edilen HKO deęeri ise bildirilen deęerlerden yüksek bulunmuştur. Şekeroęlu ve ark., (2013)'nin tahmin ettikleri modelin HKO üç yerleşim sıklığında sırasıyla 2110, 2846, 2950 olarak bildirilmiştir. Bu çalışmanın HKO deęeri bildirilen birinci yerleşim sıklığından yüksek dięer yerleşim sıklıkları ile benzer deęer almaktadır.

Şekeroęlu ve ark., (2013), Adenaike ve ark., (2017), Roush ve ark., (2006), Mohammed (2015), Eleroęlu ve ark., (2016) ve Topal ve ark., (2008)'nin bildirdikleri R² deęerleri (0.99) bu çalışmadan tahmin edilen modelden elde edilen R² deęeri ile örtüşmektedir. Yüksek R² deęeri ise tahminin çok iyi olduğunu göstermektedir.

OMYH deęerini Roush ve ark., (2006) 2.30-2.47; Topal ve ark., (2008) erkeklerde 0.04, dişilerde 0.05 olarak tahmin etmişlerdir. Roush ve ark., (2006)'nın tahmin ettiği deęerler bu çalışmadan yüksek, Topal ve ark., (2008)'nin tahmin ettikleri deęerler ise bu çalışmadan düşük gözlenmiştir.

Roush ve ark., (2006)'nın etlik piliçlerde yapmış oldukları çalışmada bildirdikleri OMS değerleri 15.42-19.59'dur. Tahminlenen modelden hesaplanan değer Roush ve ark., (2006)'nın hesapladıkları değerden daha düşük tespit edilmiştir.

4.2. YSA'na Ait Bulgular

Yapılan çalışmada YSA ile model belirlemede veri setinin 0-5 haftalık yaştaki CA verileri giriş seti olarak kullanılmıştır. Bu giriş setine karşılık YSA'nın öğrenmesini sağlamak için çıkış seti olarak 6. haftaya ait CA verileri kullanılmıştır. Kullanılan programın sınırları dahilinde ağın özellikleri belirlenmiştir. Ağ türü olarak ileri yayılım geri besleme (Feed-forward backprop) danışmanlı öğrenme algoritması seçilmiştir. Bu algoritmanın tercih sebebi; ağın eğitimi sırasında ilk olarak ileriye doğru bağlantı kurulduğu sırada ağın ağırlıklarını kullanarak ağa verilen girdi değerlerine karşılık gelecek çıktılar elde etmesi, geri yayılım algoritması ile de çıktı katmanında meydana gelen hatanın en aza indirilmesi için ağırlıkların geriye doğru düzenlenmesi sağlanmaktadır. Ayrıca ağın eğitim fonksiyonu olarak öğrenme hızını belirgin şekilde arttıran Levenberg-Marquardt algoritması tercih edilmiştir. Performans fonksiyonu olarak HKO kullanılmış ve bu en düşük hata düzeyine ulaşılmaya çalışılmıştır. Kaastra ve ark., (1996)'a göre; genellikle YSA problemlerinin çözümünde bir ara katmanlı ağlar başarılı bulunmuştur (Aksu ve ark., 2016). Ara katman sayısının fazla tercih edilmesi hesaplamadaki karmaşıklığı arttırdığı ve süreyi uzattığı için ağ da kullanılan ara katman sayısı bir olarak alınmıştır. Ara katmanda bulunan nöron sayısı ise deneme-yanılma yöntemi ile belirlenmiştir (Çizelge 4.4) (Takma, 2012; Yılmaz, 2015). Ağın eğitimi sırasında örnekleme sayısını belirlemede kullanılan yüzde (%) değerleri ise yine programın sınırları dahilinde sırasıyla % 5-10-15-20-25-30-35 olarak alınmıştır. Eğitim, doğrulama ve test seti yüzdeleri olarak yine program sınırları dahilinde alınabilecek tüm yüzde değerleri sırasıyla %50-60-70-80-90 olarak en doğru ağ modelini belirlemek için denenmiştir. Daha sonra ise ağın eğitimi yapılmıştır. Ağ verilen girdilere karşılık istenen çıktılarını belirlemek için ağırlıklarını güncellemiş ve böylece ağın çıktıları ile gözlenen çıktılar arasındaki hata ağ tarafından hesaplanmış ve ağ yeni ağırlıklarını bu hata payına göre düzenlemiştir.

Çizelge 4.4. YSA uygulama veri seti dağılımı

Uygulama	Ara katmandaki nöron sayısı	Veri seti	(%) Yüzde	(%) Yüzde değerlere karşılık gelen örnekleme sayısı
1	8-9-10-11-12	Eğitim Seti	50	61
		Doğrulama Seti	15	18
		Test Seti	35	42
2	8-9-10-11-12	Eğitim Seti	50	61
		Doğrulama Seti	20	24
		Test Seti	30	36
3	8-9-10-11-12	Eğitim Seti	50	61
		Doğrulama Seti	25	30
		Test Seti	25	30
4	8-9-10-11-12	Eğitim Seti	50	61
		Doğrulama Seti	30	36
		Test Seti	20	24
5	8-9-10-11-12	Eğitim Seti	50	61
		Doğrulama Seti	35	42
		Test Seti	15	18
6	8-9-10-11-12	Eğitim Seti	60	73
		Doğrulama Seti	5	6
		Test Seti	35	42
7	8-9-10-11-12	Eğitim Seti	60	73
		Doğrulama Seti	10	12
		Test Seti	30	36
8	8-9-10-11-12	Eğitim Seti	60	73
		Doğrulama Seti	15	18
		Test Seti	25	30
9	8-9-10-11-12	Eğitim Seti	60	73
		Doğrulama Seti	20	24
		Test Seti	20	24

Çizelge 4.4. (Devam) YSA uygulama veri seti dağılımı

10	8-9-10- 11-12	Eğitim Seti	60	73
		Doğrulama Seti	25	30
		Test Seti	15	18
11	8-9-10- 11-12	Eğitim Seti	60	73
		Doğrulama Seti	30	36
		Test Seti	10	12
12	8-9-10- 11-12	Eğitim Seti	60	73
		Doğrulama Seti	35	42
		Test Seti	5	6
13	8-9-10- 11-12	Eğitim Seti	70	85
		Doğrulama Seti	5	6
		Test Seti	25	30
14	8-9-10- 11-12	Eğitim Seti	70	85
		Doğrulama Seti	10	12
		Test Seti	20	24
15	8-9-10- 11-12	Eğitim Seti	70	85
		Doğrulama Seti	15	18
		Test Seti	15	18
16	8-9-10- 11-12	Eğitim Seti	70	85
		Doğrulama Seti	20	24
		Test Seti	10	12
17	8-9-10- 11-12	Eğitim Seti	70	85
		Doğrulama Seti	25	30
		Test Seti	5	6
18	8-9-10- 11-12	Eğitim Seti	80	97
		Doğrulama Seti	5	6
		Test Seti	15	18
19	8-9-10- 11-12	Eğitim Seti	80	97
		Doğrulama Seti	10	12
		Test Seti	10	12
20	8-9-10- 11-12	Eğitim Seti	80	97
		Doğrulama Seti	15	18
		Test Seti	5	6
21	8-9-10- 11-12	Eğitim Seti	90	109
		Doğrulama Seti	5	6
		Test Seti	5	6

Hesaplama aşamasında 121x6 girdi matrisi ve 121x1 çıktı matrisi olacak şekilde veriler MATLAB programına yüklenmiştir (Ek 1., Resim 6.). Uygulamada programın sınırları dahilinde 21 farklı şekilde yüzdelik dağılım kullanılmıştır (Ek 1., Resim 5.). Çizelge 4.4'te bu yüzdelik dağılımlar ve yüzdelere karşılık gelen örnekleme sayıları verilmiştir.

Ara katmandaki nöron sayısı ise programın otomatik olarak atadığı nöron sayısının (10), 2 alt (9-8) ve 2 üstü (11-12) olarak 5 farklı şekilde belirlenmiştir. En doğru sonuca ulaşabilmek için 21 uygulamada 5 farklı nöron olmak üzere (21x5) toplam 105 adet ağ modeli denenmiştir.

Yapılan analiz sonucunda eğitim, test ve doğrulama seti olmak üzere tüm setlerde en yüksek R^2 değerini veren model en iyi model olarak seçilmiştir (Şahin ve ark., 2014). Ayrıca eğitim, doğrulama ve test setlerindeki HKO ve R^2 değerleri incelenerek ağın eğitimini öğrenerek mi ezberleyerek mi tamamladığına bakılmıştır. Şayet analiz sonucunda ağ eğitim setinde düşük HKO değeri test setinde yüksek HKO değeri vermiş ise; R^2 değeri de eğitim setinde yüksek test setinde düşük değer vermiş ise bu ağ modeli eğitimini gerçekleştirilmemiş ezberleme yapmıştır (Aka ve ark., 2018).

Çizelge 4.5'te YSA analizi ile belirlenen modellere ait ara katmanlardaki nöron sayıları, yüzde değerleri, HKO ve R^2 değerleri verilmiştir. Çizelge 4.5 incelendiğinde en iyi sonuç veren modelin 20. uygulamada 12 nöronlu %80 eğitim %15 doğrulama ve %5 test setinin olduğu görülmektedir. 20. uygulama setinde eğitim, doğrulama ve test setlerinin yüzde değerlerine karşılık gelen örnekleme sayıları sırasıyla 97, 18, 6'dır (Çizelge 4.4). Seçilen bu modelde elde edilen R^2 değerleri eğitim, doğrulama ve test setleri için sırasıyla 0.94, 0.94, 0.98 olarak, HKO değerleri ise; %80 eğitim seti için 7005, %15 doğrulama seti için 11475 ve %5 test seti için ise 5625 olarak tespit edilmiştir. Seçilen modelin test setindeki HKO değerinin eğitim setindeki HKO değerinden düşük, R^2 değerinin ise yüksek olduğu tespit edilmiştir (Çizelge 4.5). Buradan anlaşılmaktadır ki seçilen model ezberleme yapmamış ve eğitimini başarıyla tamamlamıştır.

Çizelge 4.5. YSA analizi ile belirlenen modele ait HKO ve R² değerleri

Uygulama	Ara katmandaki nöron sayısı	Veri seti	(%) Yüzde	HKO	R ²
1. Uygulama	8	Eğitim Seti	50	53 420	0.66
		Doğrulama Seti	15	29 410	0.85
		Test Seti	35	92 619	0.62
	9	Eğitim Seti	50	11 801	0.94
		Doğrulama Seti	15	13 876	0.83
		Test Seti	35	33 343	0.69
	10	Eğitim Seti	50	35 759	0.61
		Doğrulama Seti	15	19 228	0.79
		Test Seti	35	102 023	0.71
	11	Eğitim Seti	50	4 001	0.96
		Doğrulama Seti	15	19 716	0.94
		Test Seti	35	109 296	0.61
12	Eğitim Seti	50	34 448	0.90	
	Doğrulama Seti	15	26 836	0.88	
	Test Seti	35	48 636	0.77	
2. Uygulama	8	Eğitim Seti	50	4 722	0.96
		Doğrulama Seti	20	44 572	0.81
		Test Seti	30	16 525	0.83
	9	Eğitim Seti	50	7 621	0.94
		Doğrulama Seti	20	24 617	0.85
		Test Seti	30	33 375	0.76
	10	Eğitim Seti	50	12 612	0.88
		Doğrulama Seti	20	42 711	0.79
		Test Seti	30	95 786	0.55
	11	Eğitim Seti	50	7 974	0.96
		Doğrulama Seti	20	9 306	0.92
		Test Seti	30	38 189	0.79
12	Eğitim Seti	50	19 161	0.92	
	Doğrulama Seti	20	20 076	0.88	
	Test Seti	30	21 568	0.77	
3. Uygulama	8	Eğitim Seti	50	11 658	0.92
		Doğrulama Seti	25	46 923	0.66
		Test Seti	25	33 478	0.71
	9	Eğitim Seti	50	7 856	0.92
		Doğrulama Seti	25	43 963	0.85
		Test Seti	25	40 266	0.67
	10	Eğitim Seti	50	5 056	0.96
		Doğrulama Seti	25	19 716	0.81
		Test Seti	25	78 338	0.71
	11	Eğitim Seti	50	3 820	0.98
		Doğrulama Seti	25	22 133	0.69
		Test Seti	25	58 103	0.76
12	Eğitim Seti	50	14 399	0.90	
	Doğrulama Seti	25	41 810	0.69	
	Test Seti	25	23 727	0.88	

Çizelge 4 5 (Devam) YSA analizi ile belirlenen modele ait HKO ve R² değerleri

4 Uygulama	8	Eğitim Seti	50	15 038	0.88
		Doğrulama Seti	30	15 449	0.92
		Test Seti	20	15 487	0.92
	9	Eğitim Seti	50	5 204	0.96
		Doğrulama Seti	30	30 637	0.81
		Test Seti	20	20 817	0.83
	10	Eğitim Seti	50	25 027	0.88
		Doğrulama Seti	30	134 056	0.30
		Test Seti	20	107 962	0.18
	11	Eğitim Seti	50	17 831	0.90
		Doğrulama Seti	30	173 320	0.85
		Test Seti	20	23 998	0.92
12	Eğitim Seti	50	2 604	0.98	
	Doğrulama Seti	30	26 111	0.74	
	Test Seti	20	54 848	0.79	
5 Uygulama	8	Eğitim Seti	50	40 343	0.79
		Doğrulama Seti	35	42 568	0.88
		Test Seti	15	26 429	0.85
	9	Eğitim Seti	50	18 703	0.88
		Doğrulama Seti	35	186 563	0.66
		Test Seti	15	34 721	0.76
	10	Eğitim Seti	50	16 333	0.90
		Doğrulama Seti	35	34 053	0.67
		Test Seti	15	9 354	0.98
	11	Eğitim Seti	50	9 260	0.96
		Doğrulama Seti	35	43 649	0.71
		Test Seti	15	12 691	0.86
12	Eğitim Seti	50	113 603	0.64	
	Doğrulama Seti	35	128 723	0.83	
	Test Seti	15	210 244	0.85	
6 Uygulama	8	Eğitim Seti	60	2 907	0.98
		Doğrulama Seti	5	6 111	0.98
		Test Seti	35	35 822	0.74
	9	Eğitim Seti	60	47 407	0.77
		Doğrulama Seti	5	57 368	0.90
		Test Seti	35	58 870	0.46
	10	Eğitim Seti	60	2 642	0.98
		Doğrulama Seti	5	11 667	0.98
		Test Seti	35	58 887	0.59
	11	Eğitim Seti	60	9 892	0.94
		Doğrulama Seti	5	37 103	0.92
		Test Seti	35	16 347	0.88
12	Eğitim Seti	60	20 766	0.83	
	Doğrulama Seti	5	55 970	0.32	
	Test Seti	35	545 984	0.71	

Çizelge 4 5 (Devam) YSA analizi ile belirlenen modele ait HKO ve R² değerleri

7 Uygulama	8	Eğitim Seti	60	11 207	0.88
		Doğrulama Seti	10	2 740	0.98
		Test Seti	30	65 939	0.69
	9	Eğitim Seti	60	12 773	0.92
		Doğrulama Seti	10	57 462	0.77
		Test Seti	30	59 659	0.53
	10	Eğitim Seti	60	2 866	0.98
		Doğrulama Seti	10	9 950	0.96
		Test Seti	30	39 939	0.81
	11	Eğitim Seti	60	10 040	0.90
		Doğrulama Seti	10	83 385	0.81
		Test Seti	30	15 990	0.88
12	Eğitim Seti	60	36 501	0.81	
	Doğrulama Seti	10	39 910	0.49	
	Test Seti	30	237 717	0.08	
8 Uygulama	8	Eğitim Seti	60	1 989	0.98
		Doğrulama Seti	15	64 803	0.67
		Test Seti	25	105 663	0.58
	9	Eğitim Seti	60	3 022	0.98
		Doğrulama Seti	15	25 948	0.90
		Test Seti	25	41 039	0.79
	10	Eğitim Seti	60	5 549	0.96
		Doğrulama Seti	15	5 496	0.96
		Test Seti	25	50 522	0.72
	11	Eğitim Seti	60	11 759	0.92
		Doğrulama Seti	15	25 080	0.90
		Test Seti	25	36 313	0.69
	12	Eğitim Seti	60	13 076	0.92
		Doğrulama Seti	15	13 494	0.90
		Test Seti	25	27 543	0.77
9 Uygulama	8	Eğitim Seti	60	12 191	0.92
		Doğrulama Seti	20	17 088	0.86
		Test Seti	20	36 191	0.76
	9	Eğitim Seti	60	13 944	0.94
		Doğrulama Seti	20	16 002	0.86
		Test Seti	20	24 319	0.74
	10	Eğitim Seti	60	3 173	0.98
		Doğrulama Seti	20	27 900	0.69
		Test Seti	20	50 692	0.81
	11	Eğitim Seti	60	4 579	0.96
		Doğrulama Seti	20	66 729	0.69
		Test Seti	20	33 375	0.66
12	Eğitim Seti	60	25 257	0.85	
	Doğrulama Seti	20	18 814	0.85	
	Test Seti	20	12 716	0.86	

Çizelge 4 5 (Devam) YSA analizi ile belirlenen modele ait HKO ve R² değerleri

10 Uygulama	8	Eğitim Seti	60	12 943	0.92
		Doğrulama Seti	25	21 440	0.81
		Test Seti	15	13 403	0.86
	9	Eğitim Seti	60	6 351	0.96
		Doğrulama Seti	25	36 914	0.61
		Test Seti	15	4 073	0.72
	10	Eğitim Seti	60	9 388	0.94
		Doğrulama Seti	25	17 629	0.77
		Test Seti	15	19 365	0.96
	11	Eğitim Seti	60	37 047	0.74
		Doğrulama Seti	25	56 948	0.71
		Test Seti	15	95 233	0.42
12	Eğitim Seti	60	19 845	0.90	
	Doğrulama Seti	25	40 441	0.81	
	Test Seti	15	71 206	0.62	
11 Uygulama	8	Eğitim Seti	60	13 275	0.88
		Doğrulama Seti	30	23 595	0.92
		Test Seti	10	27 815	0.88
	9	Eğitim Seti	60	13 465	0.92
		Doğrulama Seti	30	17 113	0.86
		Test Seti	10	13 390	0.85
	10	Eğitim Seti	60	3 497	0.96
		Doğrulama Seti	30	33 616	0.86
		Test Seti	10	171 102	0.86
	11	Eğitim Seti	60	9 393	0.92
		Doğrulama Seti	30	17 259	0.88
		Test Seti	10	45 297	0.85
12	Eğitim Seti	60	13 758	0.90	
	Doğrulama Seti	30	22 419	0.83	
	Test Seti	10	84 345	0.69	
12 Uygulama	8	Eğitim Seti	60	21 947	0.88
		Doğrulama Seti	35	27 703	0.66
		Test Seti	5	80 418	0.77
	9	Eğitim Seti	60	10 452	0.94
		Doğrulama Seti	35	16 782	0.74
		Test Seti	5	18 561	0.77
	10	Eğitim Seti	60	16 115	0.90
		Doğrulama Seti	35	207 303	0.13
		Test Seti	5	24 623	0.07
	11	Eğitim Seti	60	23 995	0.88
		Doğrulama Seti	35	51 865	0.69
		Test Seti	5	48 711	0.77
12	Eğitim Seti	60	3 517	0.98	
	Doğrulama Seti	35	28 523	0.86	
	Test Seti	5	176 942	0.40	

Çizelge 4 5 (Devam) YSA analizi ile belirlenen modele ait HKO ve R² değerleri

13 Uygulama	8	Eğitim Seti	70	7 132	0.94
		Doğrulama Seti	5	10 835	0.88
		Test Seti	25	45 278	0.81
	9	Eğitim Seti	70	9 347	0.96
		Doğrulama Seti	5	15 028	0.79
		Test Seti	25	226 170	0.27
	10	Eğitim Seti	70	5 477	0.96
		Doğrulama Seti	5	12 637	0.96
		Test Seti	25	37 818	0.77
	11	Eğitim Seti	70	34 528	0.85
		Doğrulama Seti	5	79 543	0.32
		Test Seti	25	218 238	0.34
12	Eğitim Seti	70	6 118	0.96	
	Doğrulama Seti	5	35 319	0.88	
	Test Seti	25	59 735	0.76	
14 Uygulama	8	Eğitim Seti	70	10 440	0.92
		Doğrulama Seti	10	60 294	0.76
		Test Seti	20	18 866	0.86
	9	Eğitim Seti	70	10 189	0.92
		Doğrulama Seti	10	8 843	0.92
		Test Seti	20	16 158	0.92
	10	Eğitim Seti	70	15 633	0.90
		Doğrulama Seti	10	20 168	0.88
		Test Seti	20	16 565	0.90
	11	Eğitim Seti	70	38 967	0.74
		Doğrulama Seti	10	35 695	0.49
		Test Seti	20	75 143	0.62
	12	Eğitim Seti	70	9 943	0.94
		Doğrulama Seti	10	11 358	0.83
		Test Seti	20	36 179	0.69
15 Uygulama	8	Eğitim Seti	70	12 481	0.88
		Doğrulama Seti	15	19 472	0.96
		Test Seti	15	9 956	0.90
	9	Eğitim Seti	70	12 275	0.92
		Doğrulama Seti	15	16 961	0.86
		Test Seti	15	11 190	0.88
	10	Eğitim Seti	70	27 183	0.83
		Doğrulama Seti	15	44 769	0.81
		Test Seti	15	52 224	0.74
	11	Eğitim Seti	70	11 364	0.90
		Doğrulama Seti	15	16 974	0.86
		Test Seti	15	14 503	0.94
	12	Eğitim Seti	70	13 649	0.92
		Doğrulama Seti	15	12 901	0.83
		Test Seti	15	19 139	0.90

Çizelge 4 5 (Devam) YSA analizi ile belirlenen modele ait HKO ve R² değerleri

16 Uygulama	8	Eğitim Seti	70	12 608	0.92
		Doğrulama Seti	20	17 981	0.88
		Test Seti	10	18 111	0.88
	9	Eğitim Seti	70	18 256	0.90
		Doğrulama Seti	20	25 923	0.71
		Test Seti	10	52 120	0.83
	10	Eğitim Seti	70	12 656	0.90
		Doğrulama Seti	20	27 416	0.92
		Test Seti	10	18 078	0.86
	11	Eğitim Seti	70	13 652	0.90
		Doğrulama Seti	20	36 584	0.85
		Test Seti	10	21 179	0.96
12	Eğitim Seti	70	10 456	0.92	
	Doğrulama Seti	20	68 707	0.62	
	Test Seti	10	14 838	0.81	
17 Uygulama	8	Eğitim Seti	70	6 039	0.94
		Doğrulama Seti	25	59 840	0.76
		Test Seti	5	9 617	0.76
	9	Eğitim Seti	70	293 653	0.02
		Doğrulama Seti	25	201 194	0.13
		Test Seti	5	223 458	0.23
	10	Eğitim Seti	70	7 191	0.96
		Doğrulama Seti	25	38 048	0.71
		Test Seti	5	6 071	0.94
	11	Eğitim Seti	70	14 648	0.88
		Doğrulama Seti	25	18 463	0.92
		Test Seti	5	11 958	0.76
	12	Eğitim Seti	70	4 423	0.96
		Doğrulama Seti	25	35 423	0.83
		Test Seti	5	65 173	0.55
18 Uygulama	8	Eğitim Seti	80	17 842	0.88
		Doğrulama Seti	5	9 283	0.94
		Test Seti	15	30 542	0.88
	9	Eğitim Seti	80	12 536	0.92
		Doğrulama Seti	5	1 107	0.98
		Test Seti	15	18 347	0.67
	10	Eğitim Seti	80	18 892	0.88
		Doğrulama Seti	5	3 245	0.96
		Test Seti	15	17 142	0.92
	11	Eğitim Seti	80	53 726	0.61
		Doğrulama Seti	5	28 304	0.94
		Test Seti	15	34 616	0.61
	12	Eğitim Seti	80	66 796	0.88
		Doğrulama Seti	5	44 115	0.96
		Test Seti	15	41 221	0.92

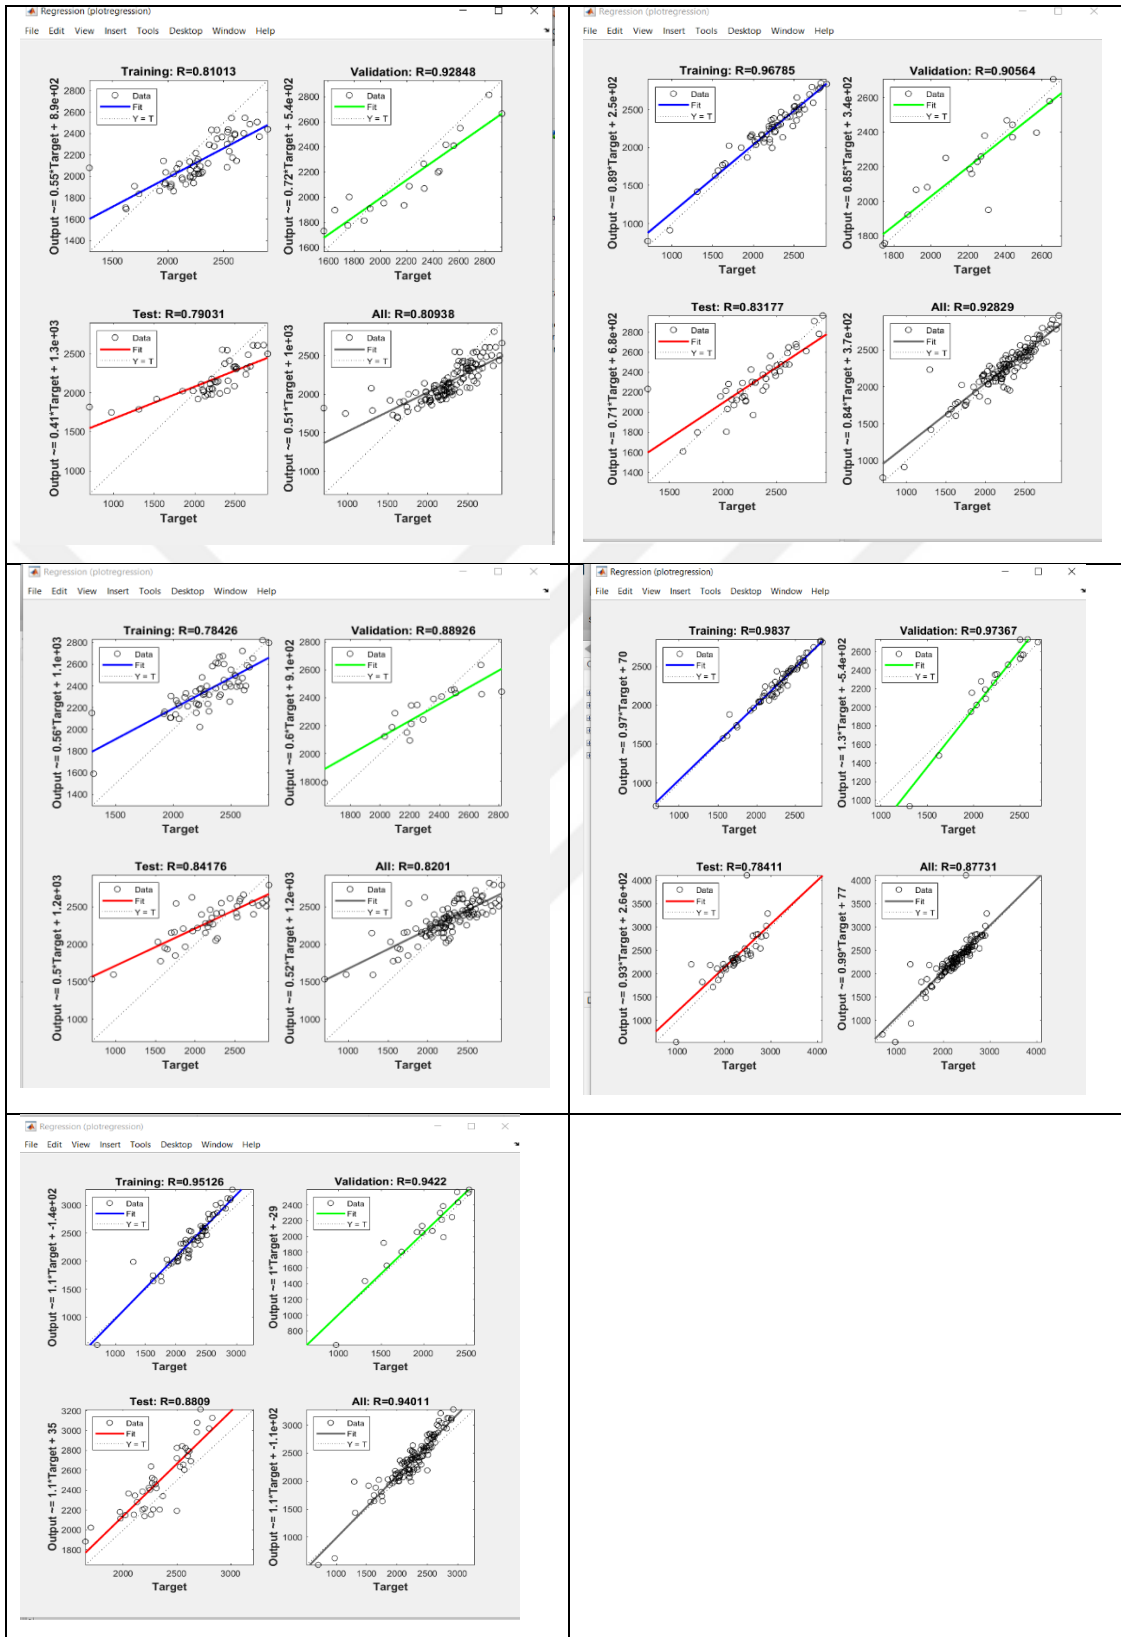
Çizelge 4 5 (Devam) YSA analizi ile belirlenen modele ait HKO ve R² değerleri

19 Uygulama	8	Eğitim Seti	80	18 894	0.90
		Doğrulama Seti	10	38 120	0.64
		Test Seti	10	11 532	0.92
	9	Eğitim Seti	80	10 144	0.92
		Doğrulama Seti	10	14 471	0.96
		Test Seti	10	17 846	0.86
	10	Eğitim Seti	80	10 841	0.92
		Doğrulama Seti	10	29 067	0.76
		Test Seti	10	16 075	0.88
	11	Eğitim Seti	80	11 370	0.92
		Doğrulama Seti	10	6 421	0.94
		Test Seti	10	47 482	0.86
12	Eğitim Seti	80	8 524	0.94	
	Doğrulama Seti	10	14 355	0.96	
	Test Seti	10	13 652	0.76	
20 Uygulama	8	Eğitim Seti	80	17 559	0.90
		Doğrulama Seti	15	6 337	0.94
		Test Seti	5	68 805	0.90
	9	Eğitim Seti	80	59 663	0.72
		Doğrulama Seti	15	13 328	0.94
		Test Seti	5	58 480	0.72
	10	Eğitim Seti	80	14 505	0.90
		Doğrulama Seti	15	20 979	0.88
		Test Seti	5	17 839	0.72
	11	Eğitim Seti	80	14 414	0.88
		Doğrulama Seti	15	34 529	0.59
		Test Seti	5	35 629	0.98
12	Eğitim Seti	80	7 005	0.94	
	Doğrulama Seti	15	11 457	0.94	
	Test Seti	5	5 625	0.98	
21 Uygulama	8	Eğitim Seti	90	15 646	0.88
		Doğrulama Seti	5	15 151	0.96
		Test Seti	5	17 098	0.86
	9	Eğitim Seti	90	11 157	0.92
		Doğrulama Seti	5	2 826	0.98
		Test Seti	5	45 944	0.81
	10	Eğitim Seti	90	15 759	0.88
		Doğrulama Seti	5	12 214	0.83
		Test Seti	5	40 699	0.92
	11	Eğitim Seti	90	32 278	0.81
		Doğrulama Seti	5	48 863	0.40
		Test Seti	5	19 740	0.98
12	Eğitim Seti	90	11 331	0.92	
	Doğrulama Seti	5	6 827	0.98	
	Test Seti	5	21 112	0.86	

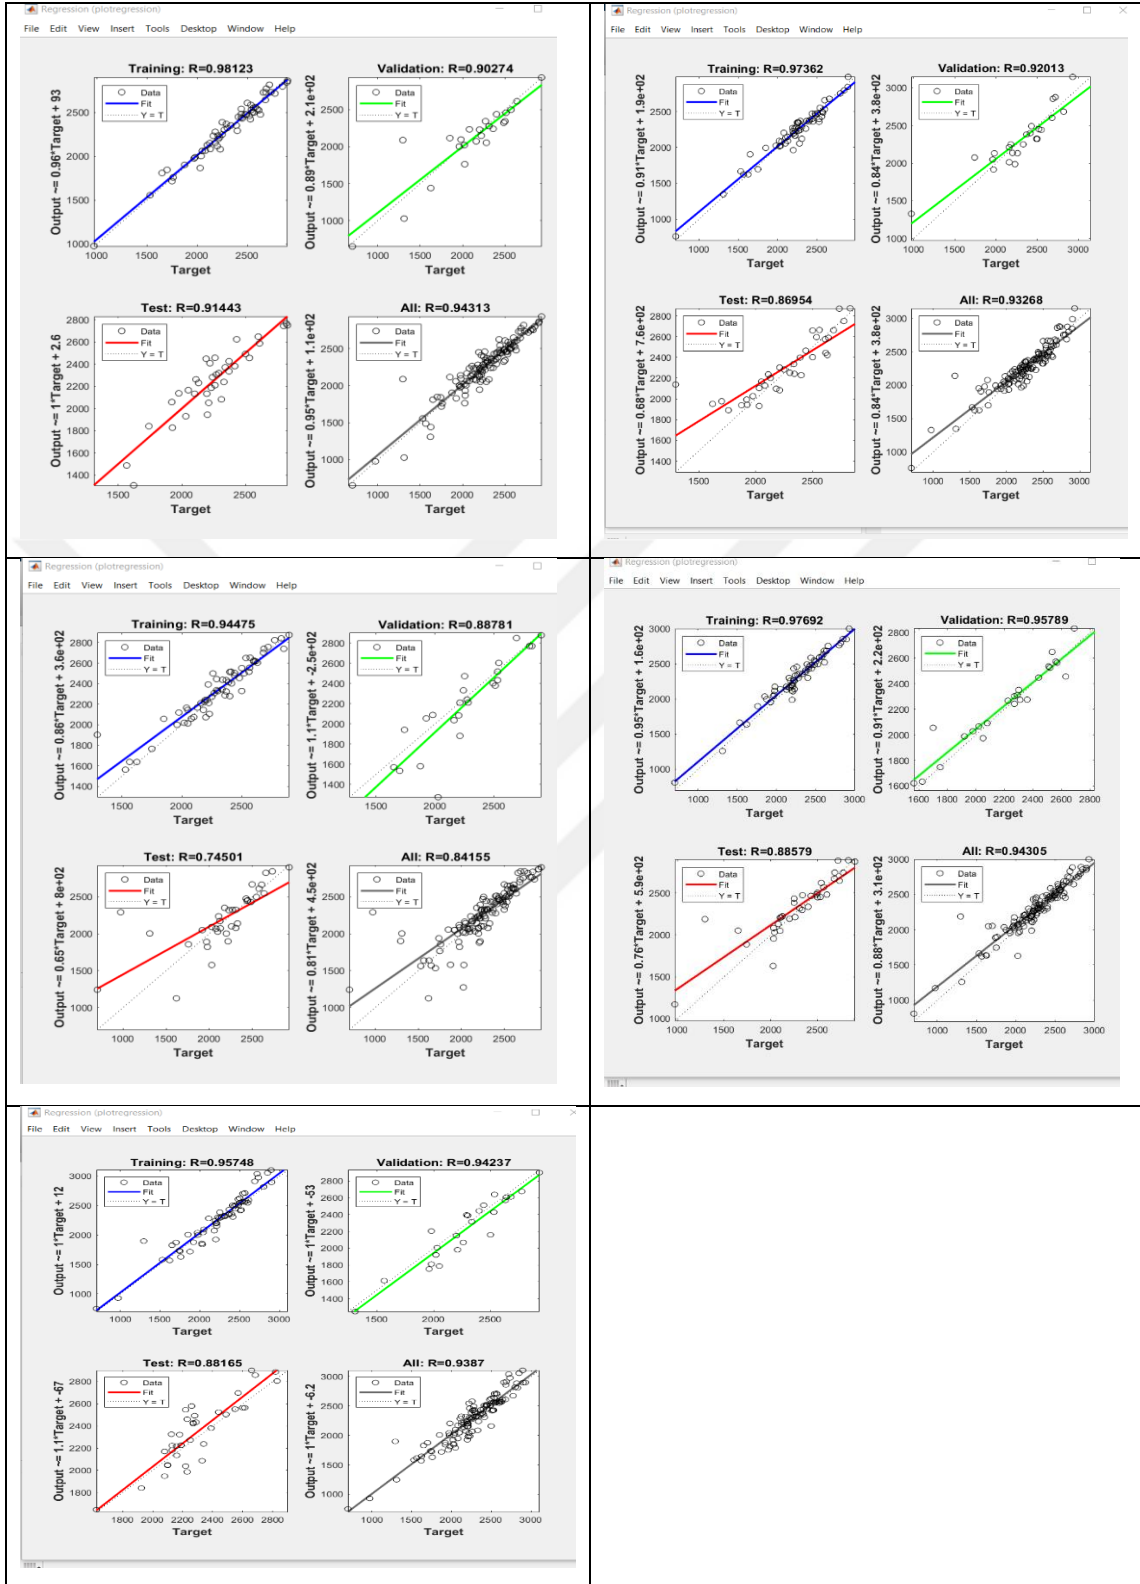
Şekil 4.2, Şekil 4.3, Şekil 4.4, Şekil 4.5, Şekil 4.6, Şekil 4.7, Şekil 4.8, Şekil 4.9, Şekil 4.10, Şekil 4.11, Şekil 4.12, Şekil 4.13, Şekil 4.14, Şekil 4.15, Şekil 4.16, Şekil 4.17, Şekil 4.18, Şekil 4.19, Şekil 4.20, Şekil 4.21 ve Şekil 4.22’de YSA ile gerçekleştirilen 21 uygulamaya ait saçılım grafikleri verilmiştir. Sayısal değişkenler arasındaki ilişki incelenirken saçılım grafiklerinden yararlanılmaktadır. Saçılım grafikleri ile iki değişkenin birlikte dağılımı incelenmektedir. Saçılım grafiklerinin yaygınlığına bakılarak değişkenler arasında zayıf, kuvvetli ve tam ilişki olup olmadığına karar verilebilmektedir (Alpar, 2013). Ağın çıktı ve hedef değerlerinin örtüşmesinin gösterildiği grafikte en iyi sonuç 45 derecelik eğri üzerindeki yığılmanın en fazla olması ile mümkündür (Kubat, 2015).

YSA modeli belirlenirken yapılan denemeler sonucunda elde edilen Şekil 4.21’deki saçılım grafikleri incelendiğinde 20. uygulama 12 katmanlı ağa ait grafiklerde eğitim ve doğrulama setlerinde çizilen regresyon doğrusu 45° ’lik doğru ile örtüşmekte test seti ise ona çok yakın değer almaktadır. Diğer uygulamalarda bu denli yakın örtüşme bulunmamaktadır. Ayrıca yine bu ağa ait R^2 değerleri eğitim ve doğrulama setlerinde 0.94, test setinde ise 0.98 olduğu görülmektedir. Bu R^2 değerleri diğer modeller içinde en yüksek R^2 değerleridir. Dolayısıyla modeller arasından en iyi modelin bu model olduğuna karar verilmiştir. Test seti için 0.98 R^2 değeri belirlenen modelin çok iyi bir model olduğunu da göstermektedir. Saçılım grafikleri ve R^2 değerlerine ek olarak diğer ağ modellerinin tercih edilmeme sebebi ise ağların ezberleme yapmasıdır. Örneğin 7. uygulamada 12 nöronlu ağa (en düşük R^2 değerleri bu modele ait olduğu için bu ağ örnek verilmiştir) ait 0.81 eğitim, 0.49 doğrulama ve 0.08 test setlerinde elde edilen R^2 değerleri kendi içinde incelendiğinde test setinde eğitim setine göre düştüğü böylece ağın modeli öğrenmediğini ezberleme yaptığını göstermektedir. Bu uygulamaya ait Şekil 4.8’deki saçılım grafikleri incelendiğinde saçılımın dağınık olduğu ve sapmaların olduğu görülmektedir.

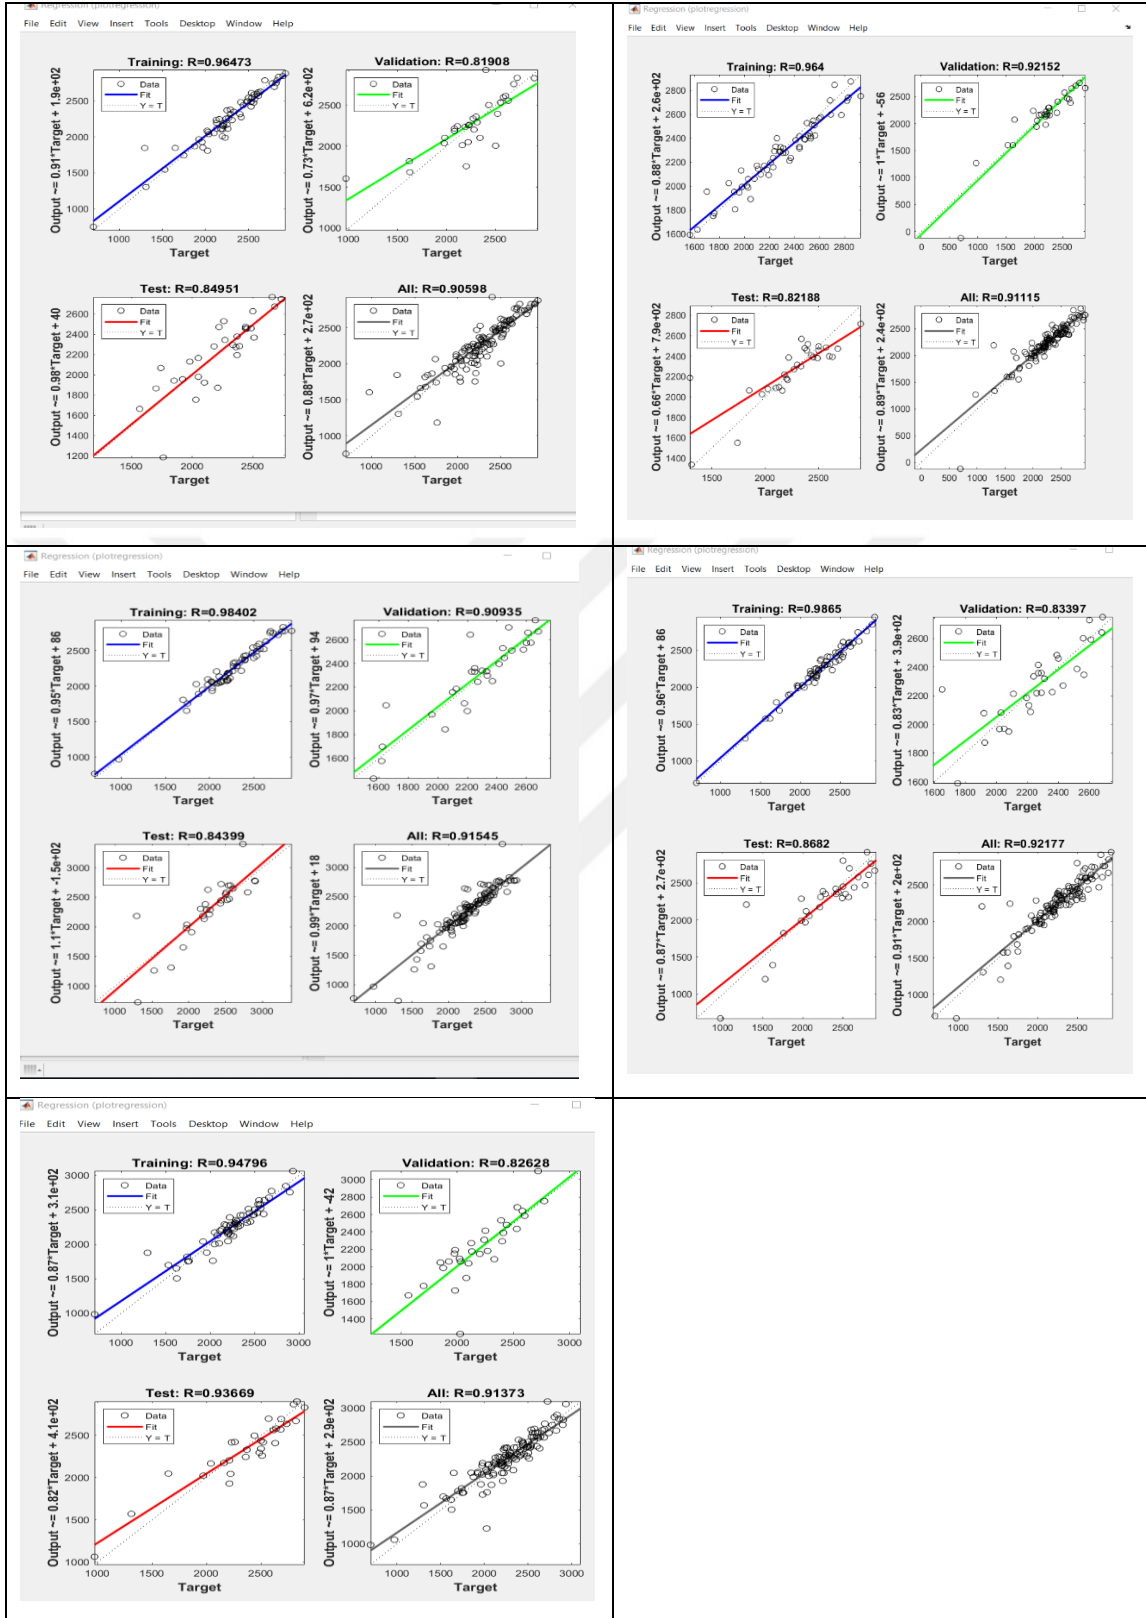
Ahmadi ve ark., (2007) ile Roush ve ark., (2006)’nın bildirdikleri YSA için tahminlenen R^2 değeri 0.99’dur. Literatürlerde bildirilen bu değerler modelden tahmin edilen değer ile örtüşmektedir.



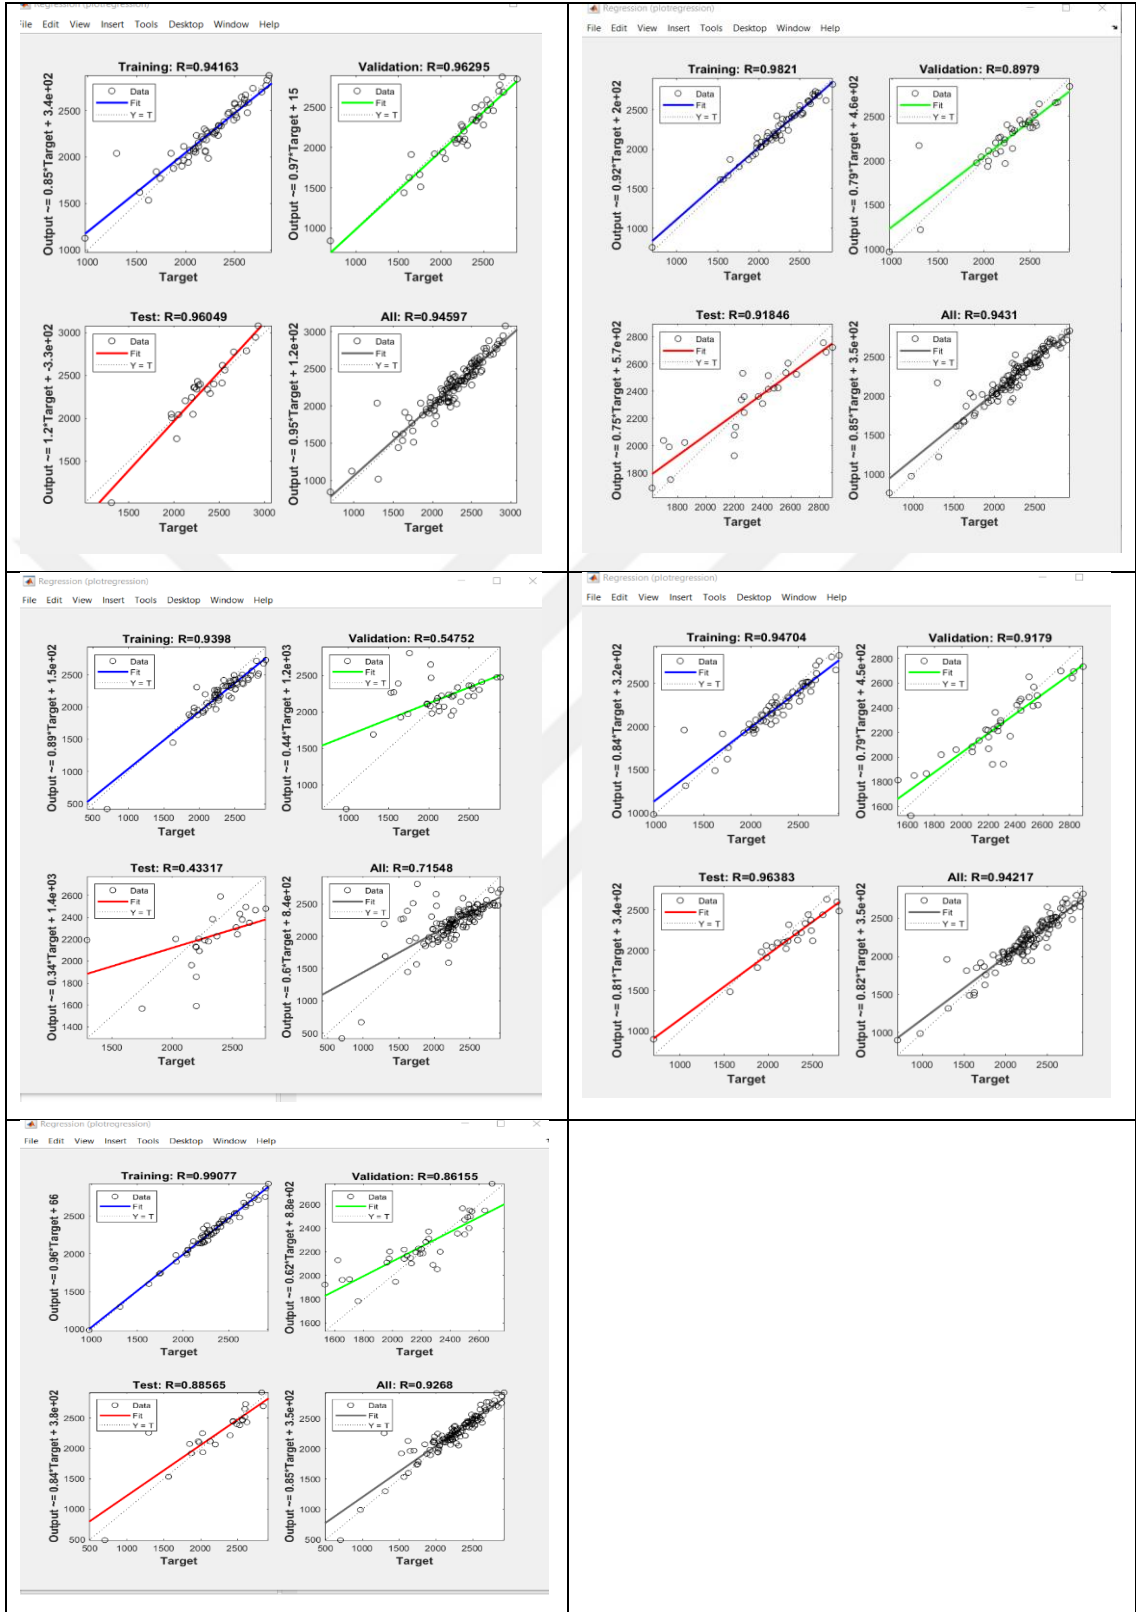
Şekil 4.2. Birinci uygulamaya ait regresyon saçılım grafikleri



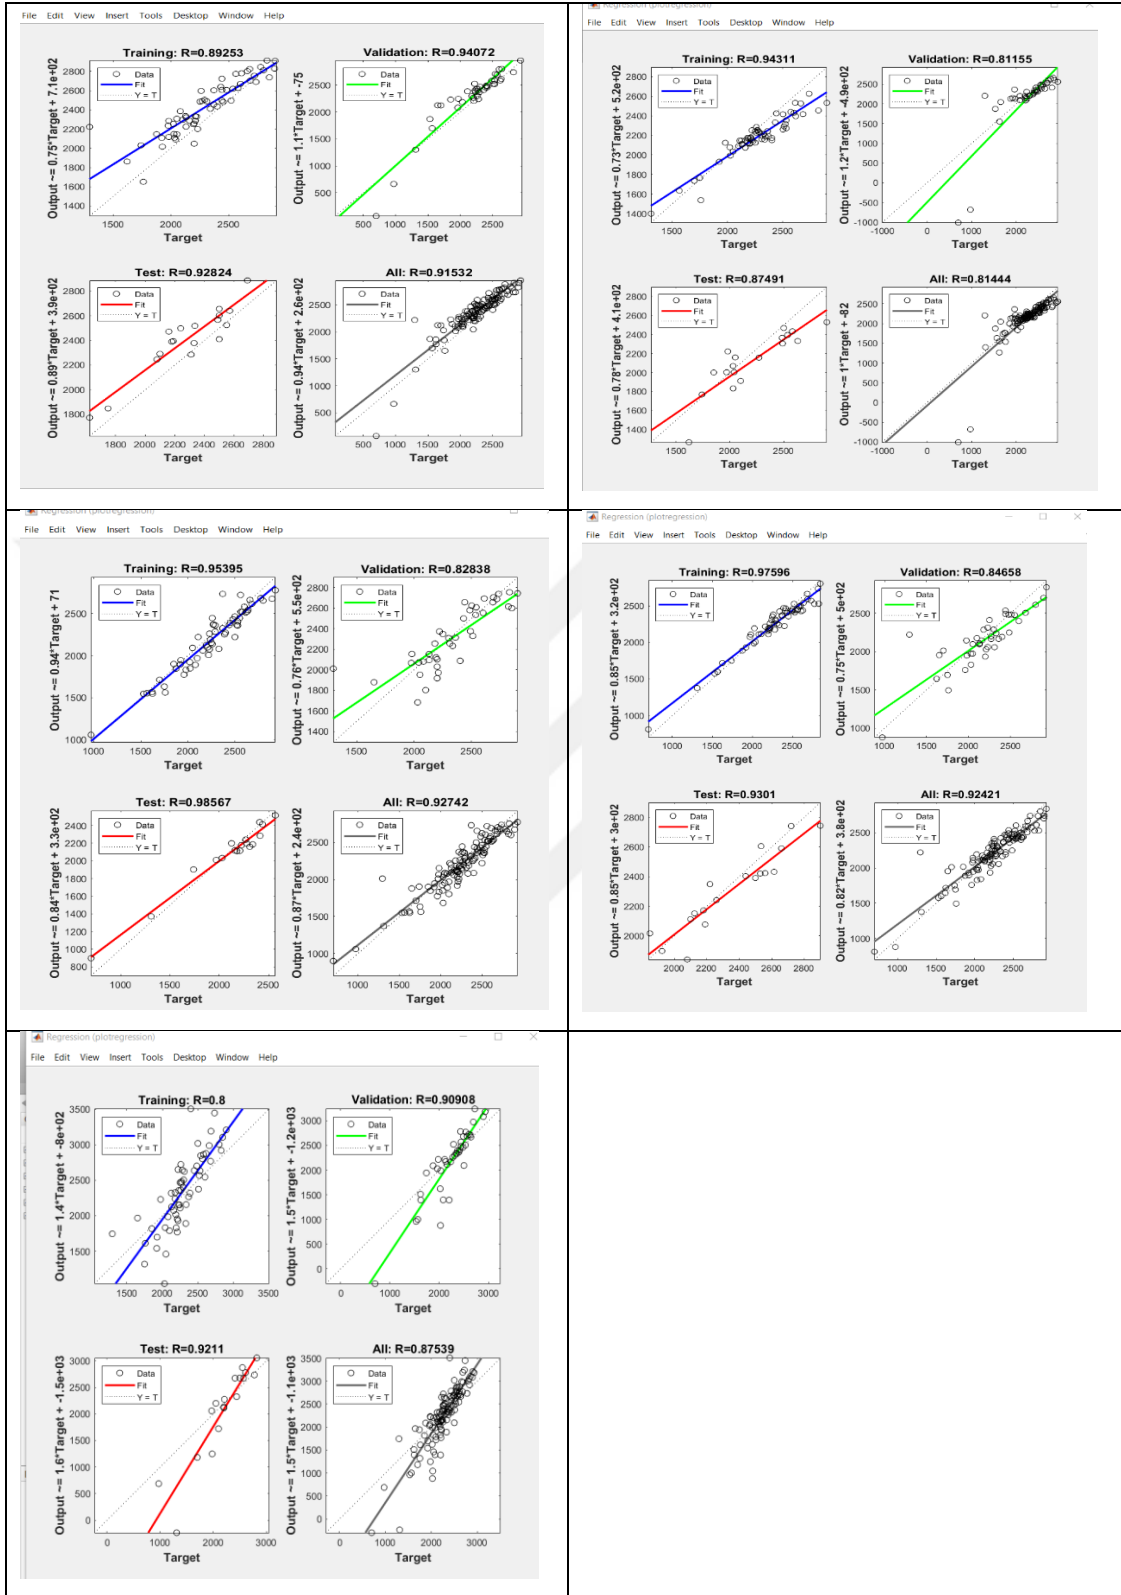
Şekil 4.3. İkinci uygulamaya ait regresyon saçılım grafikleri



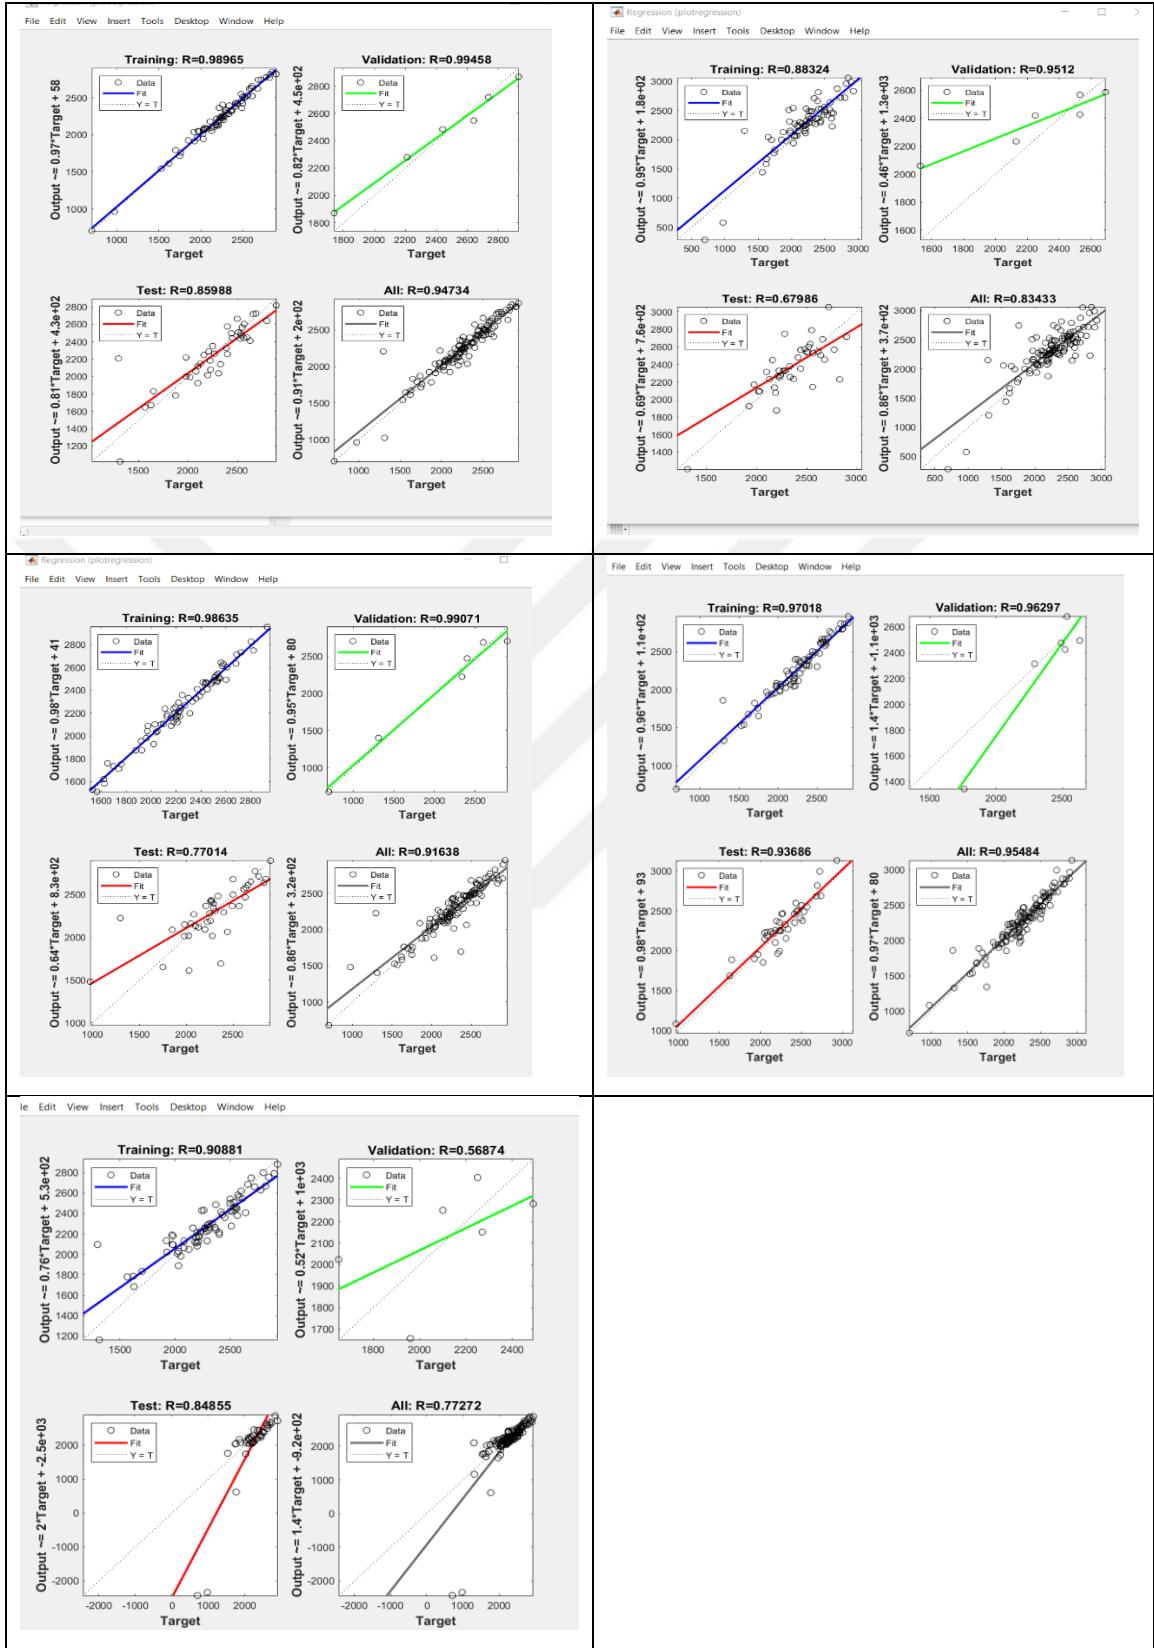
Şekil 4.4. Üçüncü uygulamaya ait regresyon saçılım grafikleri



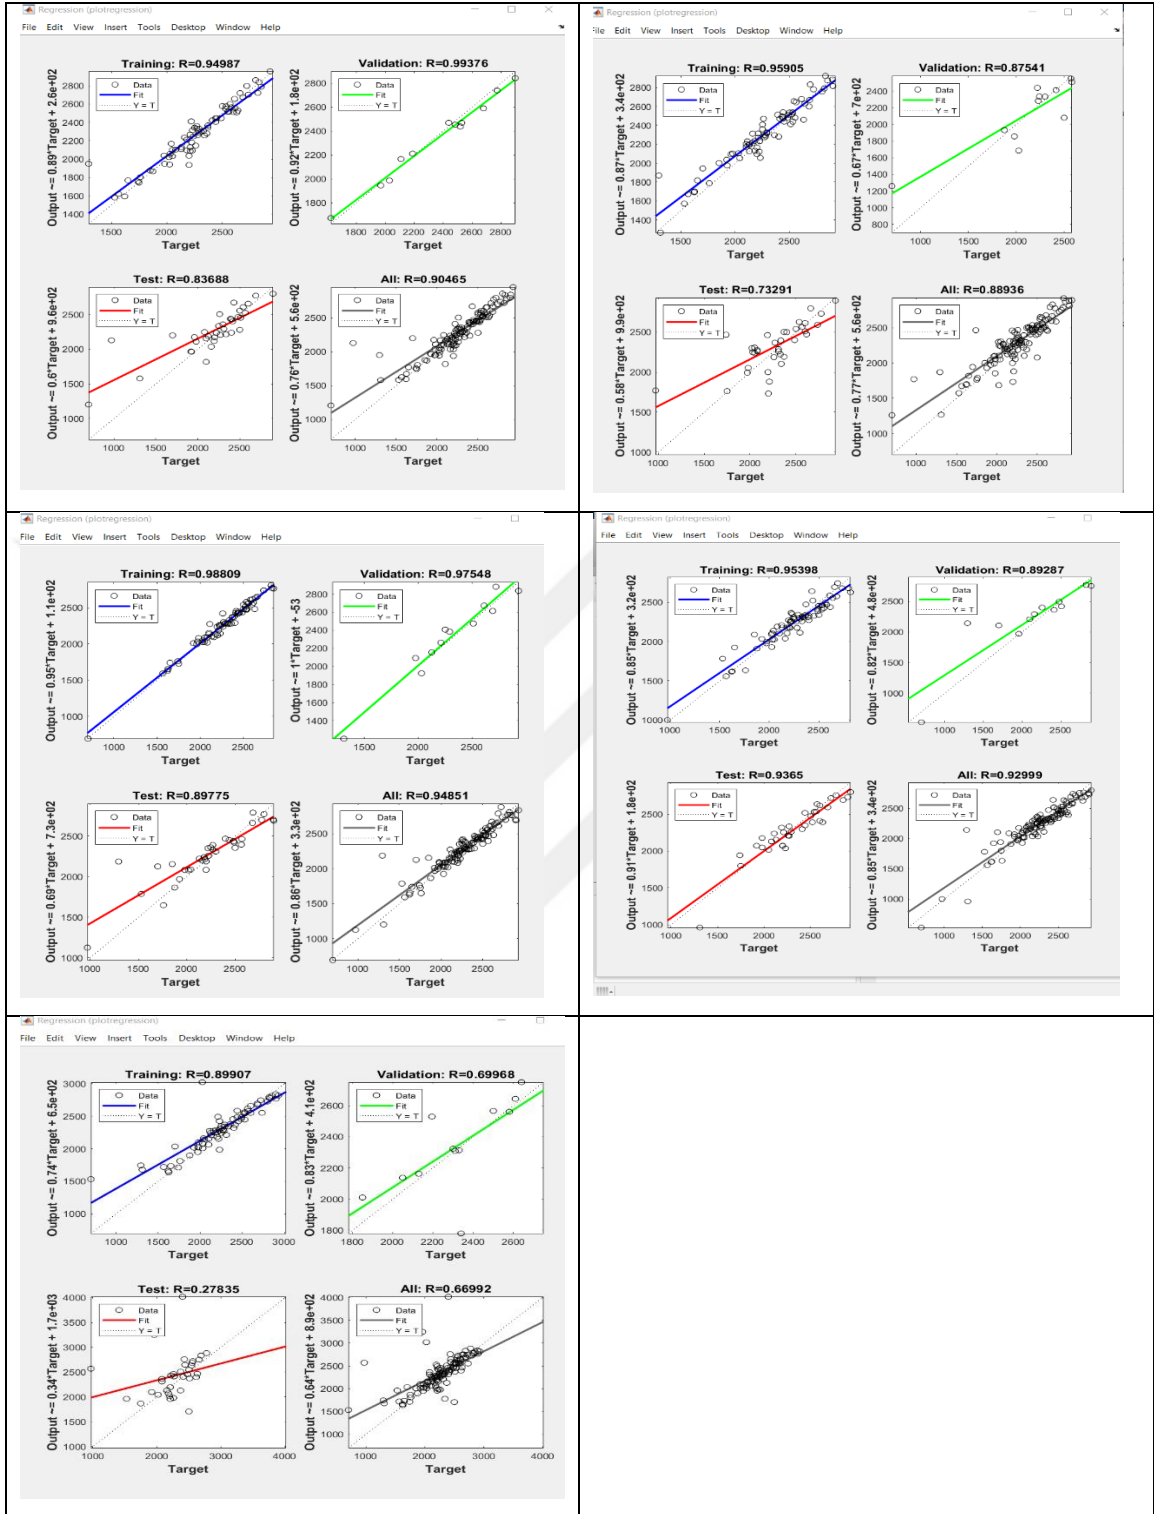
Şekil 4.5. Dördüncü uygulamaya ait regresyon saçılım grafikleri



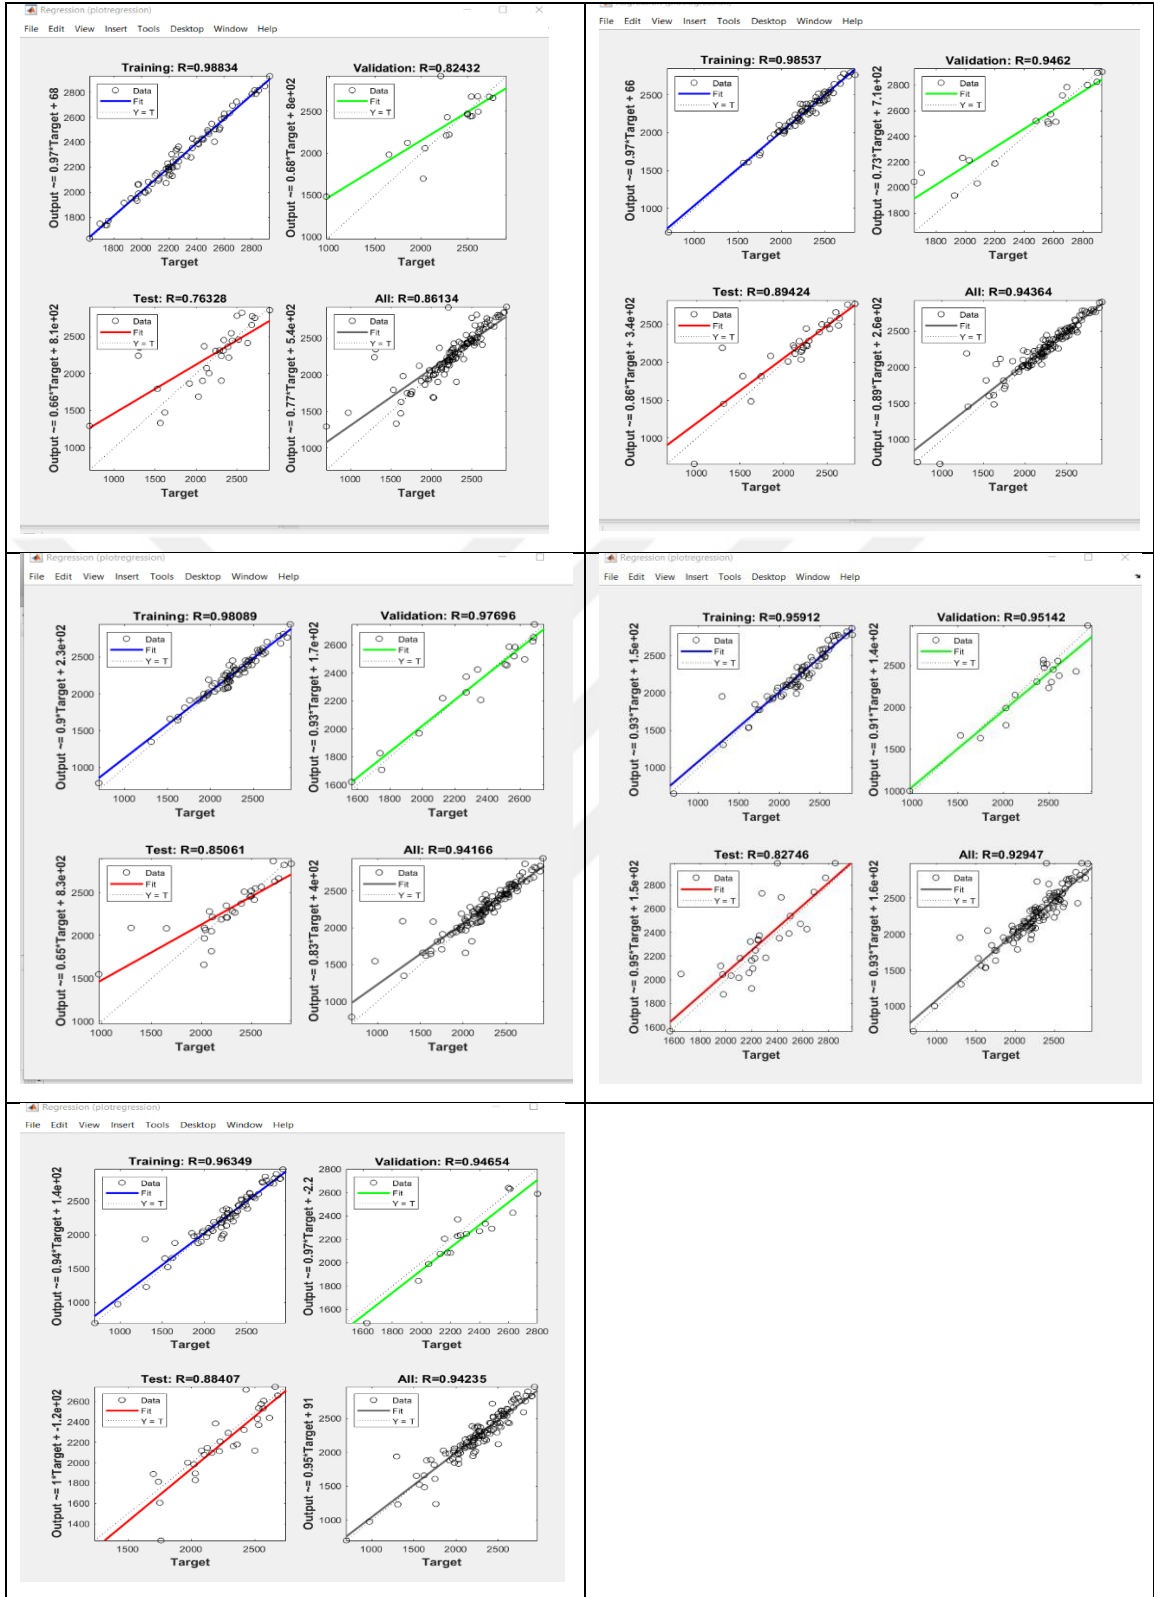
Şekil 4.6. Beşinci uygulamaya ait regresyon saçılım grafikleri



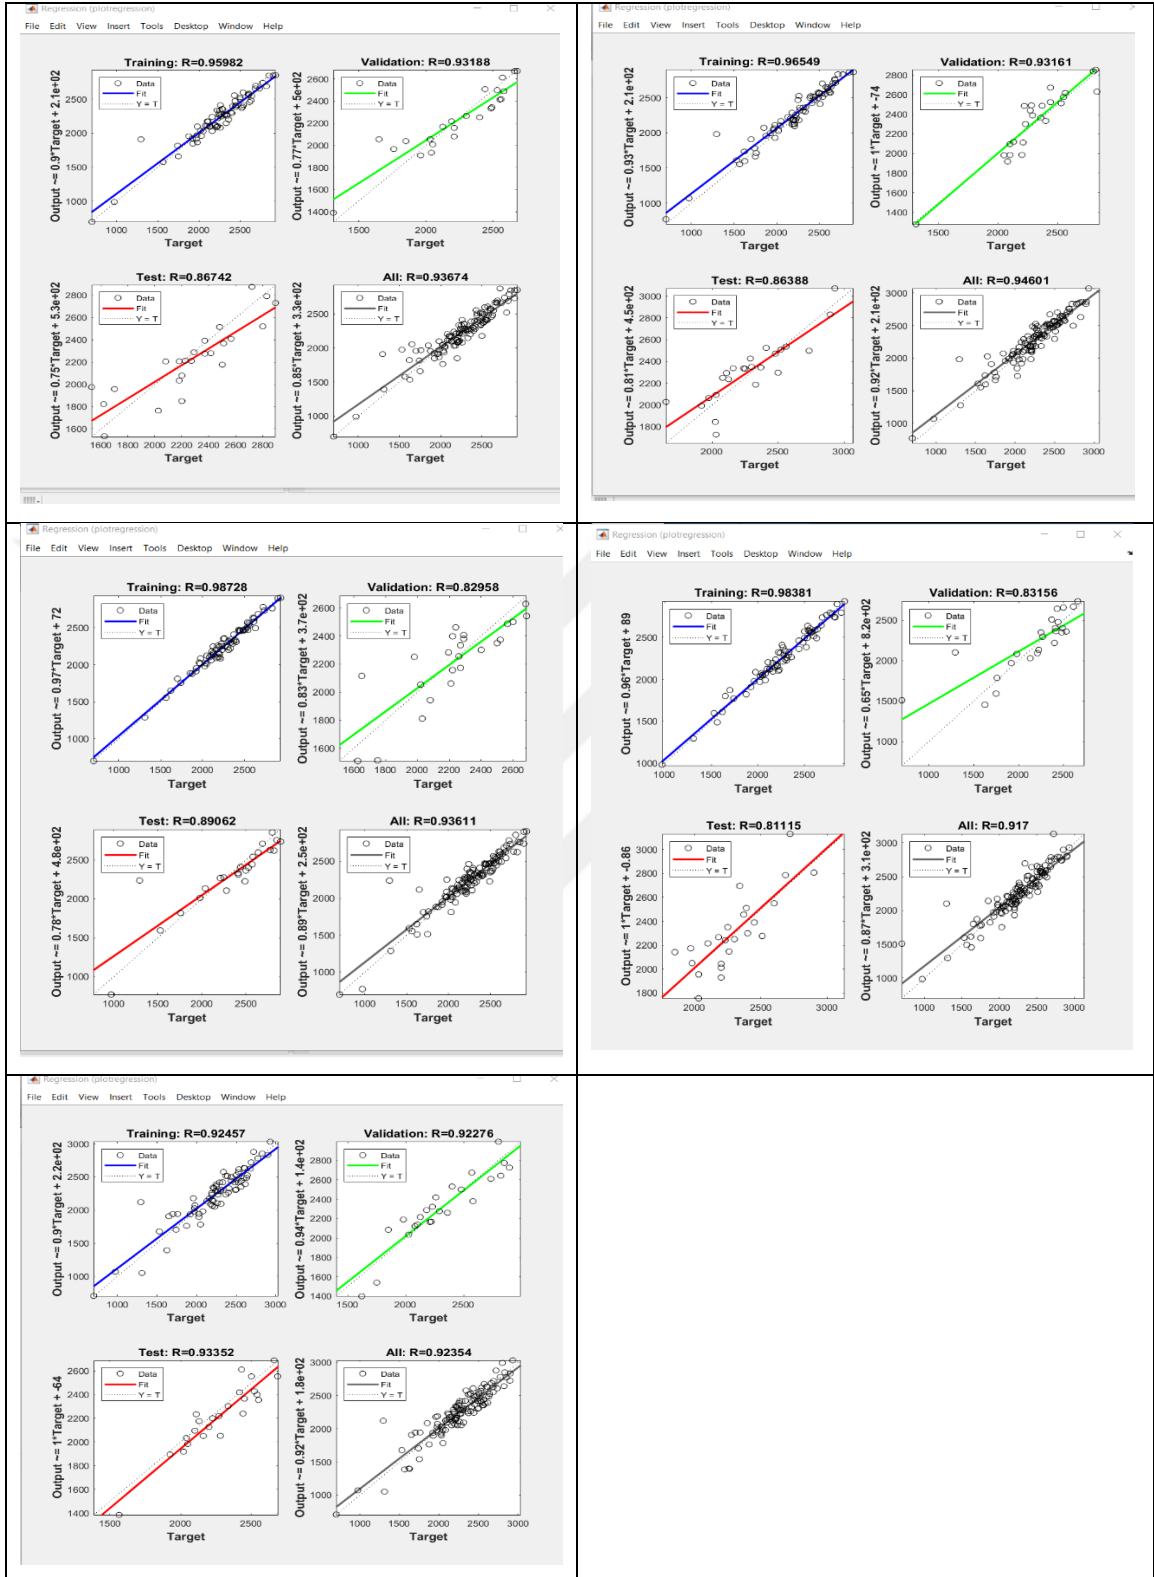
Şekil 4.7. Altıncı uygulamaya ait regresyon saçılım grafikleri



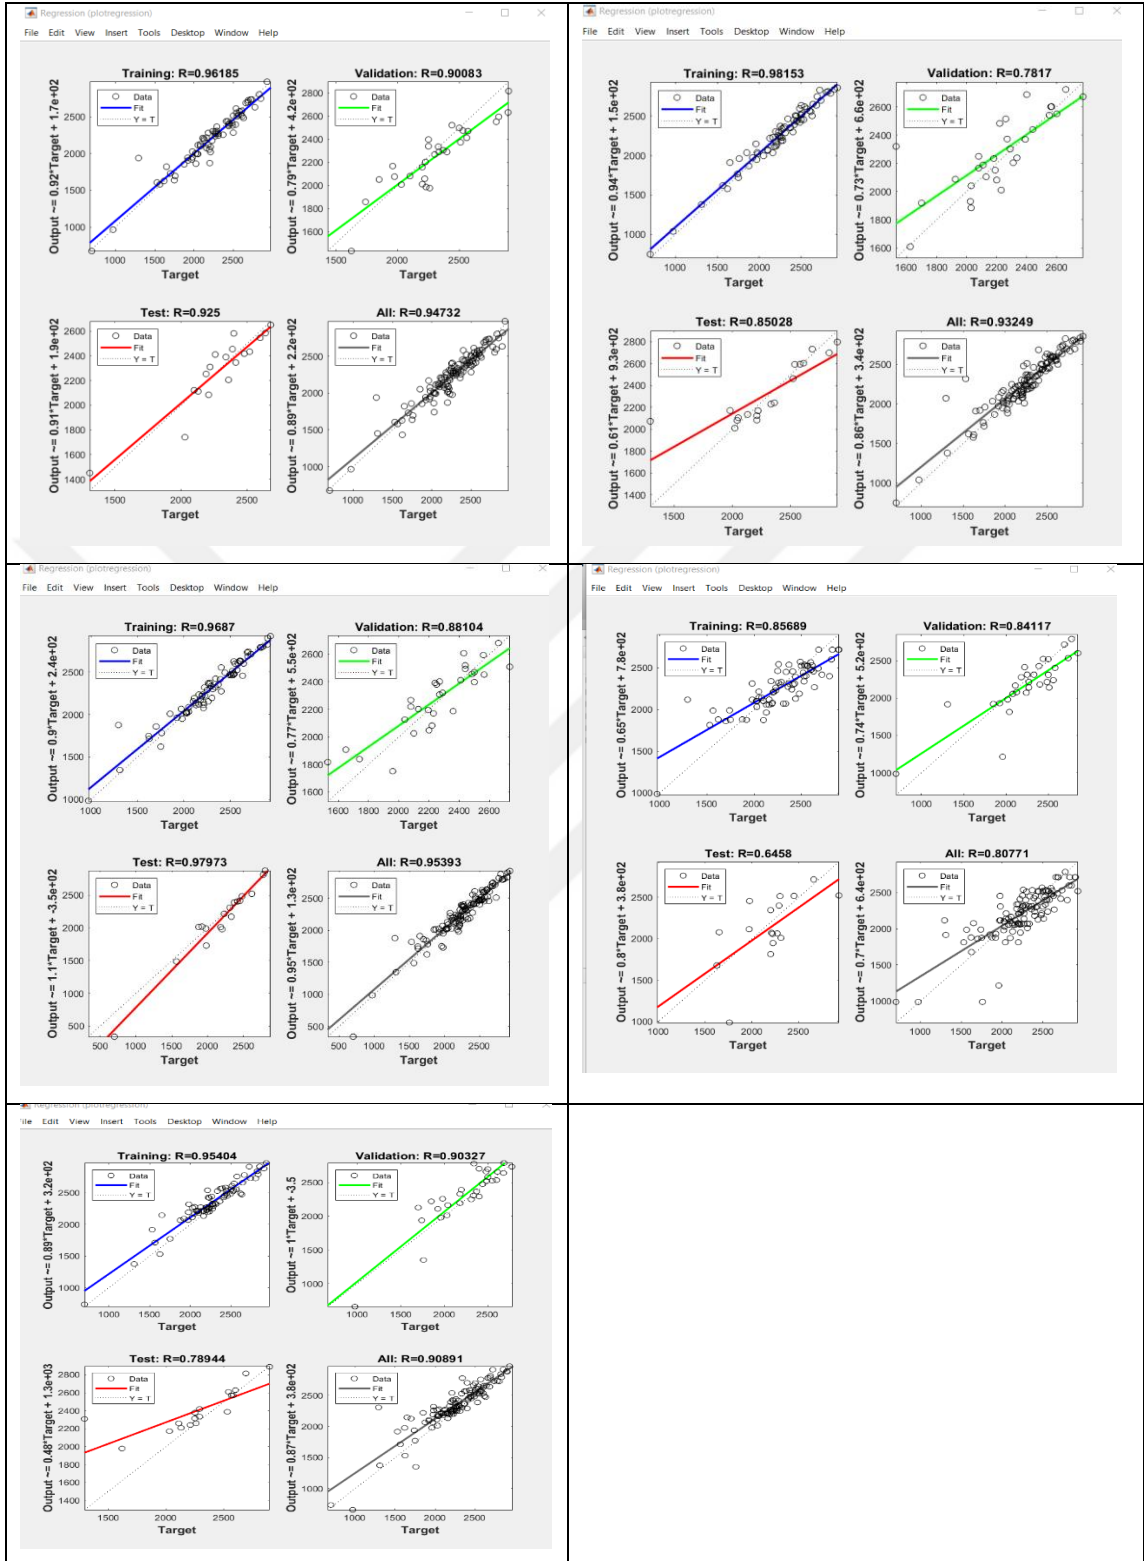
Şekil 4.8. Yedinci uygulamaya ait regresyon saçılım grafikleri



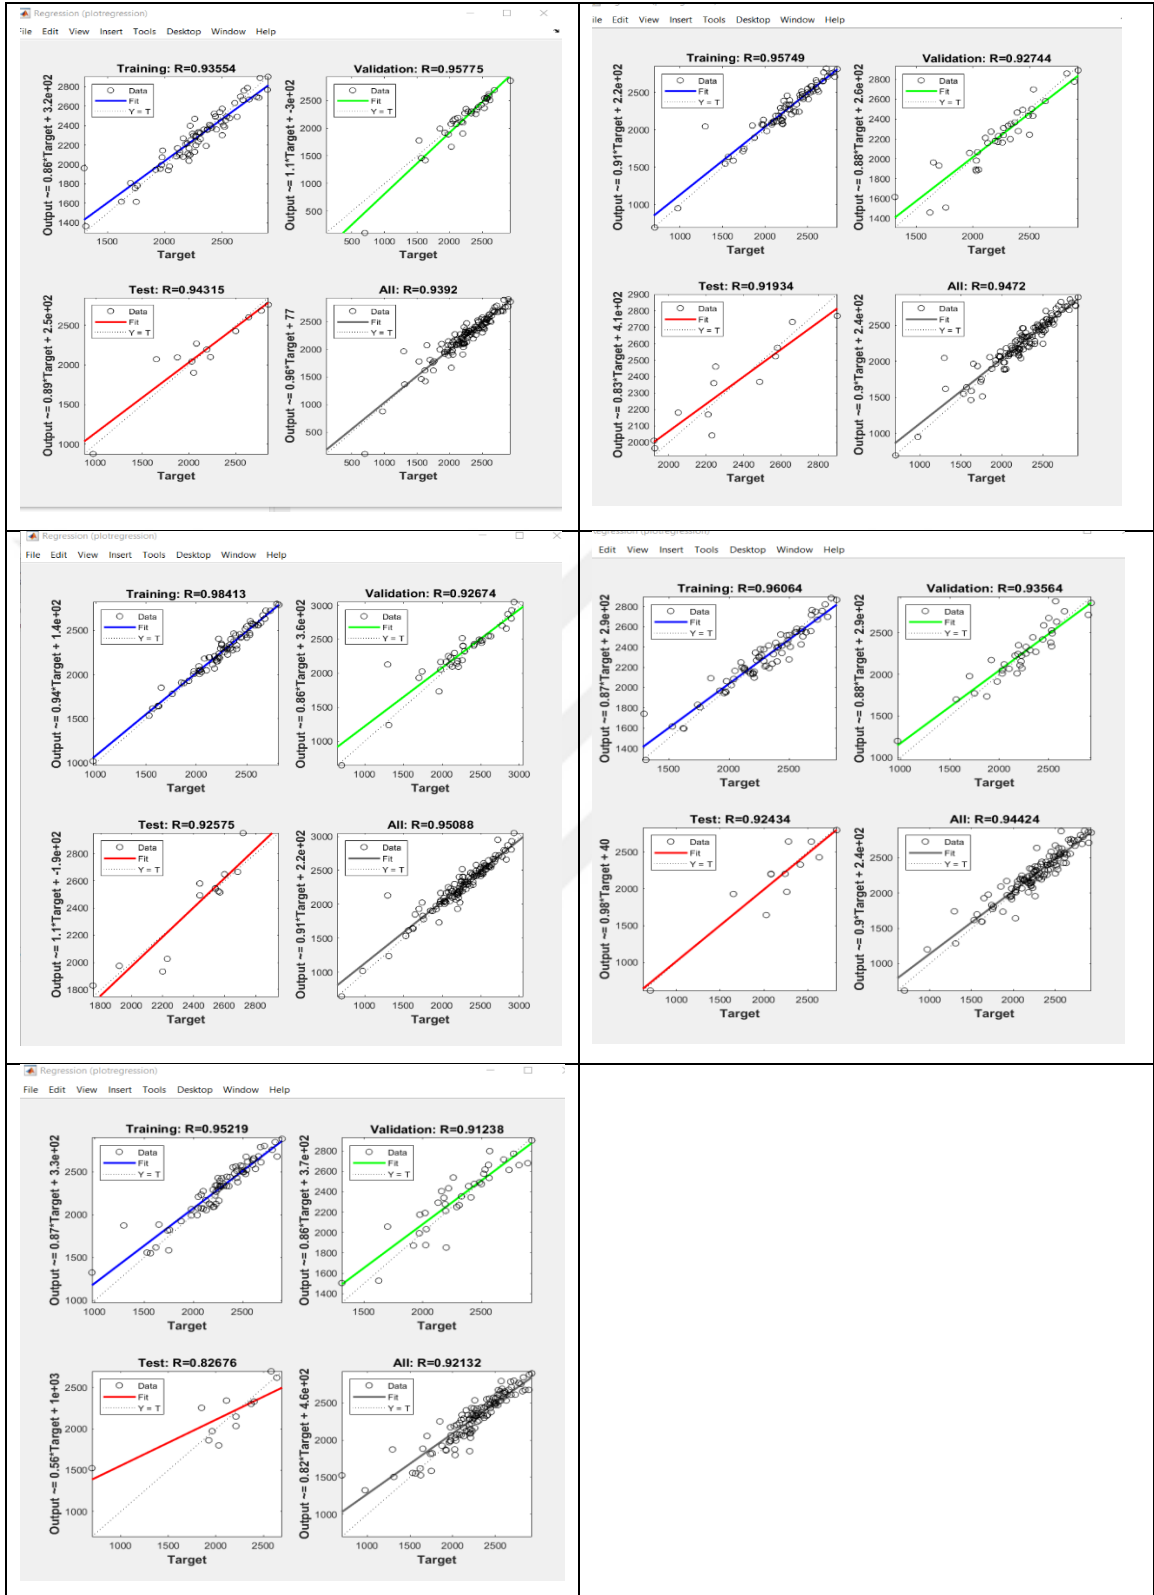
Şekil 4.9. Sekizinci uygulamaya ait regresyon saçılım grafikleri



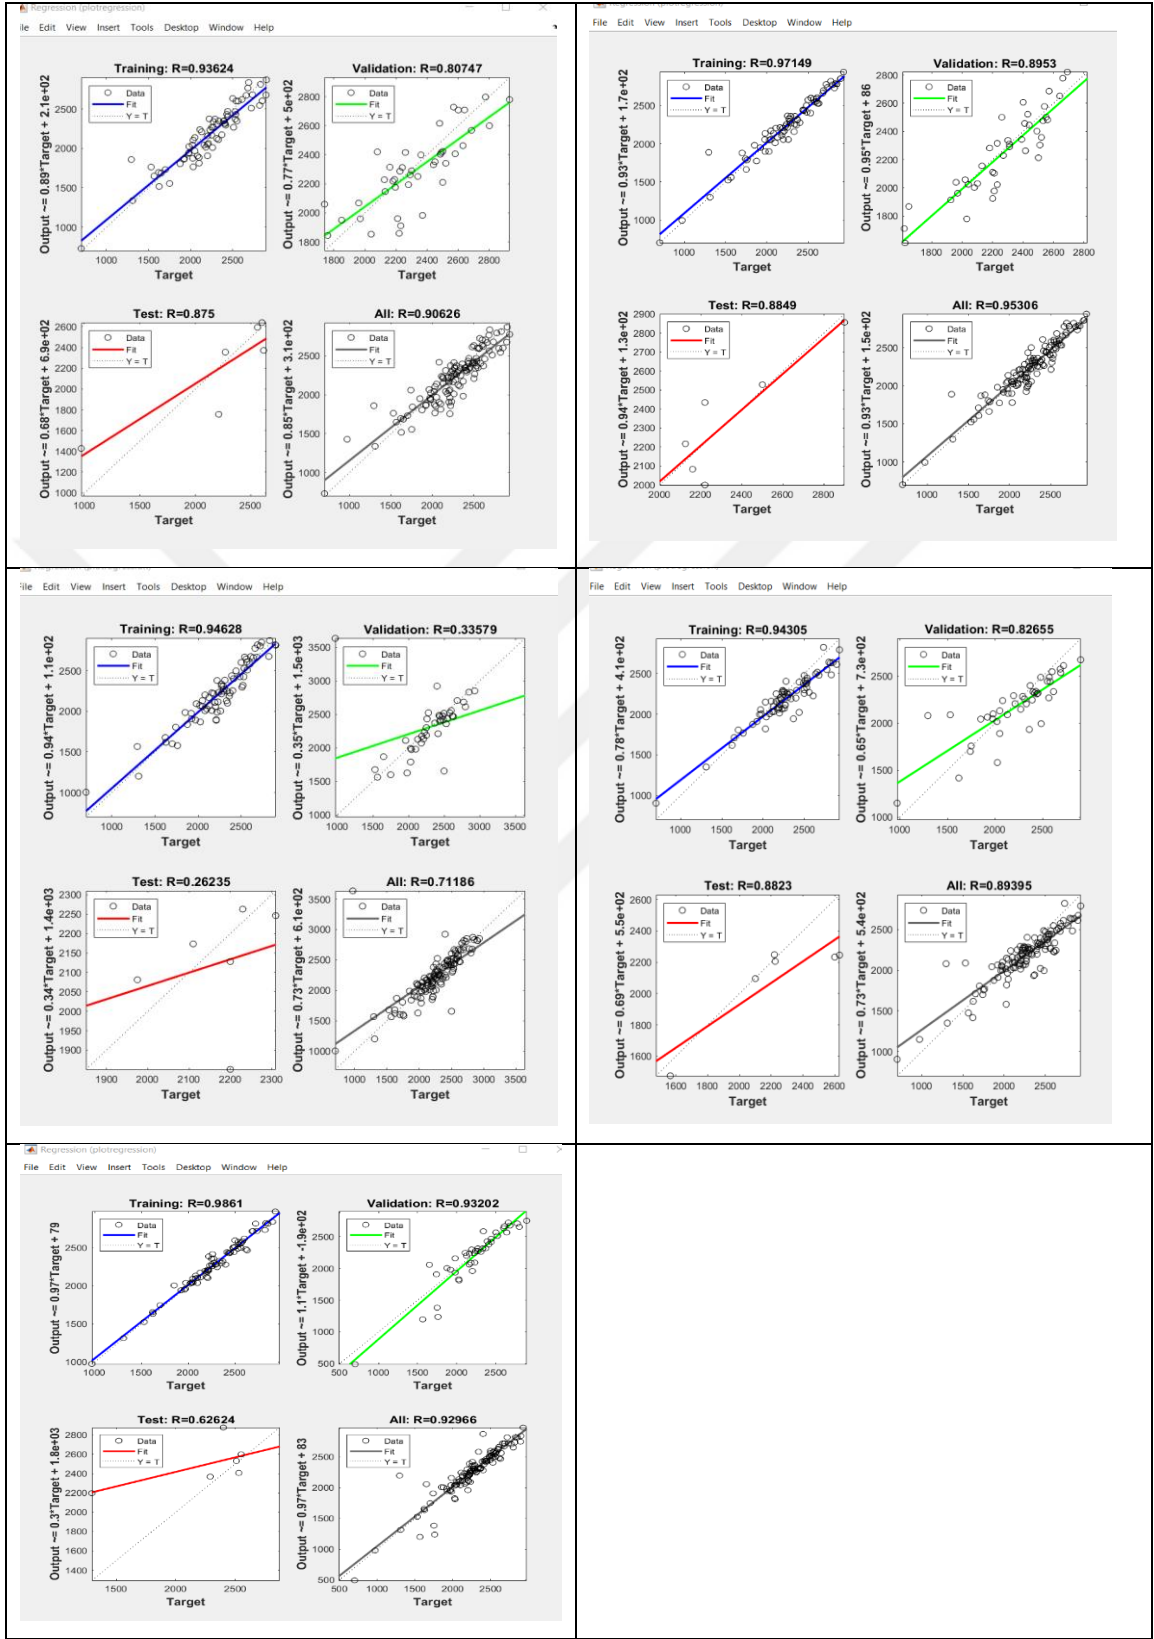
Şekil 4.10. Dokuzuncu uygulamaya ait regresyon saçılım grafikleri



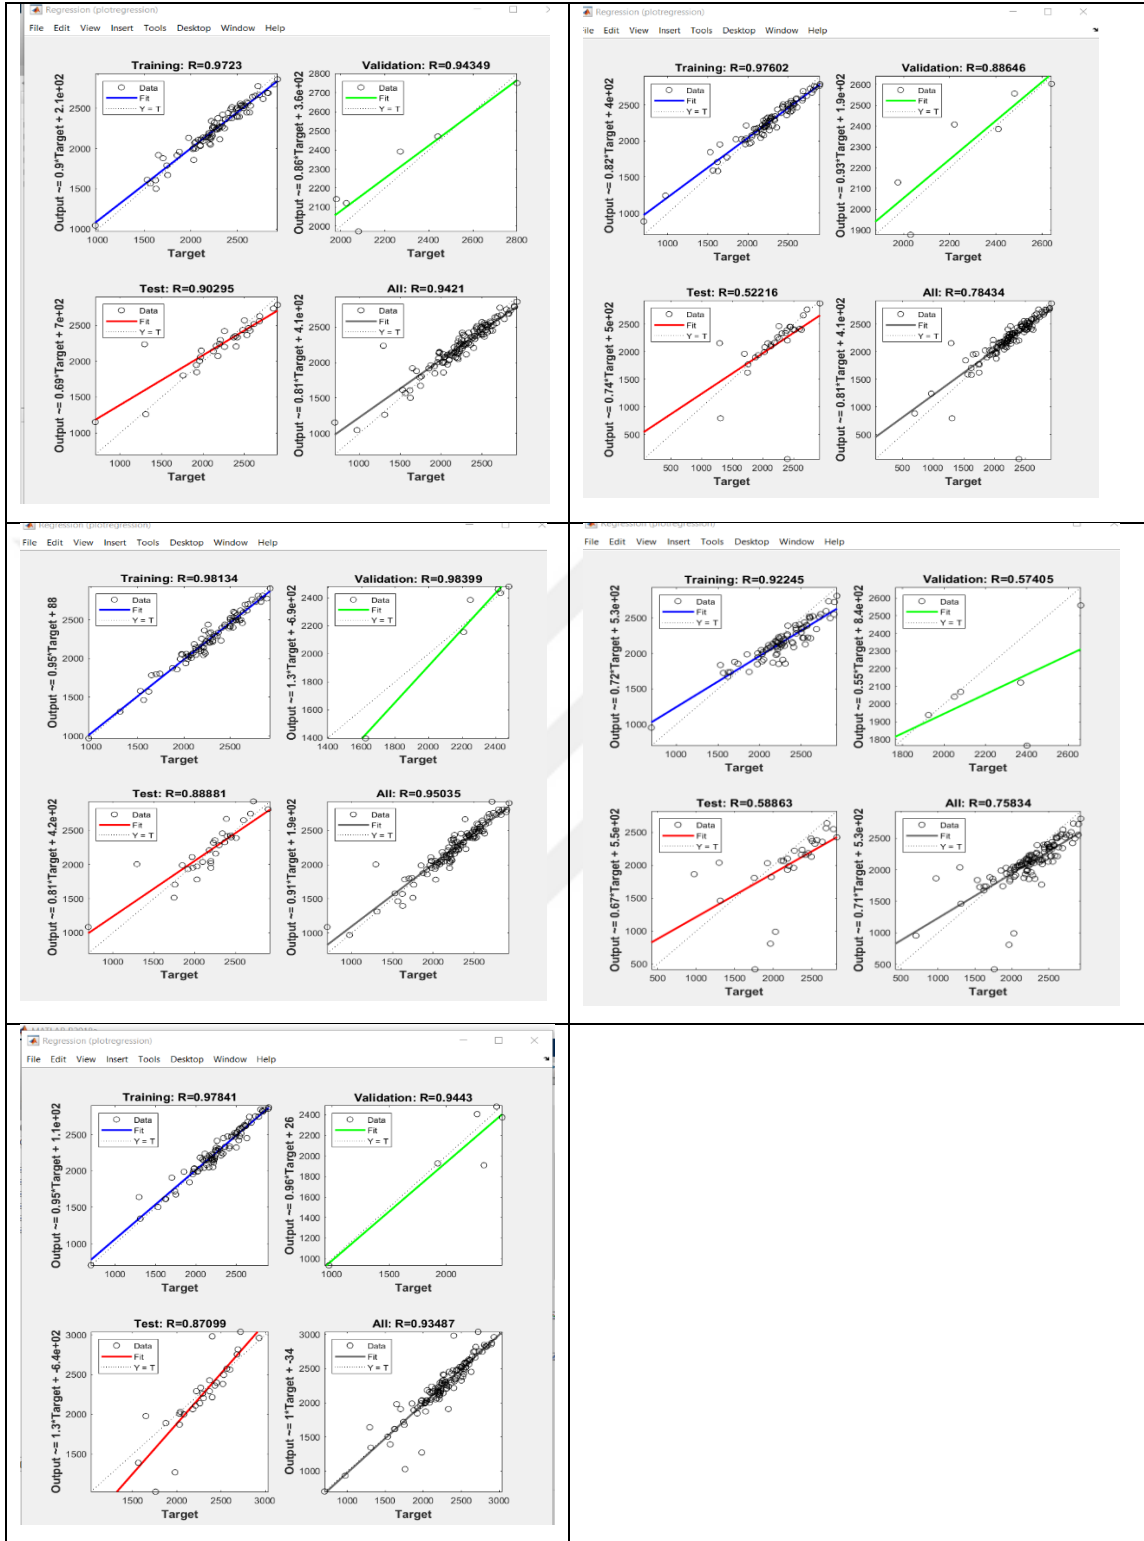
Şekil 4.11. Onuncu uygulamaya ait regresyon saçılım grafikleri



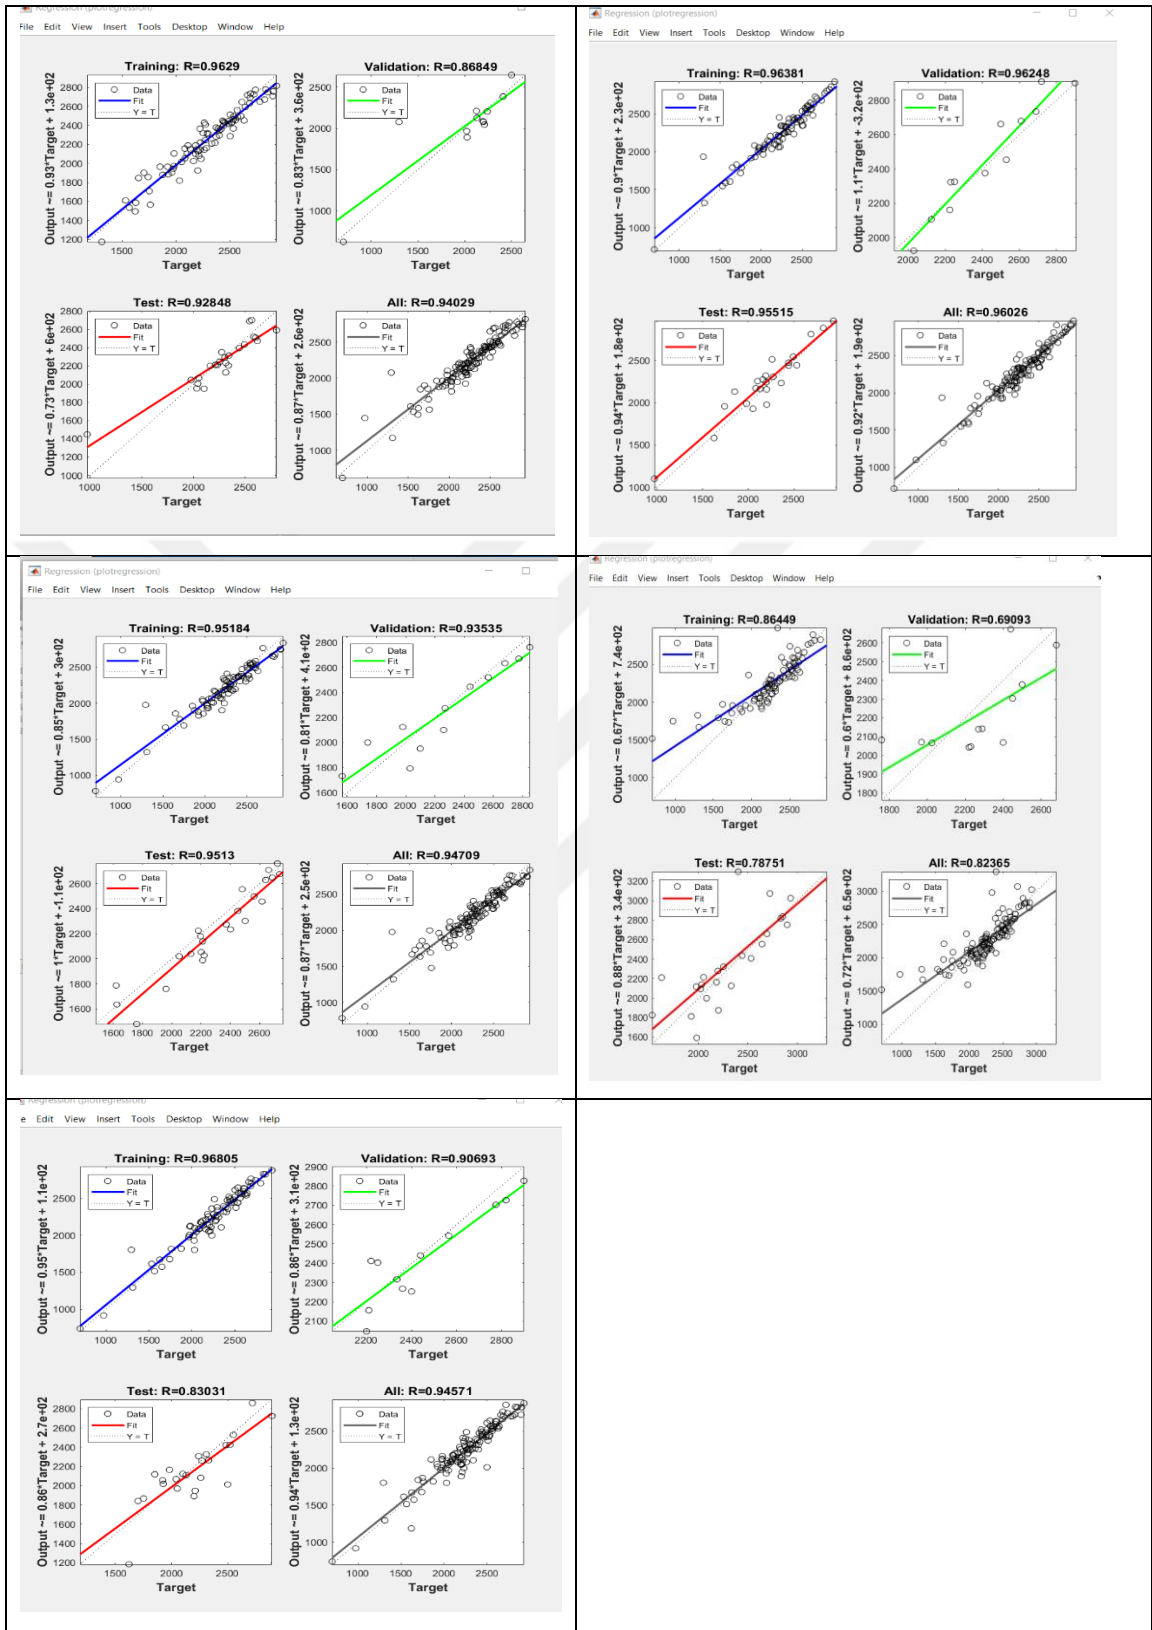
Şekil 4.12. On birinci uygulamaya ait regresyon saçılım grafikleri



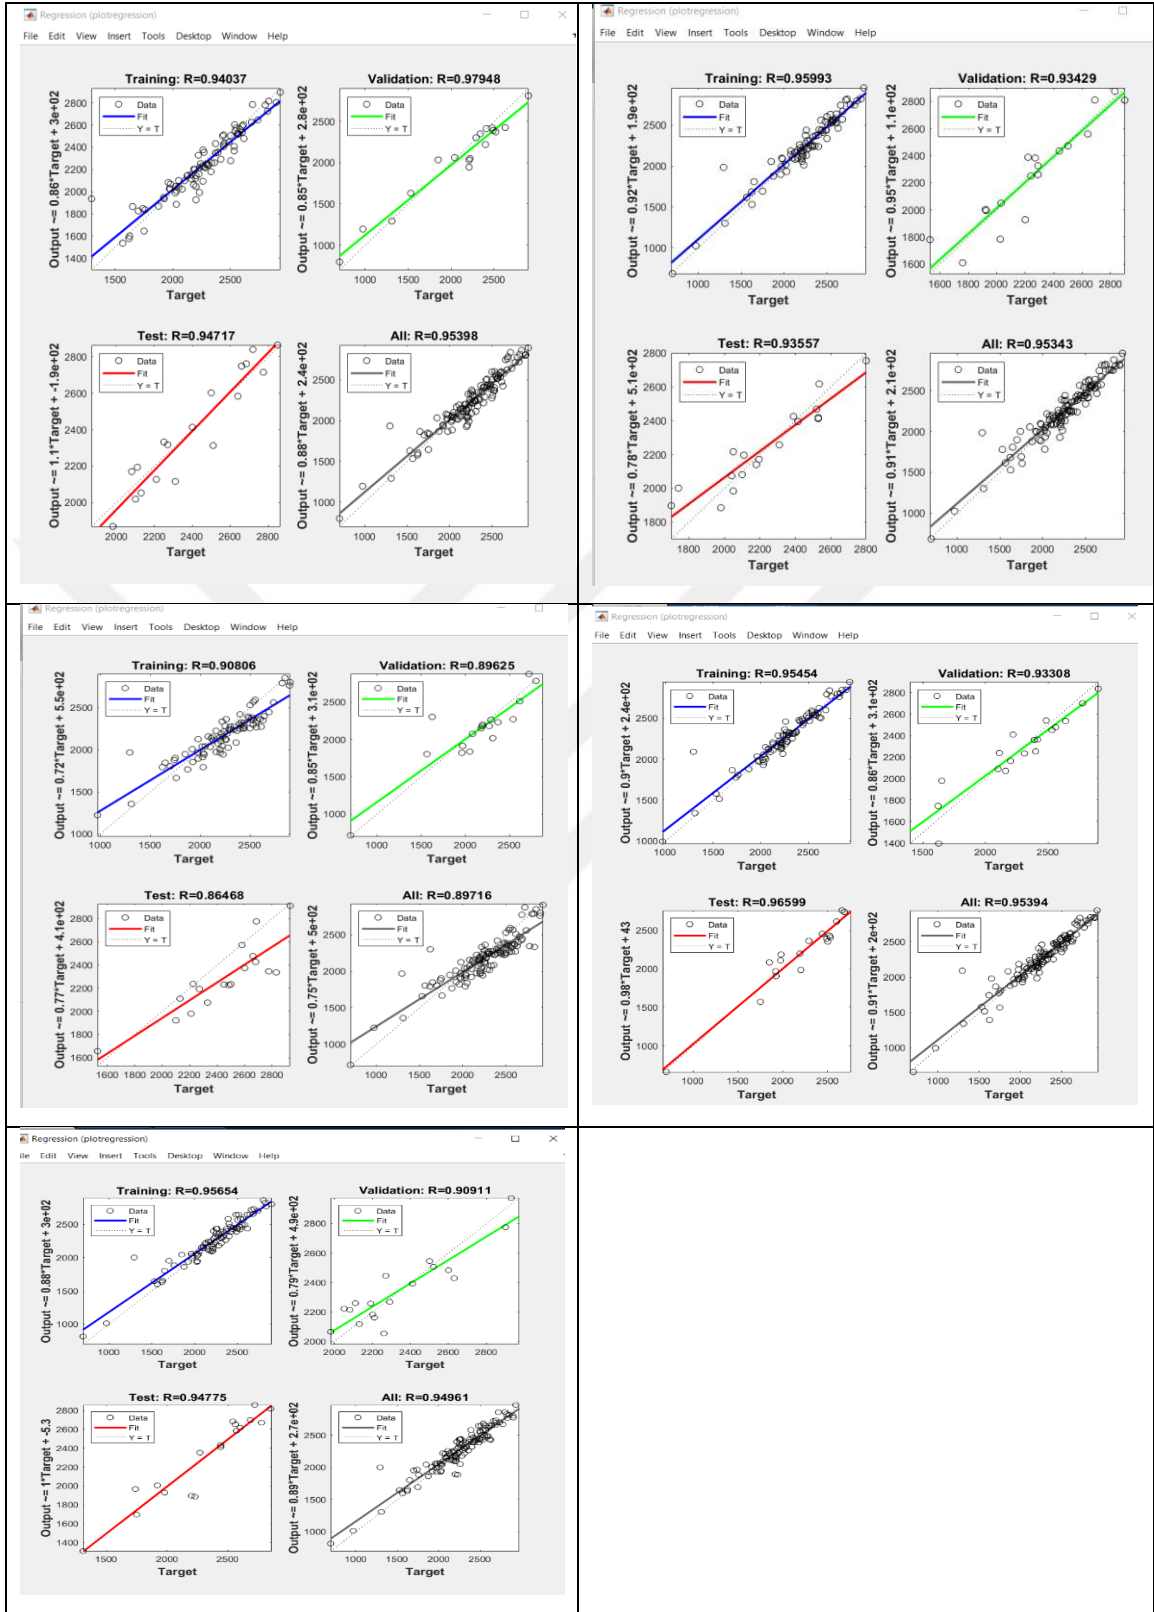
Şekil 4.13. On ikinci uygulamaya ait regresyon saçılım grafikleri



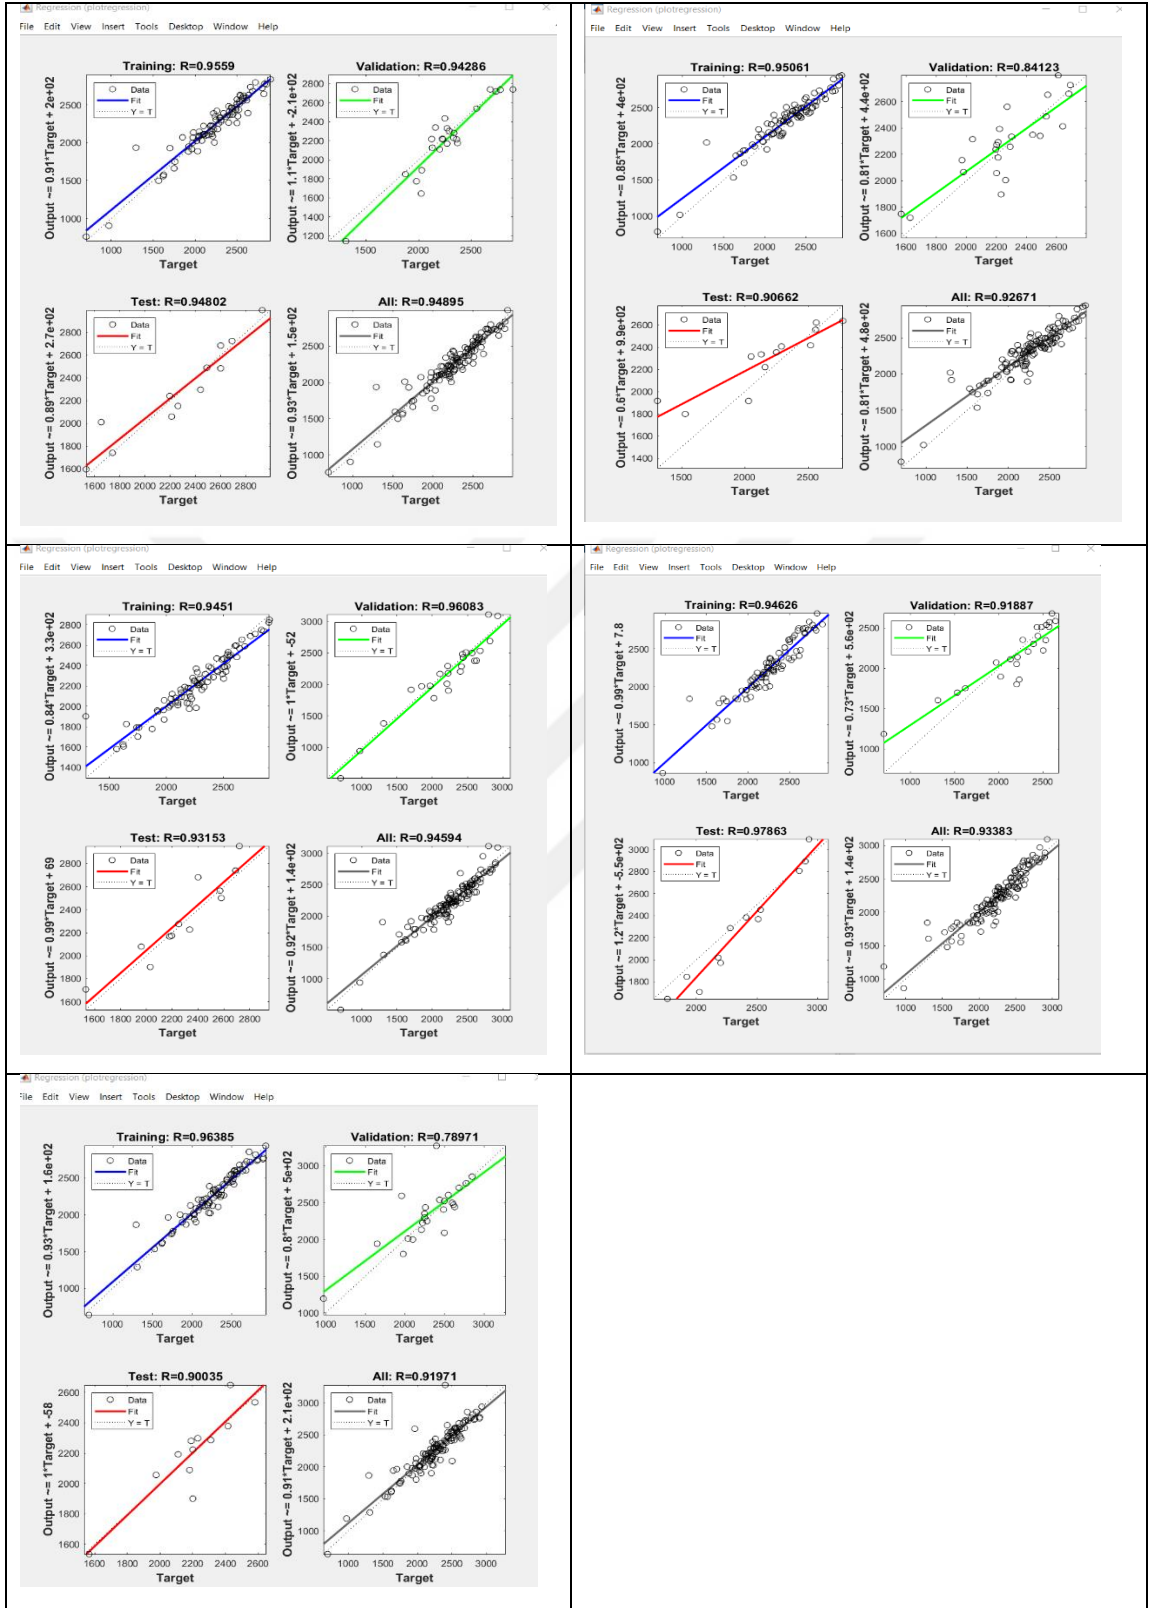
Şekil 4.14. On üçüncü uygulamaya ait regresyon saçılım grafikleri



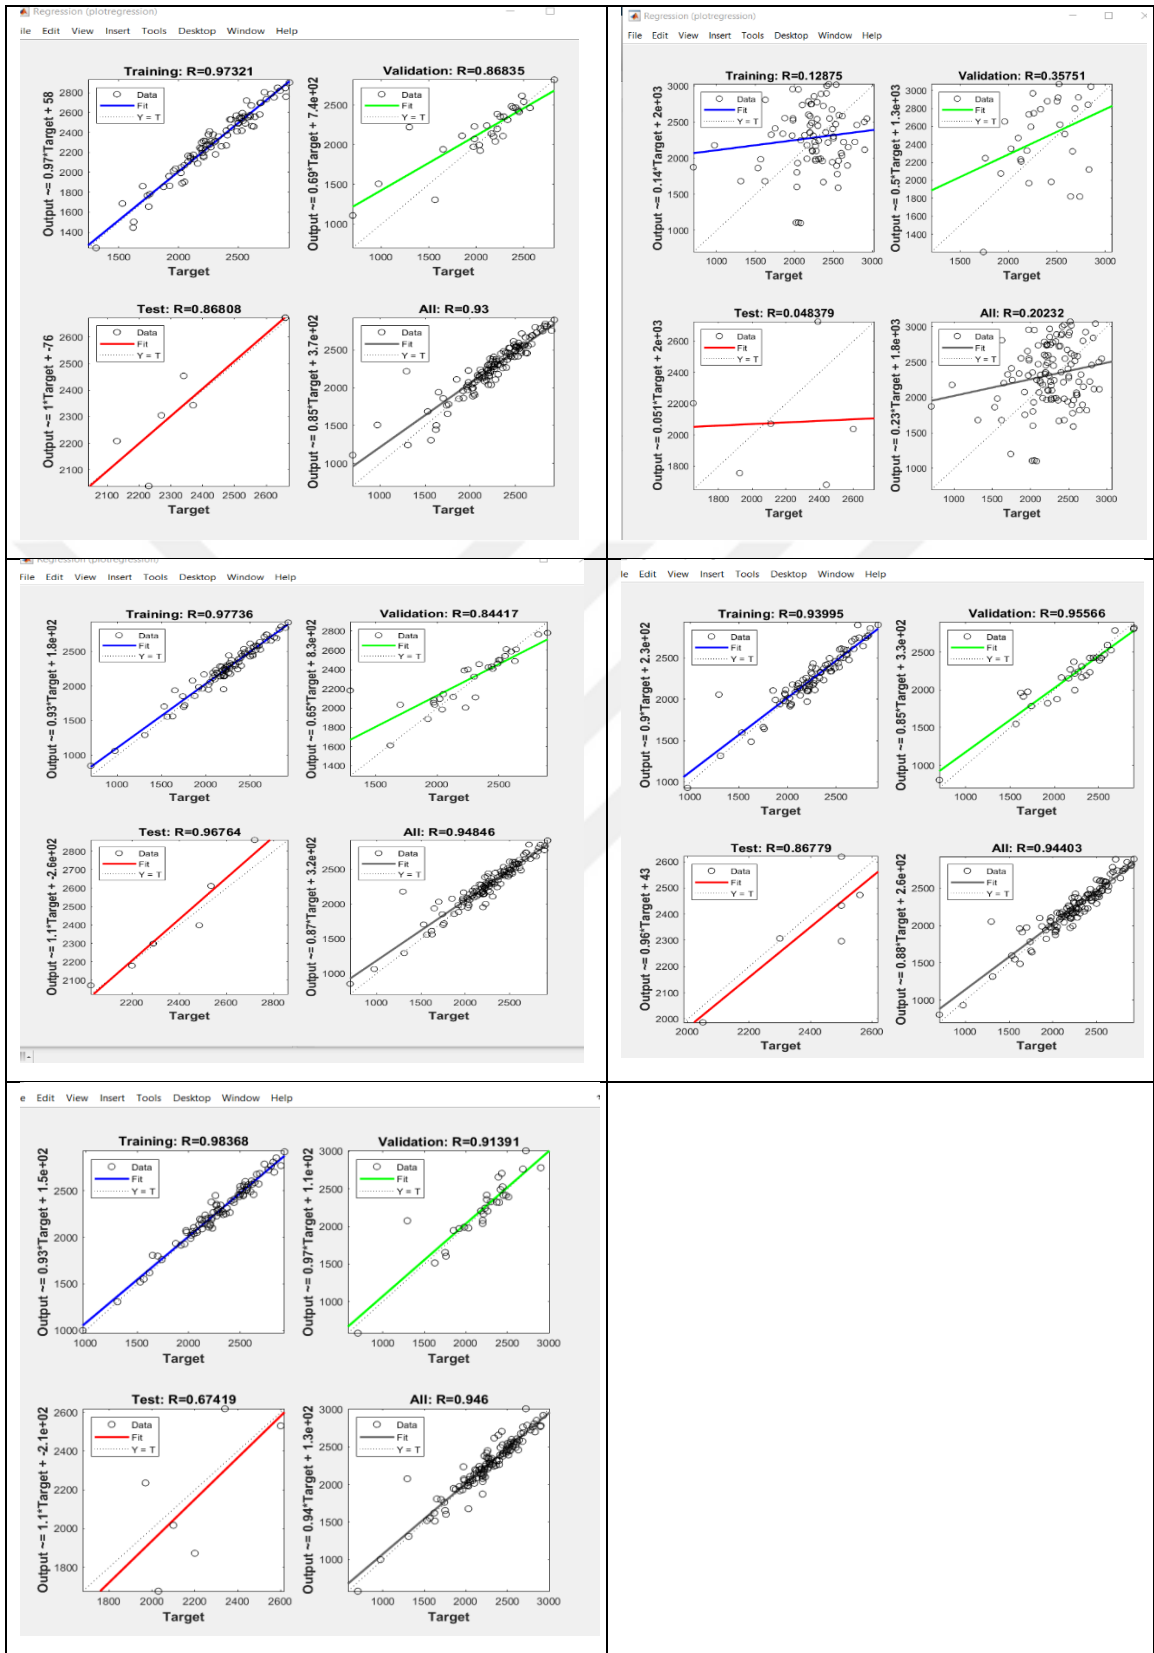
Şekil 4.15. On dördüncü uygulamaya ait regresyon saçılım grafikleri



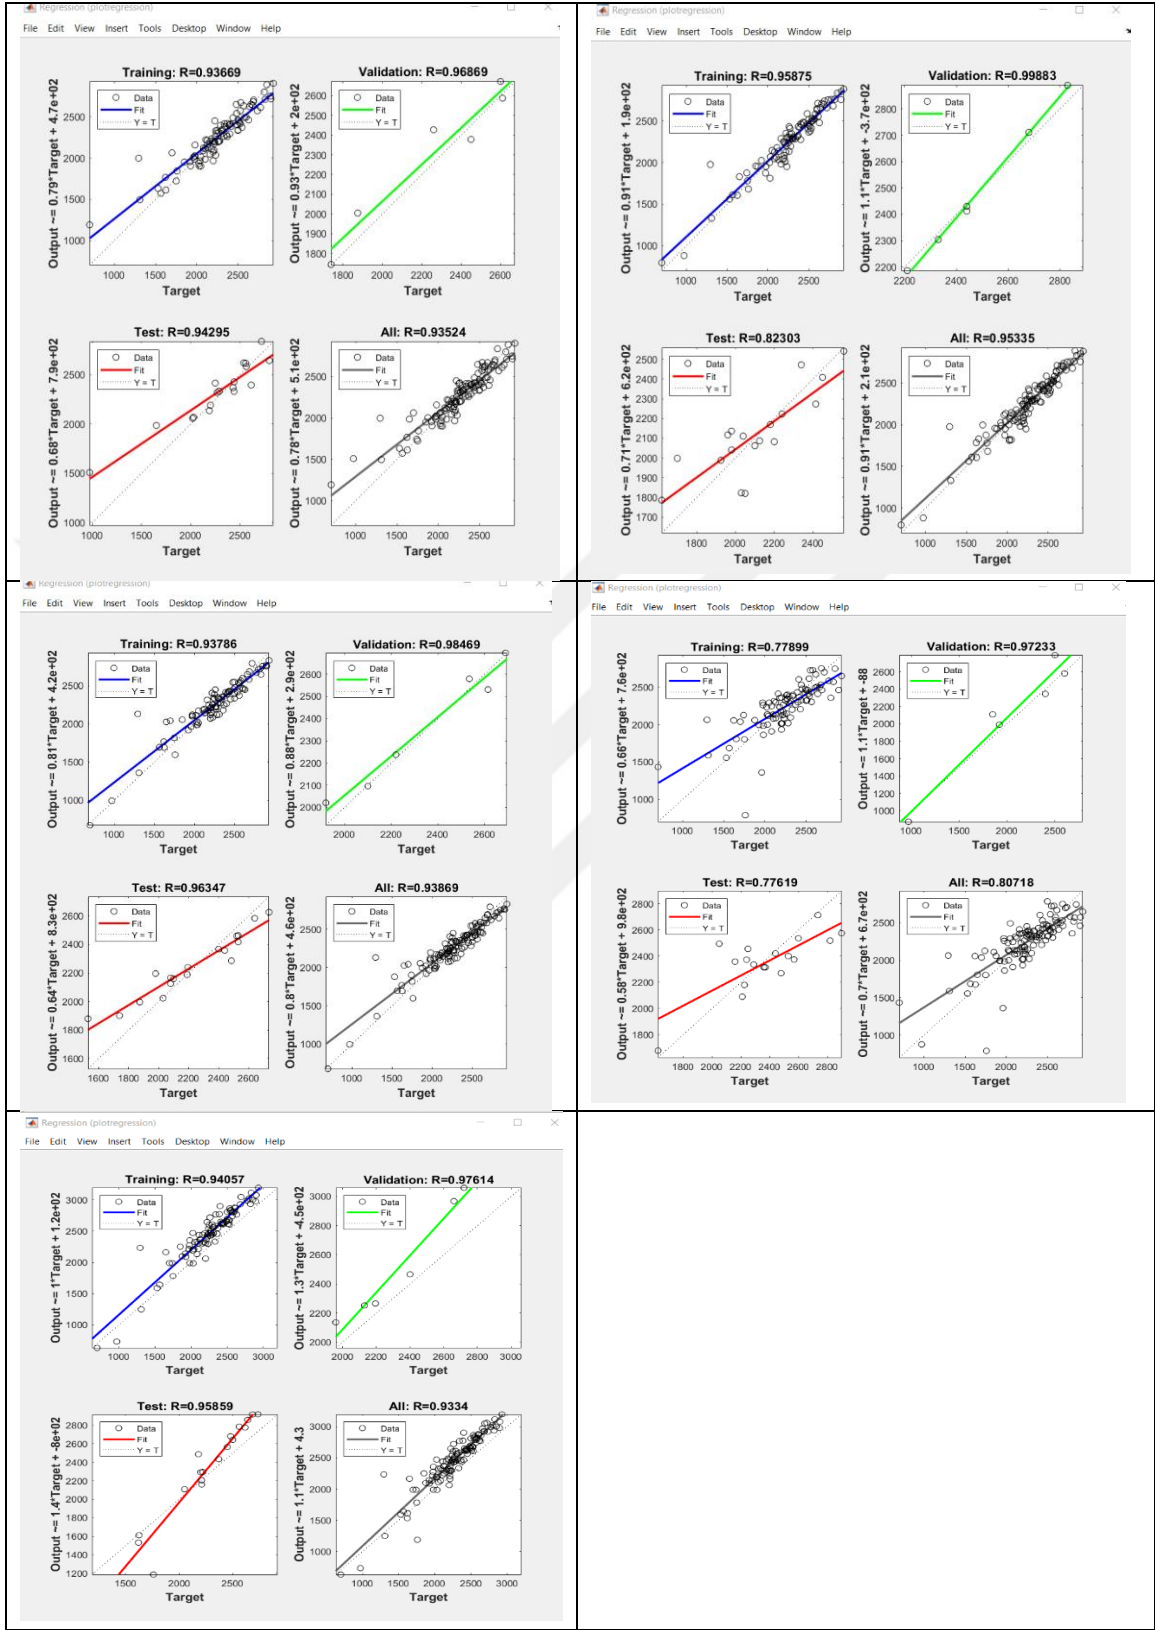
Şekil 4.16. On beşinci uygulamaya ait regresyon saçılım grafikleri



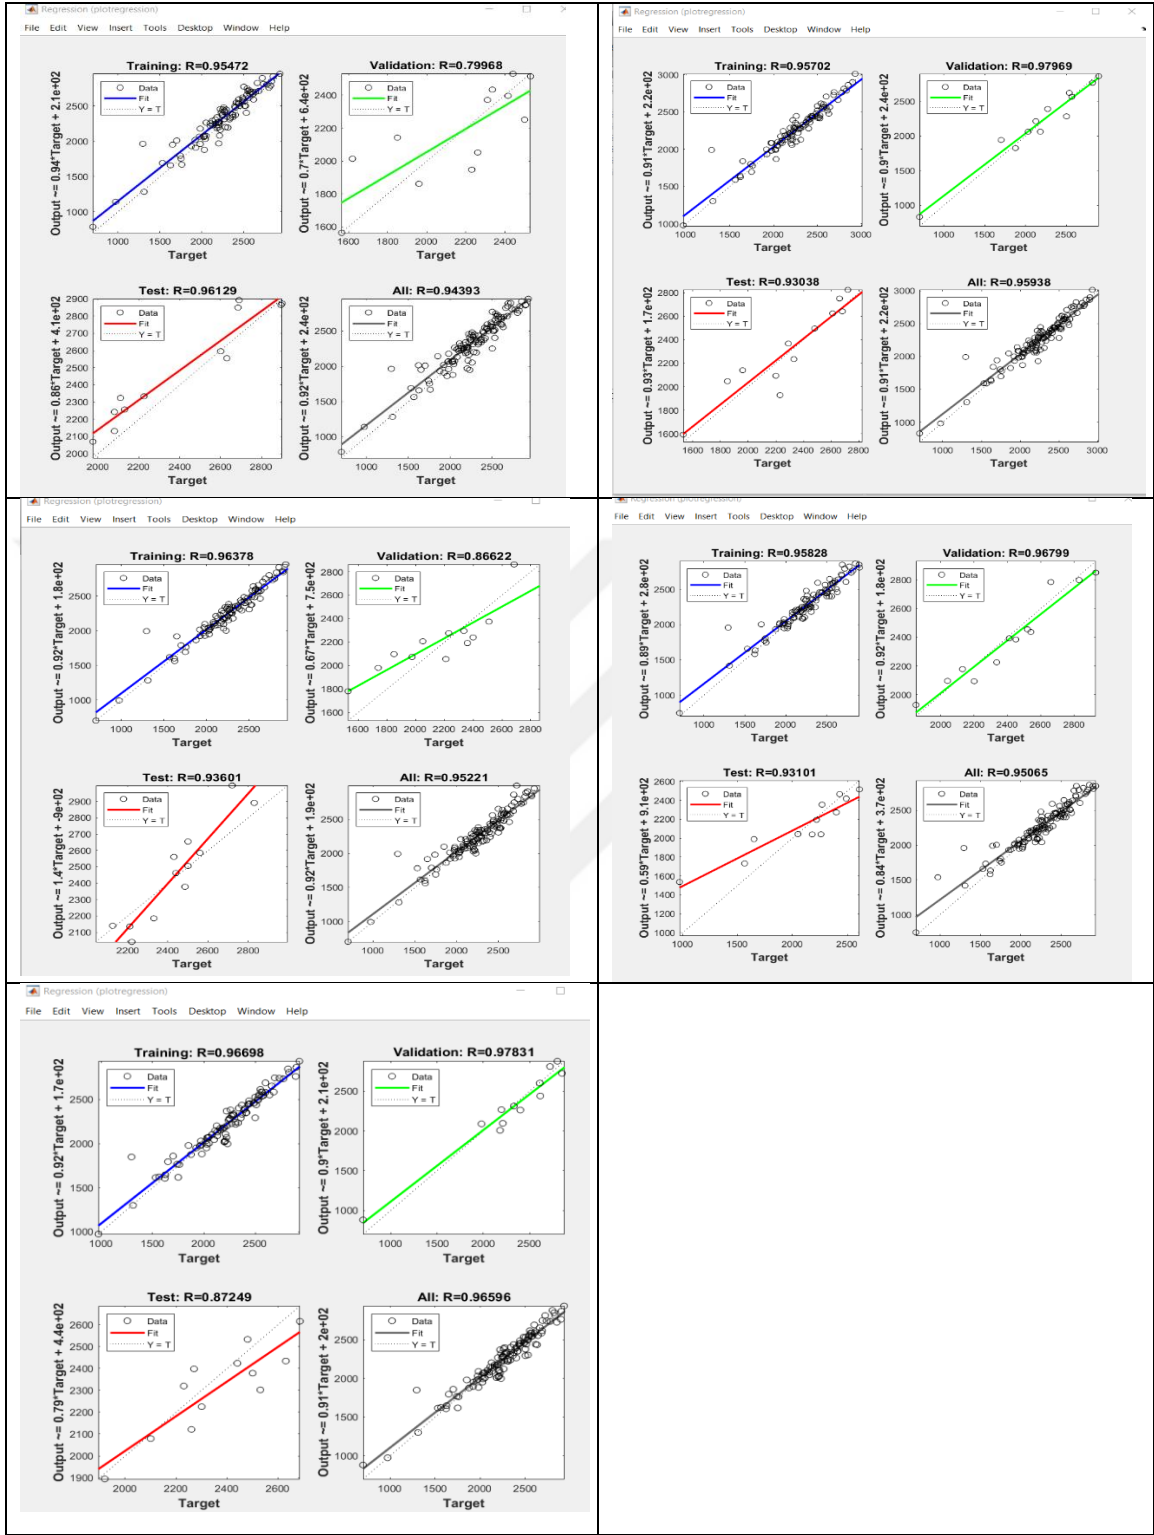
Şekil 4.17. On altıncı uygulamaya ait regresyon saçılım grafikleri



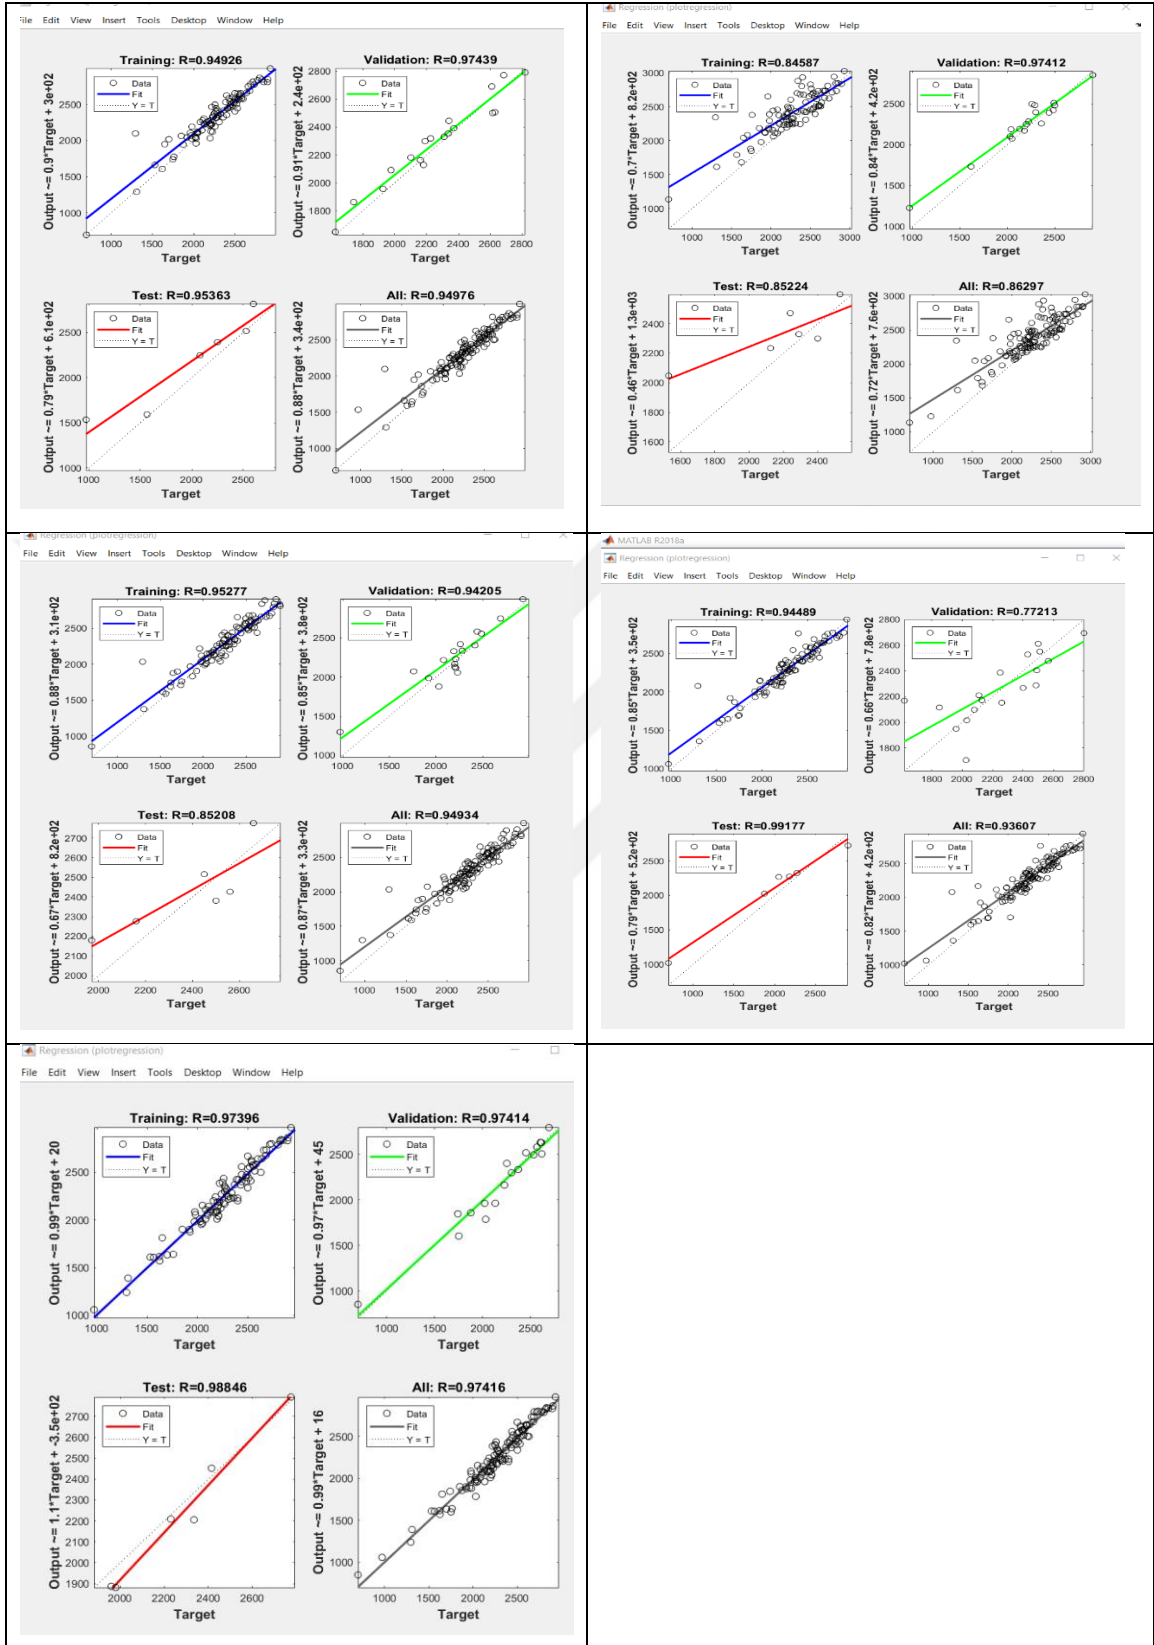
Şekil 4.18. On yedinci uygulamaya ait regresyon saçılım grafikleri



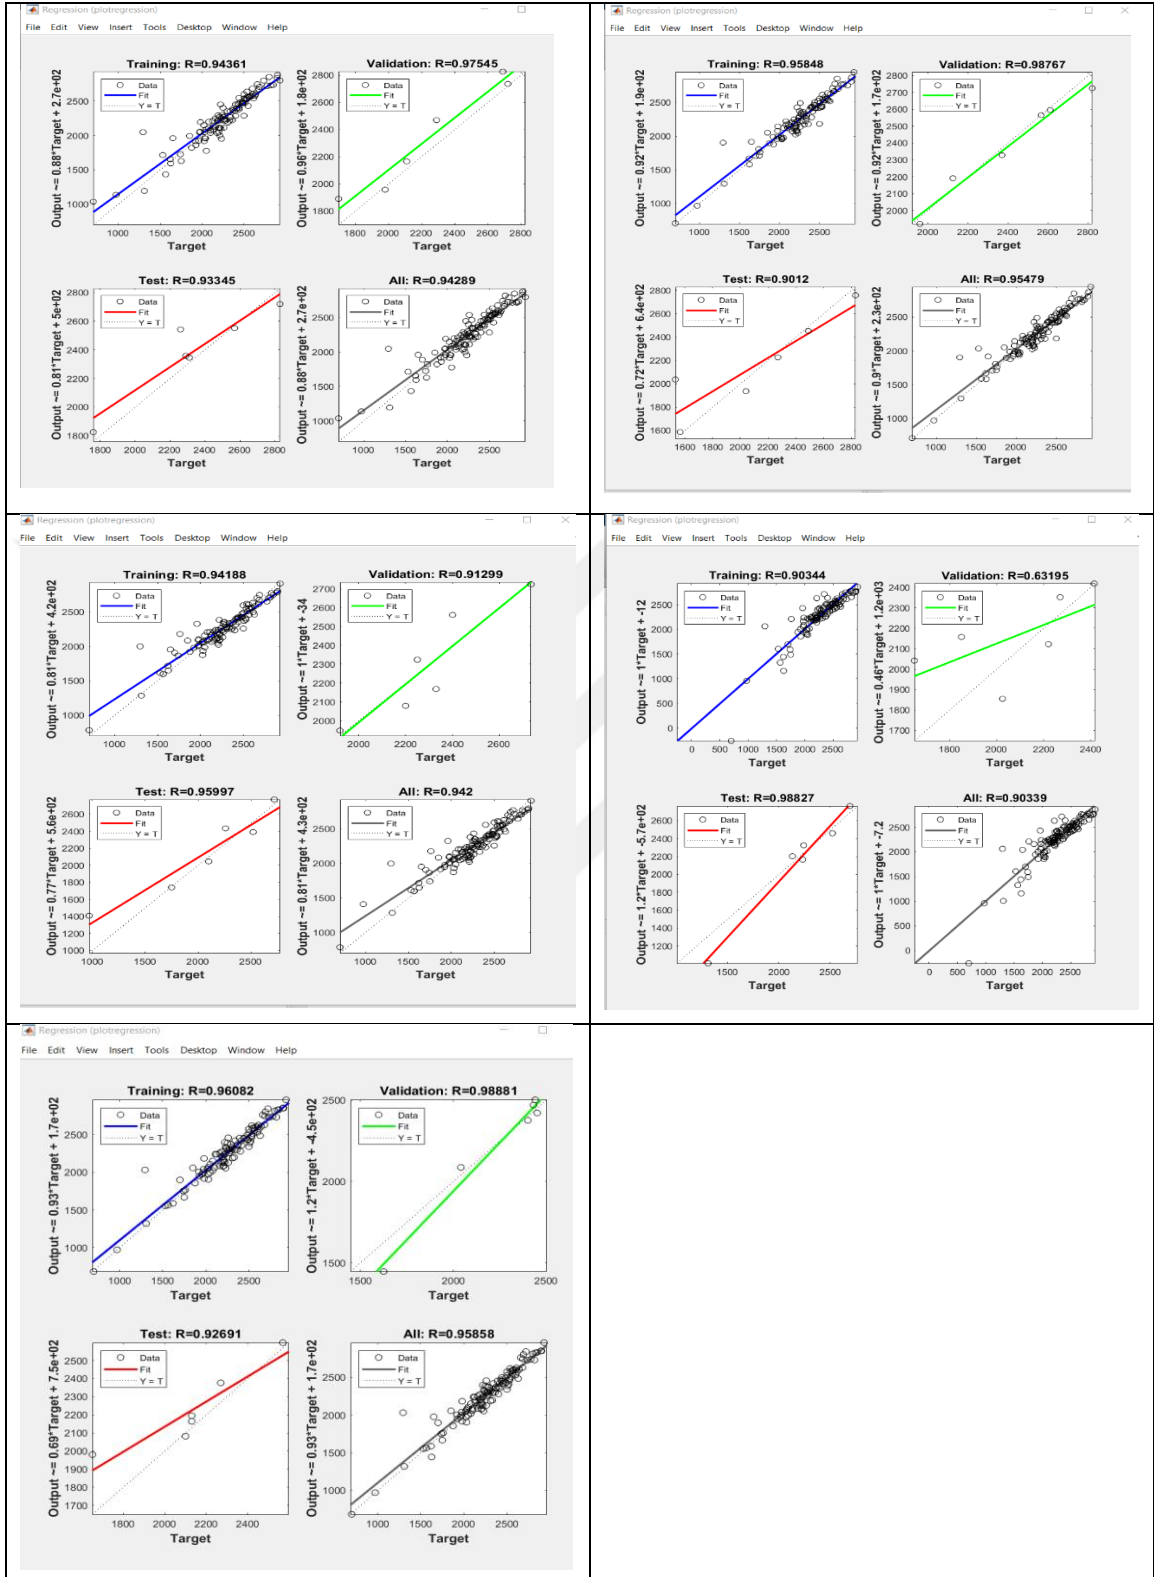
Şekil 4.19. On sekizinci uygulamaya ait regresyon saçılım grafikleri



Şekil 4.20. On dokuzuncu uygulamaya ait regresyon saçılım grafikleri



Şekil 4.21. Yirminci uygulamaya ait regresyon saçılım grafikleri

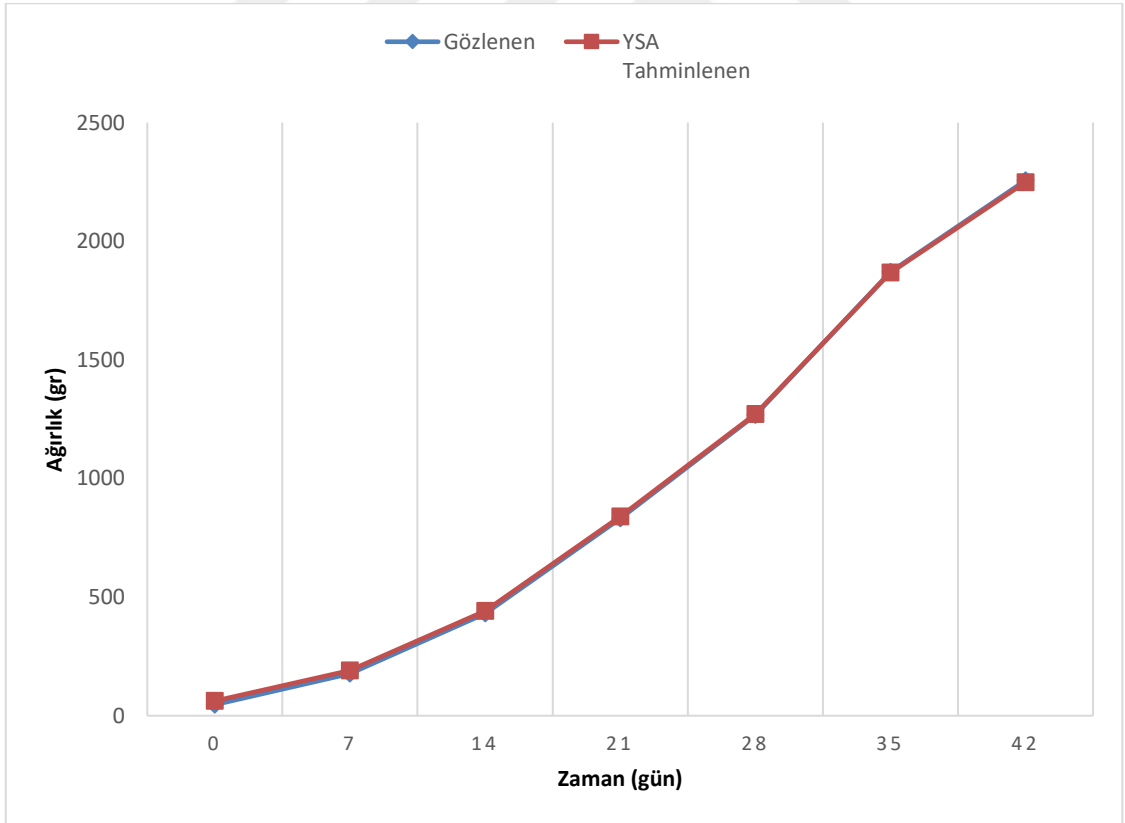


Şekil 4.22. Yirmi birinci uygulamaya ait regresyon saçılım grafikleri

Çizelge 4.6. Gözlenen ve YSA modeli ile tahminlenen haftalık CA değerleri ortalaması

Yaş (Gün)	Gözlenen (CA)	YSA Tahminlenen (CA)
0	46.6	62.1
7	177.1	191.3
14	430.5	442.2
21	831.9	839.6
28	1268.4	1271.7
35	1871.1	1868.4
42	2256.8	2250.2

Çizelge 4.6’da ve Şekil 4.23’te gözlenen ve YSA modelinden tahmin edilen CA değerlerinin değişimi verilmiştir. Gözlenen ve tahminlenen değerlerin birbirine yakın değerler olduğu tespit edilmiştir.



Şekil 4.23 YSA modeli ile tahminlenen ve gözlenen ortalama değerlerin değişimi

Şekil 4.23 incelendiğinde YSA analizi ile tahminlenen ve gözlenen değerlerin büyüme eğrilerinin örtüştüğü; Gompertz modelinde 21-42. günler arasında gözlenen değerlere ait eğriye göre olan sapmaların olmadığı görülmektedir. Gözlenen ve modellerden tahminlenen değerlere ait grafiklerde (Şekil 4.1, Şekil 4.23) eğrinin şeklinin sigmoid model ile benzer olduğu görülmektedir.

Çizelge 4.7’de tahmin edilen sonuçların tutarlılığını ölçmek için yaygın olarak kullanılan hata ölçütlerinden HKO yer almaktadır. HKO değerleri YSA modeli ile 5625 olarak tahmin edilmiştir (Çizelge 4.7). Tahmin edilen bu hata değeri ise ağın öğrenmeyi tamamladığı noktada, yaptığı en düşük hata değeridir. $R^2=0.98$, $OMYH=0.274$ ve $OMS= 0.5$ olarak tahmin edilmiştir.

Çizelge 4.7. YSA modele ait tahmin ölçütleri

	HKO	OMS	OMYH	R²
YSA	5625	0.5	0.274	0.98

Roush ve ark., (2006)’nın yapmış oldukları çalışmada bildirdikleri OMYH değeri YSA modeli için; 1.830-4.07’dir. Roush ve ark., (2006)’nın bildirdiği bu değerler modelden tahmin edilen değerden yüksek tespit edilmiştir. Roush ve ark., (2006)’nın etlik piliçlerde yapmış oldukları çalışmada bildirdikleri OMS değerleri 11.99-15.10’dur. Ahmadi ve ark., (2007)’nin YSA model için tahmin ettikleri OMYH değeri 5.56-9.11 ve OMS değerleri 0.98-1.55’tir. Tahminlenen modelden hesaplanan değerler bildirilen değerlerden düşük bulunmuştur.

Witt ve Witt (1992) ve Levis (1982) OMYH değerlerini kategorilere ayırdığında; %10’un altında tespit edilen modelleri "çok iyi", %10-%20 arasında tespit edilen modelleri "iyi", %20-%50 arasında tespit edilen modelleri "kabul edilebilir", %50’nin üzerinde tespit edilen modelleri ise "hatalı" olarak kabul etmişlerdir (Çuhadar ve ark., 2009). Çalışma sonuçlarına bakıldığında her iki modelden elde edilen OMYH değerlerinin çok iyi kategorisinde olduğu anlaşılmaktadır.

5. SONUÇ

Canlının büyümesindeki değişimin tahminlenmesinde matematiksel modeller büyük kolaylıklar sağlamaktadır. Canlının ağırlık ve vücut ölçülerindeki zamana bağlı değişiminin tahmini matematiksel modeller ile kolay şekilde yapılabilmektedir (Kocakaya, 2012).

Çalışmada Ross 308 etlik piliçlerinin büyüme eğrileri, büyümeyi en iyi açıklayan Gompertz modeli ile bu modele alternatif olabileceği düşünülen YSA modeli karşılaştırılmış olup R^2 'sı yüksek ve HKO, OMS ve OMYH değerleri düşük tahminlenen model en iyi model olarak dikkate alınmıştır.

YSA ve Gompertz modelinden elde edilen R^2 değerleri sırasıyla 0.98 ve 0.99 olarak; OMYH değerleri de 0.27 ve 0.17 olarak birbirine çok yakın tespit edilmiştir. OMS değerleri ise 0.5 ve 1.2 olarak tespit edilmiştir. YSA modelinden Gompertz modeline göre daha düşük OMS değeri tespit edilmiştir. HKO değerinde ise, YSA ve Gompertz modelinde sırasıyla 5625 ve 2950 olarak tespit edilmiştir. Genel olarak iki modelin karşılaştırılmasında kullanılan ölçütler birbirine yakın çıkmasına karşın Gompertz modelinin YSA'na göre daha iyi sonuçlar verdiği görülmüştür. Buna karşın hayvancılıkta önemli olan besi sonu veya son dönemlerinin canlı ağırlık tahminini YSA daha düşük farklarla daha iyi tahmin etmiştir.

Teknolojideki ilerleme ile birlikte son yıllarda YSA'ya olan ilgi artış göstermiştir. Birçok alanda yaygın olarak kullanılan YSA'nın tarım alanındaki kullanımı da giderek artmıştır. İnsan zekasına benzeyen YSA öğrenme ve hatırlama yönü ile tercih edilen bir yöntem haline gelmiştir. YSA ayrıca karmaşık ve doğrusal olmayan problemlere kolay çözüm üreten bir model olması sebebiyle sıklıkla tercih edilmektedir (Gevrekçi, ve ark., 2011).

İslah çalışmalarında ki başarıyı arttırabilmek için büyüme eğrilerinin kullanılması ve aynı zamanda seleksiyon çalışmalarında bir kriter olarak kullanılacak parametrelerin

belirlenmesi yetiştiricilikte önem arz etmektedir. Büyümenin başarılı bir şekilde açıklanabilmesi; üretimde verimin arttırılabilmesi için gerekli koşullardandır.

Gompertz modelinin büyümeyi açıklayıcılığının oldukça yüksek olmasının yanı sıra; YSA modelinin de kullanım kolaylığı vardır. Bütün verileri kullanarak tek bir model oluşturulmaktadır. Gompertz modelinde ise her hayvan için tek tek parametre tahmini yapıp bunların ortalaması alınmaktadır. Bu yöntemle zaman kaybı ve parametrelerin ortalaması alındığı için ham veri kaybı da olmaktadır

Bununla birlikte; YSA'nın ara katmanlar belirlenirken belirli bir yöntemin olmaması ayrıca ağı öğrenmek yerine ezberleme gerçekleştirilmesi gibi olumsuz yönleri de bulunmaktadır. Ancak YSA modeli ile tahmin yapmak bilgi ve tecrübe sonrasında oldukça kolay bir yöntem olarak tercih edilebilmektedir. Ayrıca YSA veri setindeki değişikliklerden etkilenmediğinden yeni bilgilerin ortaya çıktığı durumlarda veya değişikliklerin olduğu durumlarda dahi yeniden eğitilebilmektedirler.

Sonuç olarak YSA Gompertz modeline yakın sonuçlar verdiği için ayrıca veri kaybını önlediği, değişikliklere uyum sağlayabildiği ve yeniden eğitilebildiği için klasik büyüme eğrisi modellerine alternatif olarak kullanılabilir.

6. KAYNAKLAR

- Adenaike, A.S, Akpan, U., Udoh, J.E., Wheto, M., Durosaro, S.O., Sanda, A.J ve Ikeobi, C.O.N., 2017. Comparative evaluation of growth functions in three broiler strains of nigerian chickens. *Tropical Agricultural Science*. 40 (4), 611–620.
- Ahmadi, H., Mottaghitalab, M. ve Zadeh N.N., 2007. Group method of data handling-type neural network prediction of broiler performance based on dietary metabolizable energy, methionine and lysine. *The Journal of Applied Poultry Research* (16), 494-501.
- Aka, S., ve Akyüz., 2018. Yapay sinir ağırları analizi ile süreçlerinin iyileştirilmesi. *Ege Akademik Bakış Dergisi*, 18 (2), 261-271.
- Akbaş, Y., 1995. Büyüme eğrisi modellerinin karşılaştırılması. *Hayvansal Üretim Dergisi*, (36), 73-80.
- Akbaş, Y., 1996. Büyüme eğrisi parametreleri ve ıslah kriteri olarak kullanım olanakları. *Ege Üniversitesi Ziraat Fakültesi Dergisi*, 33 (1), 241-248.
- Akçapınar, H., ve Özbeyaz, C., 1999. *Hayvan Yetiştiriciliği Temel Bilgileri*. Kariyer Matbaacılık, Ankara.
- Akkaya, G., 2007. Yapay sinir ağırları ve tarım alanındaki uygulamaları. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 38 (2), 195-202.
- Aksu, N., ve Uçan, K., 2016. Zaman ve konum girdileri kullanılarak yapay sinir ağırlarıyla referans evapotranspirasyonun tahmin edilmesi. *El-Cezeri Fen ve Mühendislik Dergisi*, 3 (2), 204-221.
- Alpar, R., 2013. *Çok Değişkenli İstatistiksel Yöntemler*. Detay Yayıncılık. Bizim Büro ve Basım Evi. Ankara. 886.
- Anthony, N. B., Nestor K. E. ve Bacon W. L., 1986. Growth curves of japanese quail as modified by divergent selection for 4-week body weight. *Poultry Science* 65, 1825-1833.
- Anthony, N. B., Emmerson, D. A. ve Nestor, K. E., 1991a. Resarch note: influence of body weight selection on the growth curve of turkeys. *Poult Science* 70, 192.
- Anthony, N. B., Emmerson, D. A., Nestor, K. E. ve Bacon, W. L. 1991b. Comparison of growth curves of weight selectedpopulations of turkeys, quail and chickens. *Poultry Science* 70, 13.
- Aitkenhead, M. J., Dalgetty, I. A., Mullins, C. E., McDonald, A. J. S. ve Strachan, N. J.S., 2003. Weed and crop discrimination using image analysis and artificial intelligence methods. *Computers and Electronics in Agriculture*, 39 (3), 157-171.
- Ajakaiye, A. S., Adeyemo, A.B., Osofisan A.O. ve Olowu, A.P.A., 2006. Analysis of poultry birds production performance using artificial neural networks. *Asian Journal of Information Technology*, 5 (5), 522-527.
- Asilkan, Ö., ve Irmak, Sezgin., 2009. İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağırları ile tahmin edilmesi. *Süleymen Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 14 (2), 375-391.
- Bathaei, S.S. ve Leroy, P.L., 1996. Growth and mature weight of mehraban iranian fat-tailed sheep. *Small Ruminant Research*, 22 (20), 155-162.
- Bhadula, S.K. ve Bhat, P.N., 1980. Note on growth curves in sheep. *Indian Journal of Animal Science* 50 (11), 1001-1003.

- Brody, S., 1945. Bioenergetics and Growth. Reinhold Publishing Corp., Newyork.
- Çayıroğlu, İ., 2003. İleri Algoritma Analizi Ders Notu. Karabük Üniversitesi Mühendislik Fakültesi Karabük. 13.
- Çelikoğlu, K., 2012. Pırlak Kuzularında Büyüme Eğrilerini Etkileyen Genetik ve Çevresel Faktörlerin Belirlenmesi ve Eğri Parametreleri Yönünden Baba Koçların Değerlendirilmesi. (Doktora Tezi), Zootekni Anabilim Dalı, Afyonkarahisar.
- Çelikoğlu, K. ve Tekerli, M. 2014. Pırlak kuzularında büyüme eğrilerini etkileyen genetik ve çevresel faktörlerin belirlenmesi ve eğri parametreleri yönünden baba koçların değerlendirilmesi. I. Bazı çevresel faktörlerin canlı ağırlığa ilişkin büyüme eğrilerine etkileri. Afyon Kocatepe Üniversitesi., Veterinerlik Fakültesi, Zootekni Anabilim Dalı, Lalahan Hayvan Araştırma Enstitüsü Dergisi, 54 (1), 8-14.
- Çıtak, B., Kesici, T., Eliçin, A. ve Kocabaş, Z. 1998. Keçilerde Değişik Karakterler Bakımından Büyüme Eğrileri. II. Ulusal Zootekni Bilim Kongresi, Bursa.
- Çolak, C., Orman, M.N. ve Ertuğrul, O., 2006. Simental x Güney Anadolu Kırmızısı sığına ait beden ölçüleri için basit doğrusal ve lojistik büyüme modeli. Ankara Üniversitesi Veterinerlik Fakültesi Dergisi, 53, 195-199.
- Çuhadar, M. ve Kayacan, C., 2005. Yapay sinir ağları kullanılarak konaklama işletmelerinde doluluk oranı tahmini. Türkiye'deki konaklama işletmeleri üzerine bir deneme. Turizm Araştırmaları Dergisi, cilt 16(1), 24-30.
- Çuhadar, M., Güngör, İ. ve Göksu, A., 2009. Turizm talebinin yapay sinir ağları ile tahmini ve zaman serisi yöntemleri ile karşılaştırmalı analizi: Antalya iline yönelik bir uygulama. Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14 (1), 99-114.
- Doğan, İ., 2003. Kuzularda büyümenin çok boyutlu ölçekleme yöntemi ile değerlendirilmesi. Uludag University Journal of The Faculty of Veterinary Medicine 22 (1-3), 33-37.
- Efe, E., 1990. Büyüme Eğrileri. (Doktora Tezi), Fen Bilimleri Enstitüsü. Zootekni Anabilim Dalı, Adana.
- Eleroğlu, H., Bircan, H., Yıldırım, A. ve Kılıç, F., 2016. Ticari etlik piliçlerde büyüme eğrilerinin doğrusal olmayan modeller kullanılarak karşılaştırılması. Tavukçuluk Araştırma Dergisi 13 (2), 12-16.
- Elmas, Ç., 2003. Yapay Sinir Ağları, Birinci Baskı, Ankara: Seçkin Yayıncılık.
- Elizondo D., G. Hoogenboom ve Mc Clendon R.W., 1994a. Development of a neural network model to predict daily solar radiation. Agricultural and Forest Meteorology, 71, 115-132.
- Elizondo D. A., Mc Clendon R.W. ve Hoogenboom G., 1994b. Neural Network Models For Predicting Flowering and Physiological Maturity of Soybean, Transactions of The ASAE, . 37 (3), 981-988.
- Emsen, E., ve Köyceyiz, F., 2004. İvesi ve Morkaraman dişi kuzularında büyüme eğrilerinin karşılaştırılması. 4.Ulusal Zootekni Bilim Kongresi, 01-03 Eylül 2004. Isparta.
- Friggens, N. C., Shanks, M., Kyriazakis, I., Oldham, J.D. ve Mc Clelland, T.H. 1997. The growth and development of nine european sheep breeds. I. british reeds: bscottish blackface welsh mountain and shetland. Animal Science 65 (3), 409-426, 68.

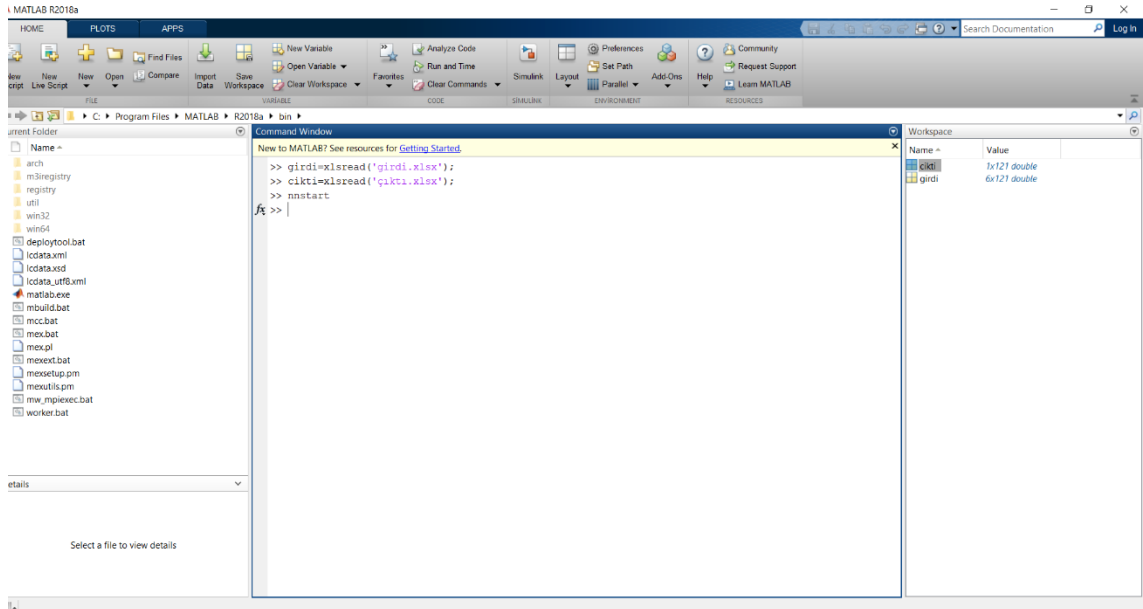
- Gevrekçi, Y., Yeğenoğlu, E.D., Akbaş, Y. ve Sesli M., 2011. Yapay sinir ağlarının tarımsal alanda kullanımı. Ege Üniversitesi Ziraat Fakültesi Dergisi, 48(1), 71-76.
- Gonzales, M.A., Herra, G. M., Vicente, B.D.J. ve Radera F.J.M. 1992. A Study on Growth to 98 Days of Age in Spanish Black Mountain Kids. Terra- Arida. 11, 45-49. Proceedings, International Symposium on Goat Breeding in Arid Zones, Coquimbo, Chile, 23-26.
- Haykin, S., 1999. Neural networks a Comprehensive Foundation. Prentice Hall International, Inc. McMaster Univ. USA. 1-50, 117-256.
- Hwang, j.T.G. ve Ding, A.A. 1997. Prediction Intervals For Artificial Neural Networks. Journal of the American Statistical Association, 92 (438), 748-757.
- Kaastra, I. ve Boyd, M., 1996. Designing a neural network for forecasting financial and econometric time series, neurocomputing. Elsevier Journals. 10, 215-236.
- Karadavut, U., Şahin, A., Taşkın, A. ve Akıllı, A., 2014. Japon bıldırcınlarında (Coturnix Coturnix Japonica) büyümenin tek ve çok aşamalı analizlerinin seleksiyon kriterleri olarak kullanılabilme olanaklarının araştırılması. Türk Tarım ve Doğa Bilimleri Dergisi, 1(4), 539-546.
- Kirby, Y. K., Mc New, R. W., Kirby, J. D. ve Wideman, R. F., 1997. Evaluation of logistic versus linear regression models for predicting pulmonary hypertension syndrome (ascites) using cold exposure or pulmonary artery clamp models in broilers. Poultry Science 76, 392-399.
- Kocakaya, S., 2012. Japon bıldırcınlarında büyüme eğrisinin farklı modellerle belirlenmesi. (Yüksek Lisans Tezi), Namık Kemal Üniversitesi Fen Bilimleri Enstitüsü. Tekirdağ.
- Köyceyiz, F., 2003. İvesi ve Morkaraman Kuzularında Değişik Vücut Ölçüleri Bakımından Büyüme Eğrileri. (Yüksek Lisans Tezi), Atatürk Üniversitesi Fen Bilimleri Enstitüsü. Erzurum.
- Kubat, C., 2015. Matlab Yapay Zeka ve Mühendislik Uygulamaları. Deniz Ofset Matbaacılık. İstanbul. 762.
- Kuyucu, Y. E., 2012. Lojistik Regresyon Analizi (LRA), Yapay Sinir Ağları (YSA) ve Sınıflandırma ve Regresyon Ağaçları (C&RT) Yöntemlerinin Karşılaştırılması ve Tıp Alanında Bir Uygulama. (Yüksek Lisans Tezi), GOP Üniversitesi Sağlık Bilimleri Enstitüsü. Tokat.
- Kuzu, E., ve Elçin, A., 2002. Kilis Keçisi Oğlaklarında değişik vücut ölçüleri bakımından büyüme eğrileri. Tarım Bilimleri Dergisi. 8 (3), 242-247.
- Lambe, N.R., Navajas, E.A., Sımm, G. ve Bunger, L., 2006. A Genetics investigation of various growth models to describe growth of lambs of to contrasting breeds. Journal of Animal Science 84, 2642-2654.
- Levis, C.D., 1982. Industrial and Business Forecasting Methods, Butterworths Publishing. London.
- Michalczuk, M., Damaziak, K. ve Goryl, A., 2016. Sigmoid models for the growth curvesin medium-growing meat type chickens, raised under semi-confined conditions. Ann. Anim. Science, 16 (1), 65-77. Poland.
- Mohammed, F.A., 2015. Comparison of three nonlinear functions for describing chicken growth curves. Science Agriculturae, 9 (3), 120-123.
- Moshou, D., Vrinds, E., Ketelaere, B. D., Baerdemaeker, J. D ve Ramon, H., 2001. A neural network based plant classifier. Computers and Electronics in Agriculture, 31 (1), 5-16.

- Moshou, D., Bravo, C., West, J., Wahlen, S., McCarney, A. ve Ramon, H., 2004. Automatic detection of 'yellow rust' in wheat using reflectance measurements and neural networks. *Computers and Electronics in Agriculture*, 44 (3), 173-188.
- Mukundan, G., Khan, B.U. ve Bhat, P.B. 1982. Note on growth curve in malabari goats and saanen half- breeds. *Indian J. of Anim. Science*, 52 (11),1112-1113.
- Mukundan, G., Bhat, P.N. ve Khan, B.U. 1984. Factors affecting monthly body weight gains in malabari goats and their saanen halfbreeds. *Indian Journal of Animal Science* 54 (8), 779-781.
- Murthy, V.S., Rao, M.V.K. ve Rao, C.V., 1972. Trend of Growth in Nellore and Mandya Lambs. *Wool and Woolens of India*. 32-35.
- Nabiyev, V. V., 2003. *Yapay Zeka*. Birinci Baskı, Ankara. Seçkin Yayıncılık. 710.
- Narınç, D., Aksoy, T., Çürek, D.İ. ve Karaman, E. 2007. Farklı gelişme hızına sahip etlik piliçlerde büyümenin analizi. *Hayvancılık Araştırma Dergisi*, 17 (2),1-8.
- Narınç, D., Aksoy, T., Karaman, E. ve Karabağ, K., 2009. Japon bıldırcınlarında yüksek canlı ağırlık yönünde uygulanan seleksiyonun büyüme parametreleri üzerine etkisi. *Akdeniz Üniversitesi Ziraat Fakültesi Dergisi*, 22 (2), 149-156.
- Öztemel, E., 2003. *Yapay Sinir Ağları*. Birinci Baskı, İstanbul. Papatya Yayıncılık. 231.
- Özveren, U., 2006. *Pem Yakıt Hücrelerinin Yapay Sinir Ağları İle Modellenmesi*. (Yayınlanmamış Yüksek Lisans Tezi), Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü. İstanbul.
- Park, S. J., Hwang, C. S. ve Vlek, P. L.G., 2005. Comparison of adaptive techniques to predict crop yield response under varying soil and land management conditions. *Agricultural Systems*, 85 (1), 59-81.
- Parmar, R.S., McClendon, R.W., Hoogenboom G., Blankenship, P.D., Cole, R.J. ve Dorner, J.W., 1997. Estimation of Aflatoxin Contamination in Preharvest Peanuts Using Neural Networks. *Transactions of the ASAE*, 40 (3), 809-813.
- Patel, V. C., McClendon R. W. ve Goodrum J. W., 1998. Development and evaluation of an expert system for egg sorting. *Computers and Electronics in Agriculture*, 20 (2), 97-116.
- Roush, W. B., W.A Dozier ve S.L. Branton 2006. Comparison of gompertz and neural network models of broiler growth. *Poultry Science* 85 (4), 794 – 797.
- Roush, W.B., Y.K. Kirby and T.L. Cravener ve R.F. Wideman. 1996. Artificial neural network prediction of ascites in broilers. *Poultry Science* 75 (12), 1479-1487.
- Salle, C.T.P., Guahyba, A.S., Wald, V.B., Silva, A.B., Salle F.O. ve Nascimento V.P., 2003. Use of artificial neural networks to estimate production parameters of broilers breeders in the production phase. *br. Poultry Science* 44 (2), 211–217.
- Sharma, V., Negi, S. C., Rudra, R. P. ve Yang, S., 2003. Neural networks for predicting nitrate-nitrogen in drainage water. *Agricultural Water Management*, 63 (3), 169-183.
- Soysal, M.I., Gürcan, E.K., Genç, S. ve Aksel, M., 2015. Mandalarda büyüme eğrisinin farklı büyüme modelleri ile karşılaştırılması. *Tekirdağ Ziraat Fakültesi Dergisi*, 12 (3).
- Şahin, A., Ulutaş, Z., Karadavut, U., Yıldırım, A. ve Arslan, S., 2014. Anadolu mandası malaklarında büyüme eğrisinin çeşitli doğrusal olmayan modeller kullanılarak karşılaştırılması. *Kafkas Üniversitesi Veterinerlik Fakültesi Dergisi*, 20 (3), 357-362.

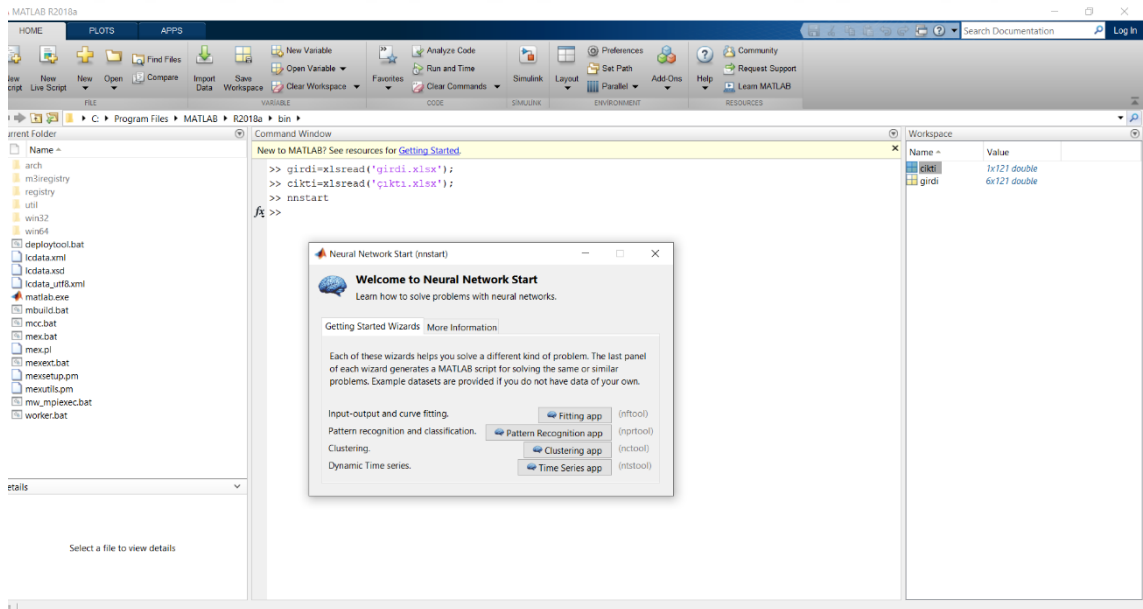
- Şekeroğlu, A., Tahtalı, Y., Sarıca, M., Gülay, M.Ş., Abacı, S.H. ve Duman, Mustafa., 2013. Farklı yerleşim sıklıklarındaki etlik piliçlerin büyüme eğrilerinin gompertz modeli ile karşılaştırılması. *Kafkas Üniversitesi Veterinerlik Fakültesi Dergisi*, 19 (4), 669-672.
- Takma, Ç., Atıl, H. ve Aksakal, V., 2012. Çoklu doğrusal regresyon ve yapay sinir ağı modellerinin laktasyon süt verimlerine uyum yeteneklerinin karşılaştırılması. *Kafkas Üniversitesi Veterinerlik Fakültesi Dergisi*, 18 (6), 941-944.
- Taner, A., Tekgüler, A., Sauk, H. ve Demirel, B., 2012. Yulaf çeşitlerinin yapay sinir ağları kullanılarak sınıflandırılması. 27. Tarımsal Mekanizasyon Ulusal Kongresi, 5-7 Eylül, 2012, Samsun.
- Taner, A., Tekgüler, A. ve Sauk, H., 2015. Yapay sinir ağları ile makarnalık buğday çeşitlerinin sınıflandırılması. *Anadolu Tarım Bilimleri Dergisi*. 30, 51-59.
- Tekel, N., 1998. İvesi Kuzularının Süt Emme ve Mer'alanma Dönemlerinde Büyüme Eğrilerinin Çizilmesi Üzerine Bir Araştırma. (Yüksek Lisans Tezi), Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Topal, M. ve Bölükbaşı, Ş.C., 2008. Comparison of nonlinear growth curve models in broiler chickens. *Journal of Applied Animal Research*. 34, 149-152
- Tozkan, S., 2004. Yapay Sinir Ağları. (Bitirme Ödevi), Fırat Üniversitesi Mühendislik Fakültesi Elektrik Elektronik Mühendisliği Bölümü. Elazığ.
- Witt, S.F. ve Witt, C., 1992. *Modeling and Forecasting Demand in Tourism*, Academic Pres, London. 195.
- Williams D.B. ve Zazueta F.S., 1996. Solar Radiation Estimation via Neural Network. *Proceedings of 6. Intern. Conf. on Computers in Agriculture, Mexico*. 1143-1149.
- Yakupoğlu, Ç., 1999. Etlik piliçlerde büyüme eğrilerinin karşılaştırılması. (Yüksek Lisans Tezi), Ege Üniversitesi Fen Bilimleri Enstitüsü, İzmir.
- Yamaki, K. ve Sagae Y., 1991. Growth and genetic parameters in sheep. *Animal Science and Technology*, 62 (10), 925-931.
- Yang, C.C., Prasher, S. O., Landry, J. A. ve Ramaswamy, H. S., 2003. Development of a herbicide application map using artificial neural networks and fuzzy logic. *Agricultural Systems*, 76 (2), 561-574.
- Yazıcı, A.C., Ögüş, E., Ankaralı, S., Canan, S., Ankaralı, H., ve Akkuş, Z., 2007. Yapay sinir ağlarına genel bakış. *Türkiye Klinikleri Dergisi*, 27, 65-71.
- Yavuz, S. ve Deveci M., 2013. İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187.
- Yeni, H. 2003. Genç Ankara Keçilerinde Büyüme Fonksiyonunun Belirlenmesi. (Yüksek Lisans Tezi), Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Yıldız, G., Soysal, M.İ., ve Gürcan, E. K., 2009. Tekirdağ ilinde yetiştirilen Karacabey merinosu kıvrıkcık melezi kuzularda büyüme eğrilerinin farklı modellerle belirlenmesi. *Tekirdağ Ziraat Fakültesi Dergisi*, 6 (1), 11-19.
- Yılmaz, B., 2015. Akarçay Havzasında Çözünmüş Oksijen Değerlerinin Yapay Sinir Ağları İle Belirlenmesi. (Uzmanlık Tezi), Orman ve Su İşleri Bakanlığı Su Yönetimi Genel Müdürlüğü, Ankara.

7. EKLER

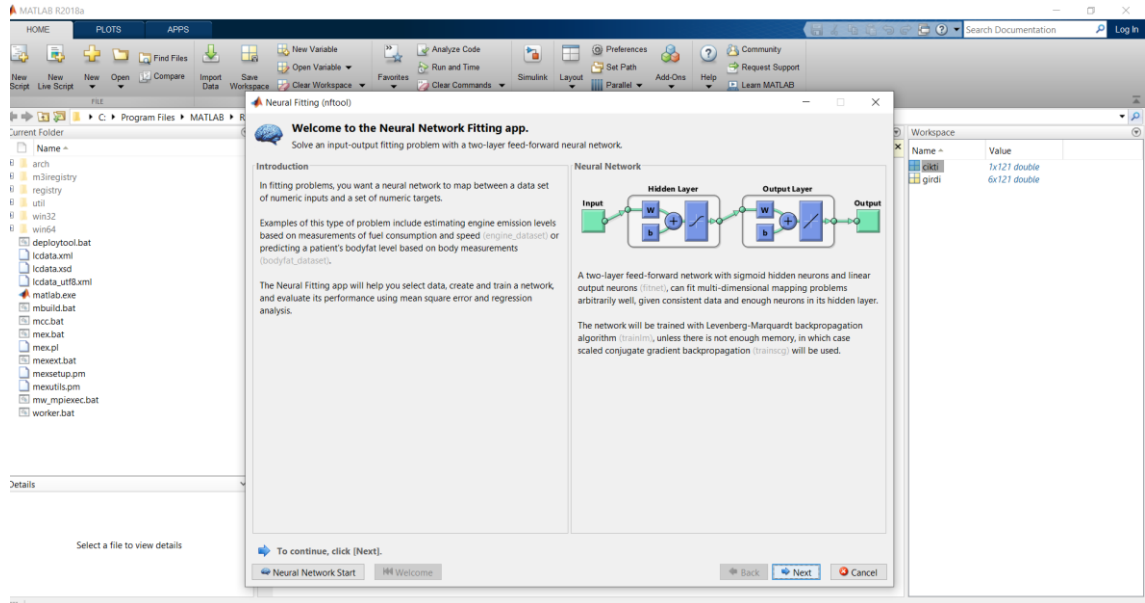
7.1. Matlab Programına Ait Ekran Görüntüleri



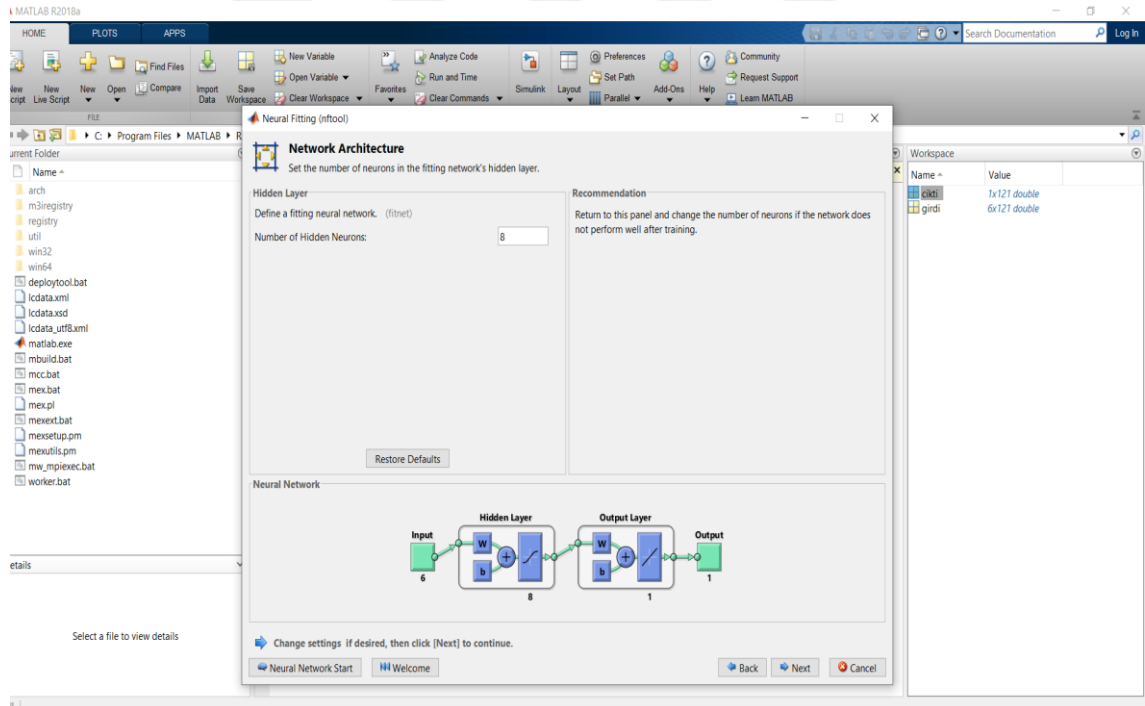
Resim 1. Matlab Programı Başlatma Komut Ekranı(nnstart)



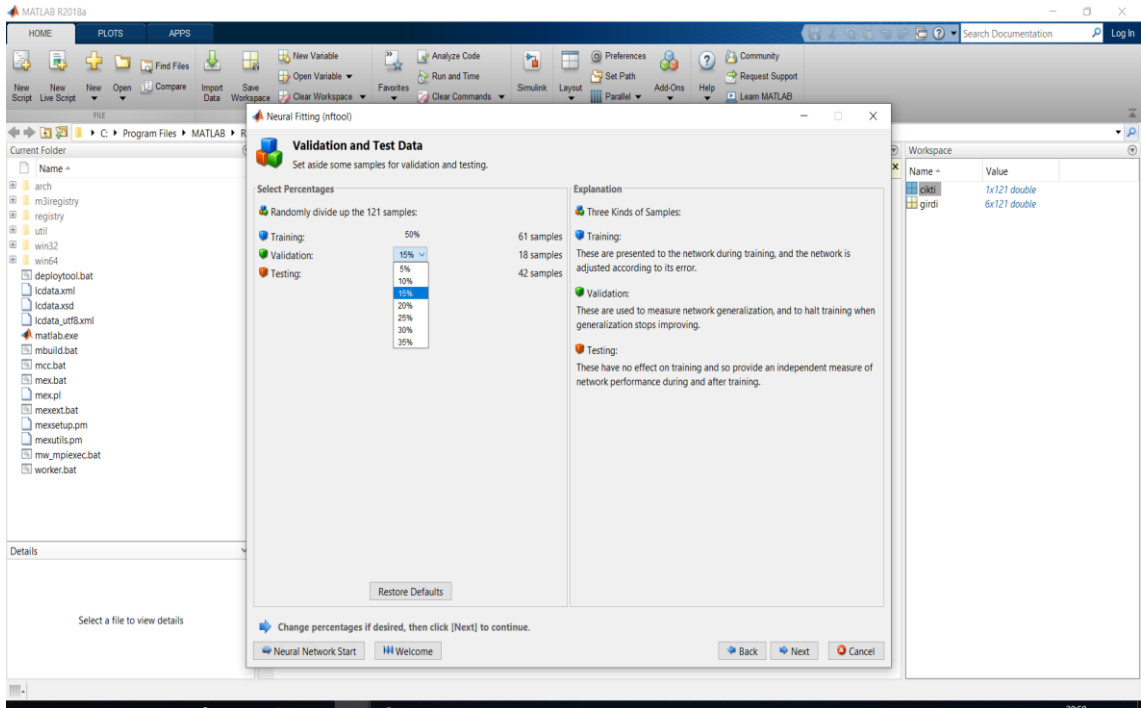
Resim 2. YSA Başlangıç Ekranı (Neural Network Start)



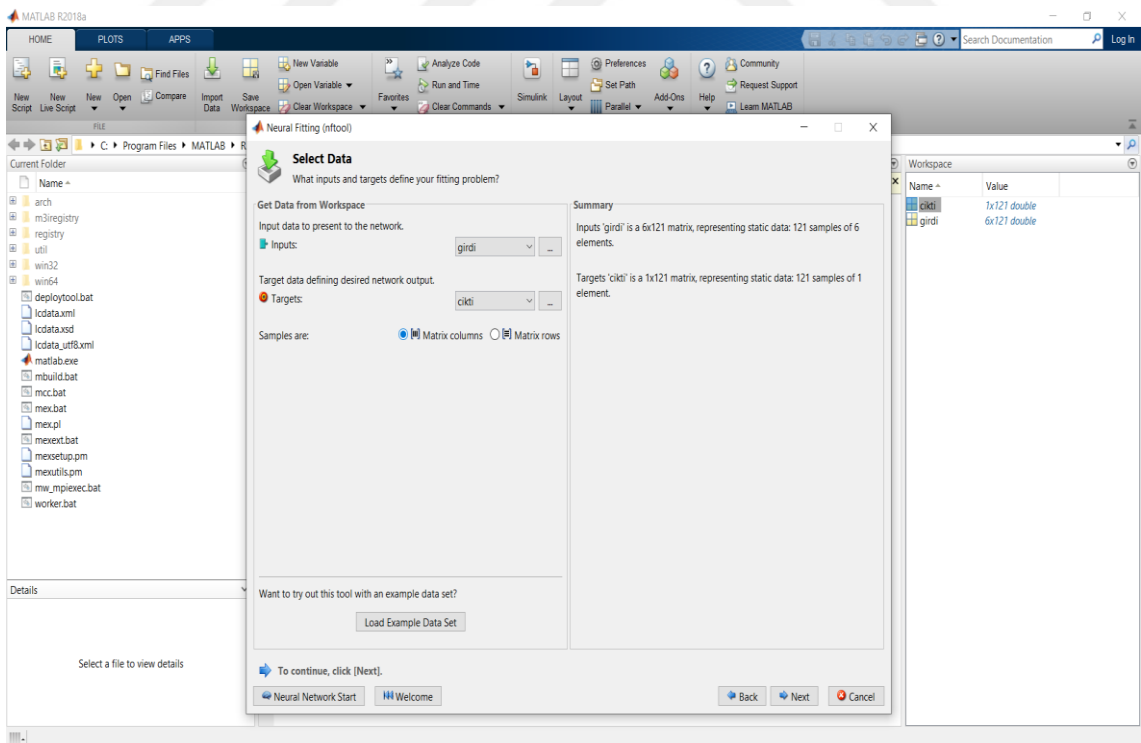
Resim 3. YSA Eğri Uydurma Aracı (Neural Fitting Tool)(nftool)



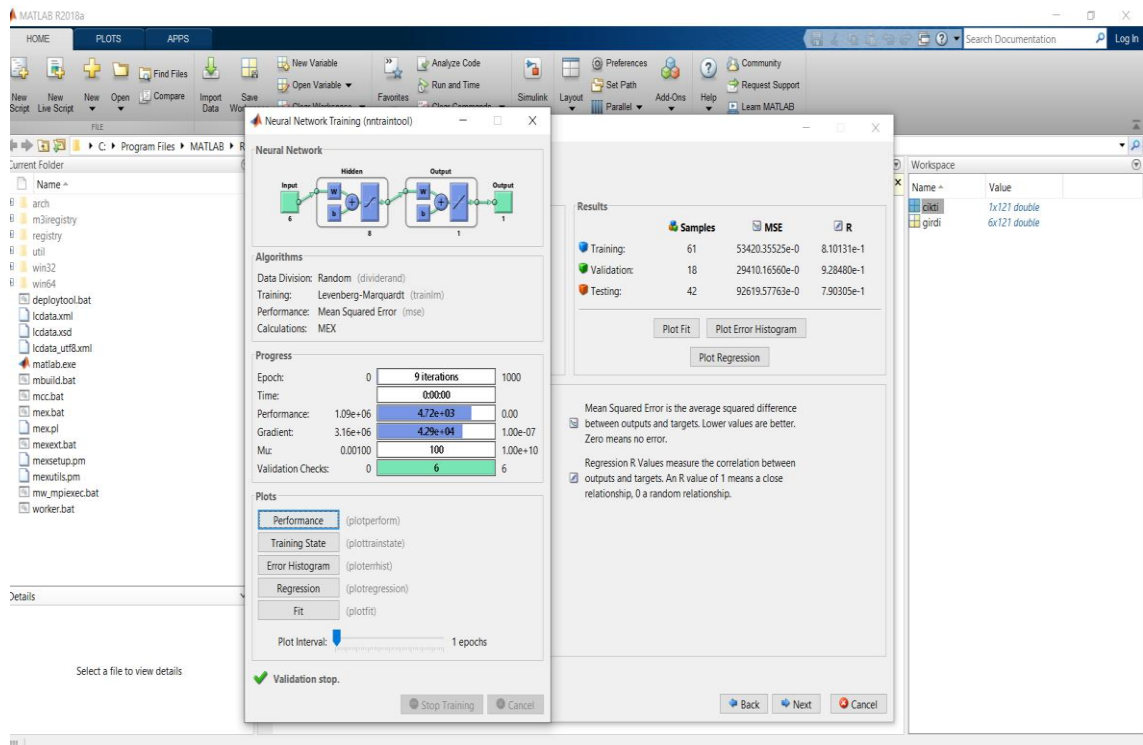
Resim 4. YSA Eğitimi Ara Katman



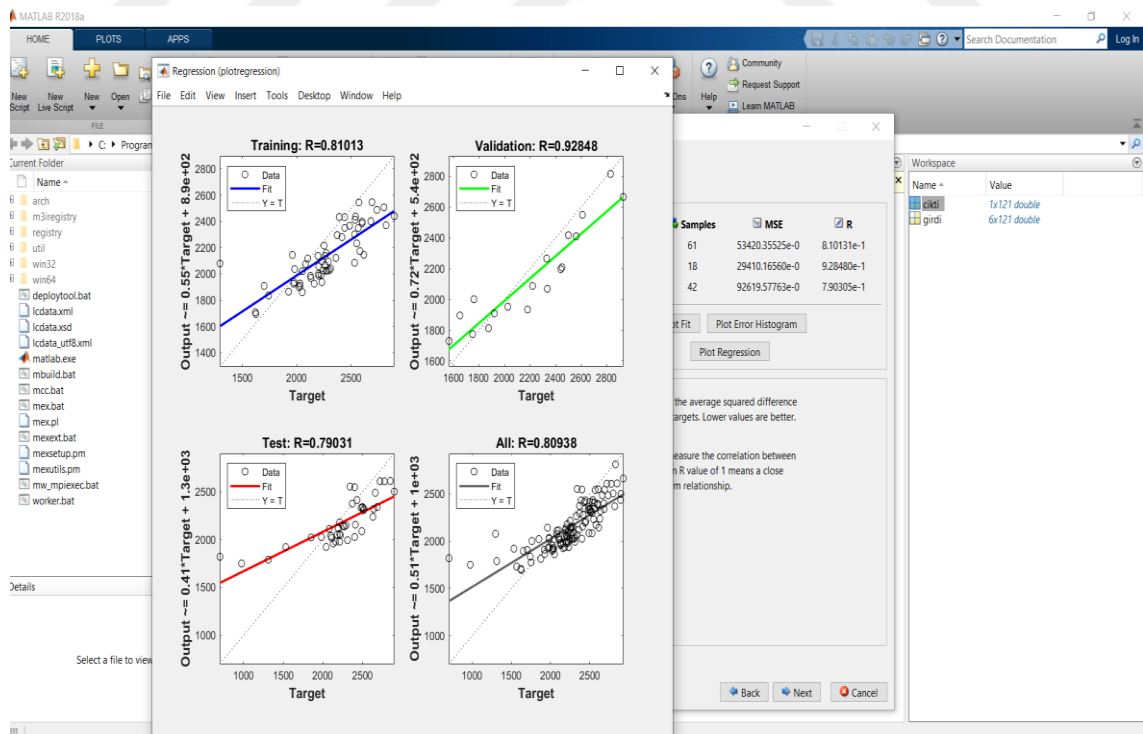
Resim 5. YSA Eğitim Test



Resim 6. YSA Matrix



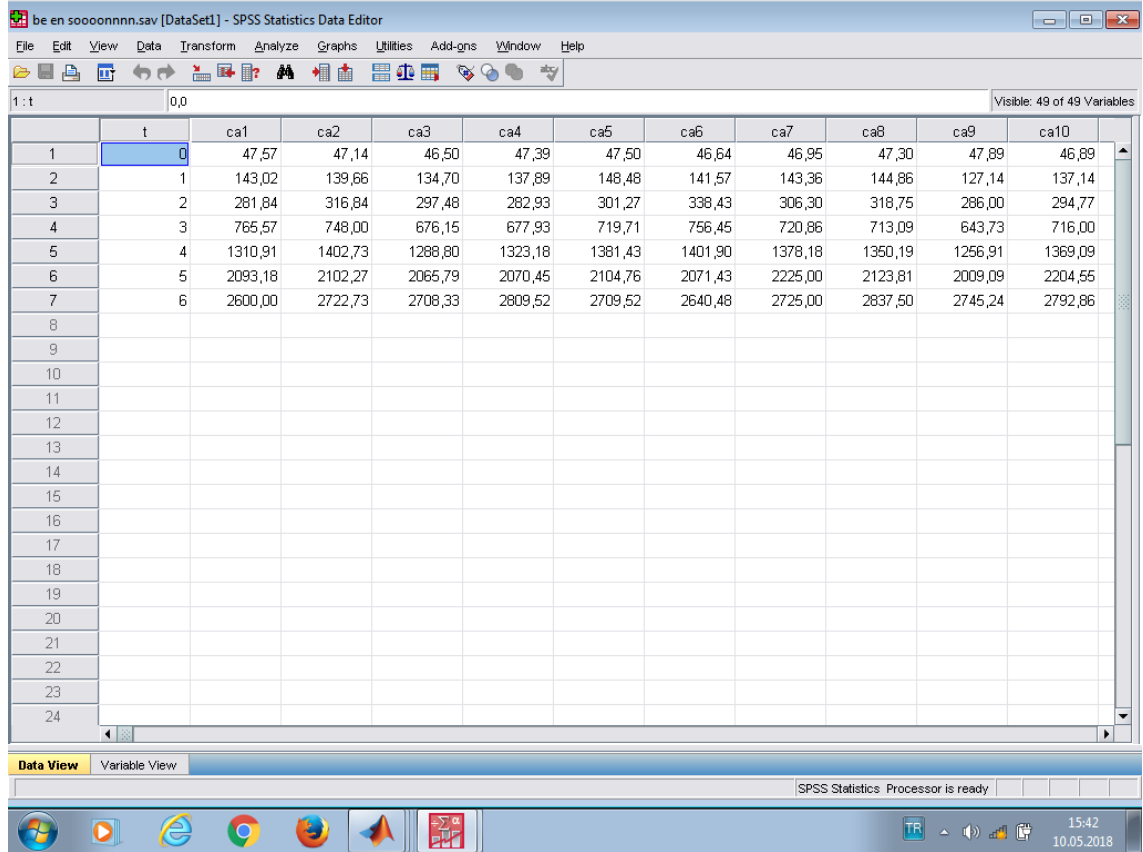
Resim 7. YSA Eğitimi (Neural Network Training) (ntraintool)



Resim 8. YSA Eğitim Regresyonu (Neural Network Training Regression) (plotregression)

7.2. SPSS(17.0) Programına Ait Ekran Görüntüleri

Büyüme eğrisi yöntemlerinden olan Gompertz yönteminin SPSS programında analiz görüntüleri aşağıda verilmiştir. Resim 7. de farklı zamanlarda alınan ağırlık ölçümlerinin SPSS programında data view ekranına girişi verilmiştir. Örneğin; t zamanlardaki birinci canlının ölçümü ca1 olarak ifade edilmiştir. Bu şekilde tüm veriler kayıt edilir.



	t	ca1	ca2	ca3	ca4	ca5	ca6	ca7	ca8	ca9	ca10
1	0	47,57	47,14	46,50	47,39	47,50	46,64	46,95	47,30	47,89	46,89
2	1	143,02	139,66	134,70	137,89	148,48	141,57	143,36	144,86	127,14	137,14
3	2	281,84	316,84	297,48	282,93	301,27	338,43	306,30	318,75	286,00	294,77
4	3	765,57	748,00	676,15	677,93	719,71	756,45	720,86	713,09	643,73	716,00
5	4	1310,91	1402,73	1288,80	1323,18	1381,43	1401,90	1378,18	1350,19	1256,91	1369,09
6	5	2093,18	2102,27	2065,79	2070,45	2104,76	2071,43	2225,00	2123,81	2009,09	2204,55
7	6	2600,00	2722,73	2708,33	2809,52	2709,52	2640,48	2725,00	2837,50	2745,24	2792,86
8											
9											
10											
11											
12											
13											
14											
15											
16											
17											
18											
19											
20											
21											
22											
23											
24											

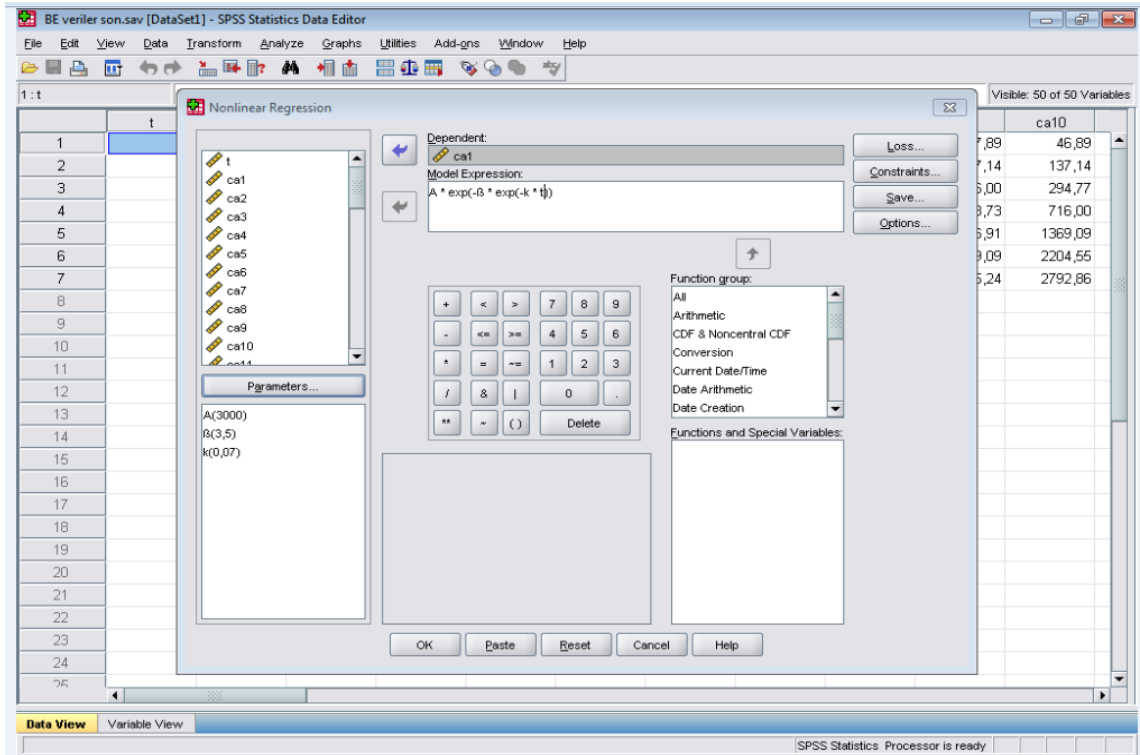
Resim 10. Veri giriş ekranı

	Name	Type	Width	Decimals	Label	Values	Missing	Columns	Align	Measure
1	t	Numeric	8	0		None	None	8	Right	Scale
2	ca1	Numeric	8	2		None	None	8	Right	Scale
3	ca2	Numeric	8	2		None	None	8	Right	Scale
4	ca3	Numeric	8	2		None	None	8	Right	Scale
5	ca4	Numeric	8	2		None	None	8	Right	Scale
6	ca5	Numeric	8	2		None	None	8	Right	Scale
7	ca6	Numeric	8	2		None	None	8	Right	Scale
8	ca7	Numeric	8	2		None	None	8	Right	Scale
9	ca8	Numeric	8	2		None	None	8	Right	Scale
10	ca9	Numeric	8	2		None	None	8	Right	Scale
11	ca10	Numeric	8	2		None	None	8	Right	Scale
12	ca11	Numeric	8	2		None	None	8	Right	Scale
13	ca12	Numeric	8	2		None	None	8	Right	Scale
14	ca13	Numeric	8	2		None	None	8	Right	Scale
15	ca14	Numeric	8	2		None	None	8	Right	Scale
16	ca15	Numeric	8	2		None	None	8	Right	Scale
17	ca16	Numeric	8	2		None	None	8	Right	Scale
18	ca17	Numeric	8	2		None	None	8	Right	Scale
19	ca18	Numeric	8	2		None	None	8	Right	Scale
20	ca19	Numeric	8	2		None	None	8	Right	Scale
21	ca20	Numeric	8	2		None	None	8	Right	Scale
22	ca21	Numeric	8	2		None	None	8	Right	Scale
23	ca22	Numeric	8	2		None	None	8	Right	Scale
24	ca23	Numeric	8	2		None	None	8	Right	Scale
25	ca24	Numeric	8	2		None	None	8	Right	Scale
26	ca25	Numeric	8	2		None	None	8	Right	Scale

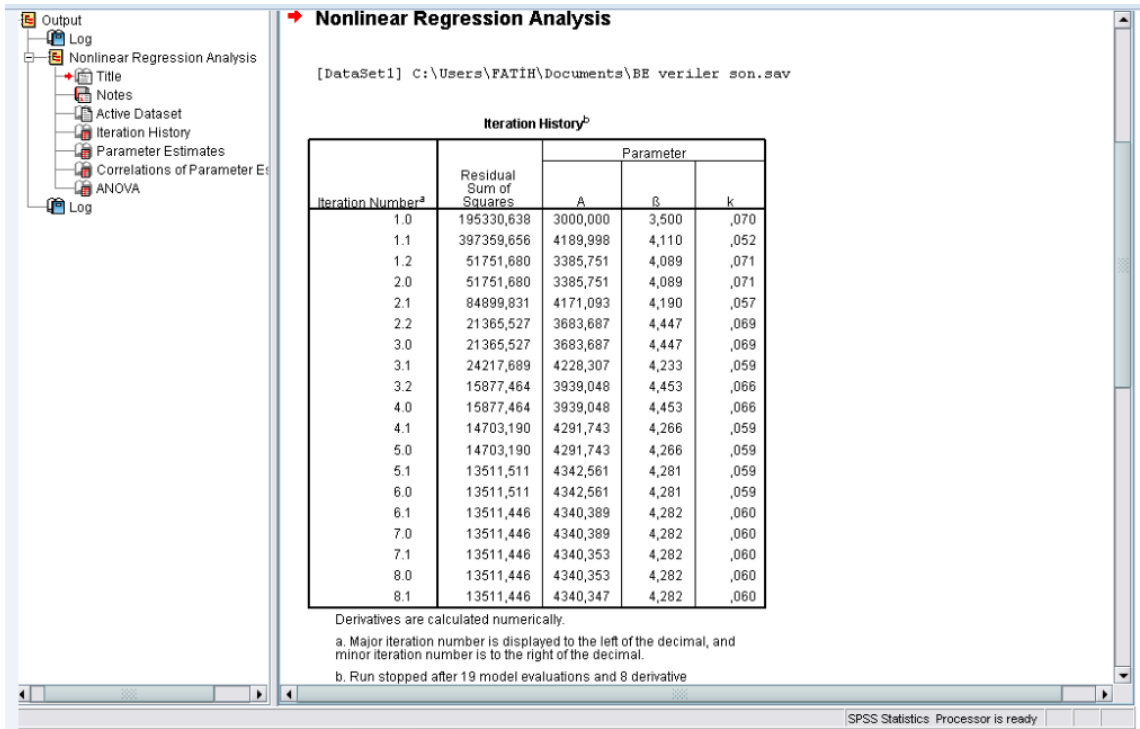
Resim 11. Variable view bölümünde ölçümler scale olarak tercih edilir.

ca4	ca5	ca6	ca7	ca8	ca9	ca10
47,39	47,50	46,64	46,95	47,30	47,89	46,89
137,89	148,48	141,57	143,36	144,86	127,14	137,14
282,93	301,27	338,43	306,30	318,75	286,00	294,77
677,93	719,71	756,45	720,86	713,09	643,73	716,00
1323,18	1381,43	1401,90	1378,18	1350,19	1256,91	1369,09
2070,45	2104,76	2071,43	2225,00	2123,81	2009,09	2204,55
		2640,48	2725,00	2837,50	2745,24	2792,86

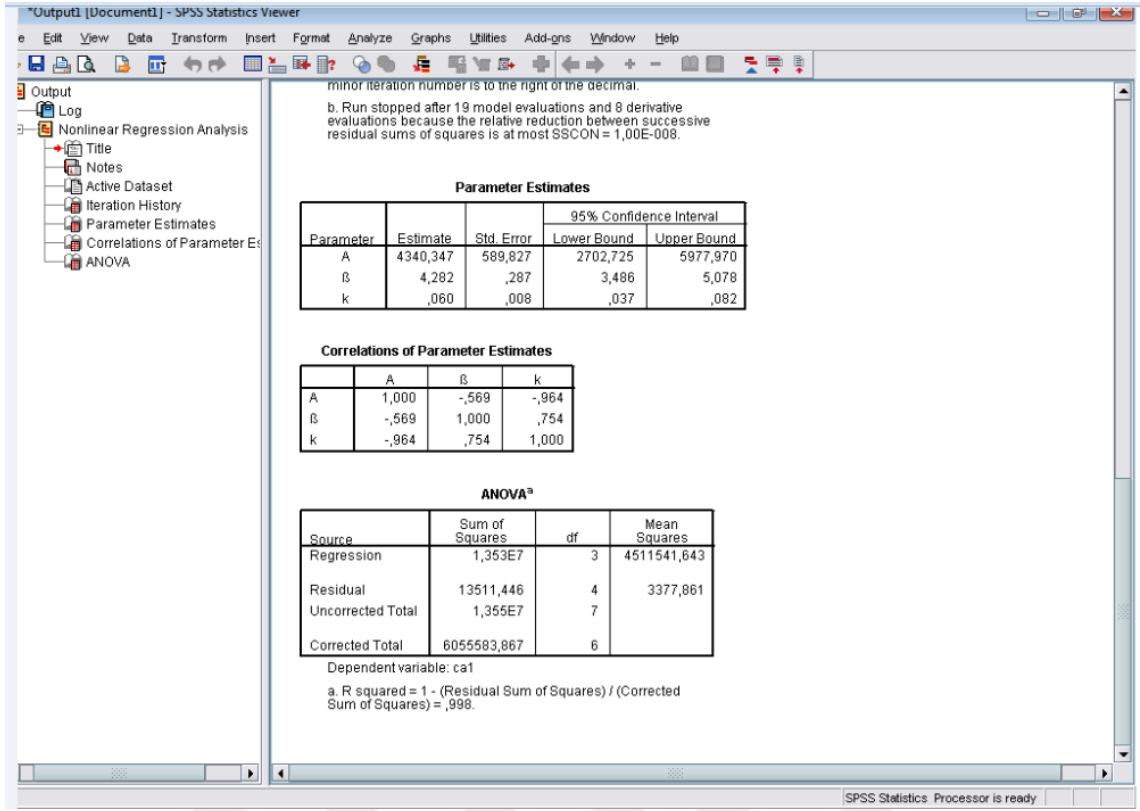
Resim 12. Doğrusal olmayan model analizi için analiz menüsünden Regression alt menüsüne girilerek Nonlinear seçeneği seçilir.



Resim 13. Nonlinear regression ekranından bağımlı değişkenler (dependent) seçilerek dependent kutucuğuna atanır ve Model Expression bölümünden analizi yapılacak olan Gompertz yönteminin modeli yazılır. Daha sonra Parametres seçilerek analizin ağırlıkları (A, β , k) atanır. Save tıklanır içeriğinde; Residuals ve Predicted values seçilir. En son OK seçeneği tıklanır.



Resim 14. Gompertz yönteme ait parametre analiz sonuçları ekranda görülmektedir.



Resim 15. Gompertz yönteme ait parametre ve ANOVA analiz sonuçları ekranda görülmektedir.

ÖZGEÇMİŞ

1984 yılında Tokat'ta doğdu. İlk, orta ve lise eğitimini Tokat'ta tamamladı. 2004 yılında Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Zootekni Bölümünden mezun oldu. 2010 yılında kamu personeli seçme sınavı sonucunda Artova Gıda Tarım ve Hayvancılık İlçe Müdürlüğüne atandı ve Tokat İl Tarım ve Orman Müdürlüğünde görevine devam etmektedir. Evli ve 2 çocuk annesidir.

