



**T.C.**  
**KONYA TEKNİK ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



**YAPAY ZEKÂ YÖNTEMLERİNİN YAĞIŞ  
HARİTALARI İÇİN MEKÂNSAL TAHMİN  
BAŞARILARININ İNCELENMESİ**

**Mustafa HÜSREVOĞLU**

**DOKTORA TEZİ**

**Harita Mühendisliği Anabilim Dalı**

**Haziran-2023**  
**KONYA**  
**Her Hakkı Saklıdır**

## TEZ KABUL VE ONAYI

Mustafa Hüsrevođlu tarafından hazırlanan “Yapay Zekâ Yöntemlerinin Yađış Haritaları için Mekânsal Tahmin Başarılarının İncelenmesi” adlı tez çalışması 22/06/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü Harita Mühendisliği Anabilim Dalı’nda DOKTORA TEZİ olarak kabul edilmiştir.

### Jüri Üyeleri

### İmza

#### Başkan

Prof. Dr. İsmail Bülent GÜNDOĞDU

.....

#### Danışman

Prof. Dr. İsmail Bülent GÜNDOĞDU

.....

#### Üye

Prof. Dr. İbrahim Öztuđ BİLDİRİCİ

.....

#### Üye

Prof. Dr. Hakan KARABÖRK

.....

#### Üye

Doç. Dr. Hüseyin Zahit SELVİ

.....

#### Üye

Dr. Öğretim Üyesi Ahmet Emin KARKINLI

.....

Yukarıdaki sonucu onaylarım.

Prof. Dr. Mevlüt UYAN  
Enstitü Müdürü

## **TEZ BİLDİRİMİ**

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

## **DECLARATION PAGE**

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Mustafa HÜSREVOĞLU

Tarih: 10.07.2023

## ÖZET

### DOKTORA TEZİ

# YAPAY ZEKÂ YÖNTEMLERİNİN YAĞIŞ HARİTALARI İÇİN MEKÂNSAL TAHMİN BAŞARILARININ İNCELENMESİ

**Mustafa HÜSREVOĞLU**

**Konya Teknik Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Harita Mühendisliği Anabilim Dalı**

**Danışman: Prof. Dr. İsmail Bülent GÜNDOĞDU**

**Yıl, 2023 Sayfa 156**

**Jüri**

**Prof. Dr. İsmail Bülent GÜNDOĞDU  
Prof. Dr. İbrahim Öztuğ BİLDİRİCİ  
Prof. Dr. Hakan KARABÖRK  
Doç. Dr. Hüseyin Zahit SELVİ  
Dr. Öğretim Üyesi Ahmet Emin KARKINLI**

Mekânsal tahminlerin doğruluğu, doğru analizler gerçekleştirmek için önemlidir. Bu çalışmada yağışların mekânsal dağılımlarının tahmini için yapay zekâ yöntemlerinin mekânsal tahmin performansı incelenmiştir. Örnek uygulamalar ile Türkiye'nin İç Anadolu Bölgesi'nde yer alan 193 meteoroloji istasyonuna ait 2016 yılı aylık ortalama yağış büyüklükleri kullanılarak, yağışların mekânsal tahminleri için Yapay Sinir Ağları (Artificial Neural Network, ANN) ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neuro-Fuzzy Inference System, ANFIS) yöntemleri kullanılmıştır. Çalışma kapsamında jeoistatistik analiz tahminleri ile sezgisel algoritmaları bir arada kullanan Bölgeselleşmiş Değişkenlerin Jeostatistiksel ve Sezgisel Mekânsal Tahmini yöntemi (Geostatistical and Heuristic Spatial Prediction of Regionalized Variables, Geo-HUSREV) yöntemi geliştirilmiştir. Tahmin performanslarını değerlendirmek için uygulamalarda kullanılmayan test noktalarının karesel ortalama hata değerleri (KOH) ve farklı özelliklere sahip 11 karakteristik test noktasında görülen tahmin hataları incelenmiştir. Yağışlar ile ilişkili 17 ikincil değişken tahminlerde girdi olarak kullanılmıştır. 1, 2, 3, 4 ve 5 girdi bir arada kullanılacak şekilde tüm girdi kombinasyonları çok sayıda uygulama yapılarak tahminler için kullanılmıştır. ANN ve ANFIS uygulamalarında yöntemlerin farklı parametreleri incelenerek tahminlere etkisi değerlendirilmiştir. ANN ve ANFIS uygulamalarından seçilen en iyi uygulamalar, aynı girdi değişkenler kullanılarak, Parçacık Sürü Optimizasyonu (PSO) ve Genetik Algoritma (GA) yöntemleri ile yeniden eğitilen ANN-PSO, ANN-GA, ANFIS-PSO, ANFIS-GA ve kriging, CoKriging (COK), Regresyon Kriging (RK), Geo-HUSREV yöntemleri ile uygulanmıştır. Bulgular karşılaştırılmıştır. Sonuç olarak çalışmada bölge için en uygun tahminler ANN yöntemi ile elde edilmiştir. ANN yönteminden sonra sırasıyla ANFIS ve Geo-HUSREV yöntemi, kriging, COK ve RK yöntemine göre daha iyi tahmin performansı sağlamıştır. Özellikle maksimum yağışın tahmin edilmeye çalışıldığı ekstrapolasyon test noktasında yapay zekâ yöntemleri oldukça başarılı olmuştur. En uygun tahmin değerlerine sahip uygulamalarda çoğunlukla nem, basınç, denize uzaklık, sıcaklık ve akarsulara uzaklık değişkenleri kullanılmıştır. 16 farklı tahmin haritası üretilmiştir ve haritaların dokularında önemli farklılıklar görülmüştür. Çalışma kapsamında, mekânsal tahminler için yapay zekâ yöntemlerinin başarılı bir şekilde uygulanabileceği ve jeoistatistik analiz çalışmalarının yanında bu yöntemlerin de bulgularının incelenmesinin önemli olduğu sonucuna varılmıştır.

**Anahtar Kelimeler:** Bulanık Mantık, Enterpolasyon, Genetik Algoritma, Jeostatistik, Kartografya, Kriging, Parçacık Sürü Optimizasyonu, Yapay Sinir Ağları

## ABSTRACT

### PhD THESIS

# EXAMINING THE SPATIAL ESTIMATION SUCCESS OF ARTIFICIAL INTELLIGENCE METHODS FOR PRECIPITATION MAPS

**Mustafa HÜSREVOĞLU**

**Konya Technical University  
Institute of Graduate Studies  
Department of Geomatics Engineering**

**Advisor: Prof. Dr. İsmail Bülent GÜNDOĞDU**

**Year, 2023 Pages 156**

#### Jury

**Prof. Dr. İsmail Bülent GÜNDOĞDU  
Prof. Dr. İbrahim Öztuğ BİLDİRİCİ  
Prof. Dr. Hakan KARABÖRK  
Assoc. Prof. Dr. Hüseyin Zahit SELVİ  
Asst. Prof. Dr. Ahmet Emin KARKINLI**

The accuracy of spatial estimations is crucial for performing accurate analyses. In this study, the spatial prediction performance of artificial intelligence methods for the estimation of spatial distributions of precipitation has been examined. Using the 2016 average monthly precipitation magnitudes belonging to 193 meteorological stations located in the Central Anatolia Region of Turkey as an example, Artificial Neural Network (ANN) and the Adaptive Neuro-Fuzzy Inference System (ANFIS) methods have been utilized for spatial predictions. As part of the thesis study, a method called Geostatistical and Heuristic Spatial Prediction of Regionalized Variables (Geo-HUSREV), which combines geostatistical methods with heuristic algorithms, has been developed. Root mean square errors (RMSE) of test points, not used in applications, and prediction errors observed at 11 characteristic test points with different features have been examined to evaluate the prediction performances. 17 secondary variables associated with precipitation have been used as inputs in predictions. All input combinations have been used in numerous applications by using 1, 2, 3, 4, and 5 inputs together for the predictions. Different parameters of the ANN and ANFIS applications have been examined, and their impacts on the predictions have been evaluated based on the findings. The models of the best applications selected from ANN and ANFIS applications have been retrained using the Particle Swarm Optimization PSO and Genetic Algorithm (GA) methods with the same input variables, and the success of ANN-PSO, ANN-GA, ANFIS-PSO, ANFIS-GA applications, kriging, COK, RK, and Geo-HUSREV methods have been examined. As a result, the most accurate predictions for the study area have been obtained with the ANN method. After the ANN method, ANFIS and the Geo-HUSREV methods, in turn, provided a better prediction performance than the kriging, COK, and RK methods. Artificial intelligence methods have been very successful at the extrapolation test point where the prediction of maximum precipitation has been attempted. In the applications with the most accurate prediction values, the variables have been mostly humidity, pressure, distance to sea, temperature, distance to rivers. 16 different prediction maps have been produced, and significant differences have been observed in the textures of the maps. The thesis study concluded that artificial intelligence methods can be successfully applied for spatial predictions, and it is important to examine the findings of these methods in addition to geostatistical analysis studies in spatial prediction studies.

**Keywords:** Artificial Neural Networks, Cartography, Fuzzy Logic, Genetic Algorithm, Geostatistics, Interpolation, Kriging, Particle Swarm Optimization

## ÖNSÖZ

Öncelikle lisansüstü eğitim hayatım boyunca bana her konuda destek veren, yardımcı olan, bilgilerinden faydalandığım ve uzun yıllar boyunca beraber çalışarak gelişmemi sağlayan danışman hocam Prof. Dr. İsmail Bülent GÜNDOĞDU'ya en derin teşekkürlerimi sunarım.

Tez izleme komitesi ve jüri hocalarıma, Konya Teknik Üniversitesine ve Harita Mühendisliği Bölümüne, Niğde Ömer Halisdemir Üniversitesine ve Harita Mühendisliği Bölümüne, tez çalışması için yağış verilerini sağlayan Meteoroloji Genel Müdürlüğü'ne, çalışmada kullanılan verileri ücretsiz bir şekilde sağlayan kurumlara, çalışmada kullanılan açık kaynaklı QGIS yazılımının geliştirilmesinde katkısı olan herkese ve adını burada yazamadığım hocalarıma, arkadaşlarıma, tez çalışmam için yardımcı olan herkese çok teşekkür ederim.

Her konuda cömertçe ve fedakârca destek vererek bu günlere gelmemi sağlayan ailemin tüm fertlerine sonsuz teşekkürlerimi sunarım. Son olarak, çalışmalarım sırasında sevgisi ile bana destek olan hayat arkadaşım Betül'e çok teşekkür ederim.

Mustafa HÜSREVOĞLU  
KONYA-2023

# İÇİNDEKİLER

<b>ÖZET .....</b>	<b>iv</b>
<b>ABSTRACT.....</b>	<b>v</b>
<b>ÖNSÖZ .....</b>	<b>vi</b>
<b>İÇİNDEKİLER .....</b>	<b>vii</b>
<b>SİMGELER VE KISALTMALAR .....</b>	<b>viii</b>
<b>1. GİRİŞ .....</b>	<b>10</b>
<b>2. KAYNAK ARAŞTIRMASI .....</b>	<b>17</b>
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>26</b>
3.1. Yapay Sinir Ağları (ANN).....	32
3.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS) .....	35
3.3. Yapay Zekâ Optimizasyon Algoritmaları .....	38
3.3.1. Parçacık sürü optimizasyonu (PSO) .....	39
3.3.2. Genetik algoritma (GA) .....	39
3.3.3. Yapay arı kolonisi algoritması (ABC) .....	40
3.4. Kriging, CoKriging (COK) ve Regresyon Kriging (RK) Yöntemi .....	40
3.5. Bölgeselleşmiş Değişkenlerin Jeostatistiksel ve Sezgisel Mekânsal Tahmini (Geo-HUSREV).....	44
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>50</b>
4.1. Yapay Sinir Ağları (ANN) Bulguları.....	50
4.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS) Bulguları .....	75
4.3. En uygun Yapay Sinir Ağları (ANN) Bulgularının Değerlendirilmesi .....	101
4.4. En uygun Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS) Bulgularının Değerlendirilmesi.....	110
4.5. ANN-PSO, ANN-GA, ANFIS-PSO ve ANFIS-GA Bulguları.....	118
4.6. Kriging, CoKriging (COK), Regresyon Kriging (RK) ve Geo-HUSREV Bulguları .....	125
4.7. Tartışma .....	136
<b>5. SONUÇLAR VE ÖNERİLER .....</b>	<b>147</b>
<b>KAYNAKLAR .....</b>	<b>150</b>

## SİMGELER VE KISALTMALAR

### Simgeler

$x$	: Rasgele değişken.
$x_i$	: $i$ konumundaki rasgele değişken, örnek noktası.
$x_0$	: Tahmini yapılan nokta.
$z(x_i)$	: $x_i$ konumundaki örnek noktasının beklenen değeri.
$\hat{Z}(x_0)$	: $x_0$ noktasındaki rasgele değişkenin tahmin edilen değeri.
$n$	: Örnek noktası sayısı.
$N$	: Karşılaştırılan örnek çifti sayısı.
$\gamma$	: Yarı varyans.
$\hat{\gamma}(h)$	: Yarı variogram fonksiyonu.
$h$	: Adım aralığı.
$w_i$	: Ağırlık katsayısı.
$P_j$	: $j$ 'inci optimizasyon parametresi.
$P_{c_k, j}$	: $k$ 'ıncı c kümesi için $j$ 'inci optimizasyon parametresi.
$X_{\varphi i, \lambda i}$	: $\varphi i, \lambda i$ konumunun bilinen gerçek değişken değeri.
$H(\hat{X}_{\varphi i, \lambda i})$	: $\varphi i, \lambda i$ konumunun optimum tahmin değeri.
$H(\hat{X}_{c_k, \varphi i, \lambda i})$	: $k$ 'ıncı c kümesinin $\varphi i, \lambda i$ konumunun optimum tahmin değeri.
$Cov_{i, \varphi i, \lambda i}$	: $\varphi i, \lambda i$ konumunun $i$ 'inci kovaryete değişkeni değeri.
$Kriging_{\varphi i, \lambda i}$	: $\varphi i, \lambda i$ konumunun kriging tahmini değeri.
$Cost$	: Maliyet fonksiyonu değeri.
$Cost_{c_k}$	: $k$ 'ıncı c kümesi için, maliyet fonksiyonu değeri.
$R$	: Korelasyon katsayısı.

### Kısaltmalar

ABC	: Artificial Bee Colony
ANFIS	: Adaptive Neuro Fuzzy Inference System
ANN	: Artificial Neural Network
ASTER	: Advanced Spaceborne Thermal Emission and Reflection Radiometer
COK	: CoKriging
FCM	: Fuzzy C-Means
FLDAS	: Famine Early Warning Systems Network Land Data Assimilation System
GA	: Genetic Algorithm
Geo-HUSREV	: Geostatistical and Heuristic Spatial Prediction of Regionalized Variables
GDEM 003	: Global Digital Elevation Model Version 3
GPM	: Global Precipitation Mission
GWR	: Geographically Weighted Regression
GWRK	: Geographically Weighted Regression Kriging
GY	: Geri Yayılım
IDW	: Inverse Distance Weighting
IMERG	: Integrated Multi-satellitE Retrievals for GPM



KED	: Kriging with External Drift
KH	: Kriging-HUSREV
KOH	: Karesel Ortalama Hata
LM	: Levenberg-Marquardt Algorithm
LRK	: Lokal RK
MGM	: Meteoroloji Genel Müdürlüğü
M-IDW	: Modified IDW
NASA	: The National Aeronautics and Space Administration
PSO	: Particle Swarm Optimization
RBF	: Radyal Bazlı Fonksiyonlar
RK	: Regresyon Kriging
SCG	: Scaled Conjugate Gradient
TPS	: Thin Plate Spline



## 1. GİRİŞ

Çeşitli çevresel değişkenlerin mekânsal dağılım tahmini haritalarının oluşturulması için kullanılan yöntem ve yaklaşımlar, uygun tahminlerin yapılması için en önemli etkenlerdendir. Bu çalışmada yağışların mekânsal dağılımlarının tahmin edilmesi ve haritalanması için yapay zekâ yöntemlerinin başarısı ve klasik yöntemlere göre performansı karşılaştırılarak incelenmiştir.

Yağışların mekânsal dağılımının tahmin edildiği haritaların doğruluğu, taşkın, toprak kayması afetleri gibi birçok konu hakkında yapılacak çalışmalar için altlık olarak kullanılması bakımından önemlidir (Canlı ve ark., 2018; Costache ve ark., 2020; Arabameri ve ark., 2021). Yapay zekâ yöntemlerinin karmaşık ve lineer olmayan ilişkileri öğrenme kabiliyetlerine rağmen, meteoroloji istasyonları değerlerinden faydalanarak yapılan haritalama çalışmalarında yaygın olarak jeostatistik analiz yöntemleri kullanılmıştır (Lloyd, 2005; Ly ve ark., 2011; Bostan ve ark., 2012; Gündoğdu, 2014; Gündoğdu, 2015; Borges ve ark., 2016; Kumari ve ark., 2016; Adhikary ve ark., 2017; Gündoğdu, 2017; Javari, 2017; Raja ve ark., 2017; Gündoğdu ve Hüsrevoğlu, 2018; Hüsrevoğlu, 2018). Jeostatistik analiz yöntemleri olarak da bilinen kriging, mesafenin tersine göre ağırlıklandırma gibi mekânsal tahmin yöntemleri, ünlü coğrafyacı Waldo Tobler'in "her şey diğer her şey ile ilişkilidir ancak yakın şeyler uzak şeylerden daha fazla ilişkilidir" (Tobler, 1970), şeklinde ifade ettiği Tobler'in ilk coğrafya kanunu esasına dayanır. Bu klasik yöntemler değişkenler arasında mesafeye göre bir mekânsal bağımlılığın olduğunu varsayar ve Tobler'in ilk kanununun operasyonel hale getirilmesidir (Waters, 2016). Buna göre tahmin yapılan konumun tahmin değerinin belirlenmesinde komşu gözlem noktaları kullanılır ve genellikle tahmine en çok yakın komşu nokta değerleri etki eder. Mekânsal bağımlılığın tanımlandığı uygun yarı variogram modelinin belirlenmesi ve Matheron (1963) tarafından geliştirilen bölgesel değişkenler teorisi varsayımlarına uygun şekilde tahmin yapılması koşuluyla, kriging yöntemi "best linear unbiased predictor", (BLUP) olarak bilinir (Şen, 2009; Oliver, 2010; Oliver ve Webster, 2015). Bu nedenle birçok çalışma kriging yöntemi ile gerçekleştirilmektedir. Ancak Cressie (1993)'ye göre varsayımların sağlanmadığı ve doğru uygulanmayan kriging yöntemi komşu gözlem değerlerinin sadece ortalamasını almaktan ibaret olan bir yöntem olacaktır. Tahmini yapılan konumun değeri için o konumun özellikleri yerine sadece komşu noktaların değerlerinin ve mesafeye bağlı bir modelden gelen ağırlıkların kullanılması bu tür yöntemlerin en önemli eksikliği olabilir.

Her ne kadar kriging yöntemleri ile uygun tahminler elde etmek için içsel durağanlık ve mekânsal bağımlılık varsayımlarının sağlanması koşulu olsa da gerçek yeryüzünde varsayımlar sağlanamayabilir ve komşu noktalar tahmini yapılan noktayı temsil etmeyebilir. Tahmini yapılan konumu temsil etmeyen komşu noktalar, tahmin sonuçlarının başarısızlığına da neden olabilir. Tahmini yapılan bir çevresel değişkenin konumuna ait yükseklik, bakı gibi diğer ikincil öznitelikler komşuluk veya yakınlık ilişkisine göre daha önemli bir bilgi olabilir. Araştırmacılar CoKriging (COK) uygulamalarında yağışın yanında ikincil veriler olarak yükseklik, eğim, bakı gibi veriler kullanarak tahminlerini iyileştirseler de (Moral, 2010; Ly ve ark., 2011; Feki ve ark., 2012; Güler ve Kara, 2014; Gündoğdu, 2014; Gündoğdu, 2015; Kumari ve ark., 2016; Adhikary ve ark., 2017; Gündoğdu, 2017; İçağa ve Taş, 2018) COK yöntemi ile kullanılan ikincil veriler komşu noktalara aittir ve tahmini yapılan noktaya ait özellikler tahminlerde kullanılmaz. Bu durum hem kriging hem de COK uygulamaları için önemli bir eksikliktir. Bunun yanında Regresyon Kriging (RK) yöntemi ile tahmini yapılan konumun özniteliklerinden faydalanılarak daha iyi tahmin performanslarının elde edilmesi sağlanabilir. RK yönteminin tahmini yapılan konumun da özniteliklerinden faydalanabilmesi, kriging ve COK yöntemlerinin önemli bir eksikliği için çözüm sunsa da bu yöntem için de yakınlık ilişkisi ve komşu değerlerin tahmin noktası için kullanımı tahminler üzerinde etkili olacaktır.

Birçok çalışma mekânsal tahmin performanslarını karesel ortalama hata (KOH) gibi bütüncül bir gösterge ile değerlendirmiştir. KOH göstergesinin performans değerlendirmesinde kullanımı yanıltıcı çıkarımlara neden olabilir. Çünkü tüm tahmin noktaları ve tahmin hataları eşit derecede önemli olmayabilir. Ayrıca karakteristik bir noktada görülebilecek önemli bir tahmin hatası değeri, ortalama üzerinde belirsiz bir hale gelebilir.

Örneğin, Hüsrevoğlu (2018) çalışmasında Türkiye için kriging ve COK yöntemlerini kullanarak başarılı KOH sonuçları elde etmiştir. Ancak çalışma bölgesinde yer alan, ani yükseklik değişimi gösteren ve yaklaşık 3900 m kotlu Erciyes Dağı üzerinde yapılan mekânsal yağış tahmin değerlerinin gerçekte olduğundan daha az olduğunu düşünmüştür. Bu düşük tahmin değerinin nedeni kullanılan veri setinde Erciyes Dağı üzerinde yer alan örnek bir istasyon verisi olmaması ve dağ çevresindeki düşük kotlu örnek istasyon noktası değerlerinin yüksek konumdaki tahmin noktasını temsil etmemesidir. Türkiye'nin İç Anadolu Bölgesi'nde yer alan dağ, bir kayak merkezi olup, çevresine göre daha fazla yağış aldığı günlük rutin yaşam sırasında bile

gözlemlenebilmektedir. Örnekte verilen problem, yeterince örnek noktası ile gözlem yapılamayan tüm çalışma alanları için mevcut olabilir. Daha uygun bir tahmin elde etmek için tahmin noktasının özelliklerinin tahminlerde kullanılması doğruluğu artırabilir.

Uluslararası Kartografya Birliği (International Cartographic Association, ICA) mekânsal analiz ve modelleme komisyonu araştırma ajandasında, jeostatistik, yapay zekâ, k-ortalamlar (k-means) kümeleme gibi yöntemlerin ve bunların çok değişkenli, zaman-mekânsal uygulamalarının önemine değinilmiştir. Ayrıca bulanık mantık, Yapay Sinir Ağları (Artificial Neural Network, ANN) gibi yöntemler, coğrafi bilgi bilimi uygulamalarında henüz standart hesaplamalı çözümler olarak kabul edilmemiş olan coğrafi hesaplama yöntemleri olarak örneklendirilmiş ve bu konularda araştırma yapılmasının önemine değinilmiştir. Yeni veya geliştirilen yöntemler ve yaklaşımlar ile gerçek dünyanın haritalarda daha iyi sunulabileceğine değinilmiştir (Virrantaus ve ark., 2009).

Klasik mekânsal tahmin yöntemleri dışında, araştırmacılar farklı yapay zekâ yöntemlerini de kullanmışlardır (Li, 2019). Örneğin sayısal yükseklik modeli için Merwin ve ark. (2002); Zhu ve ark. (2020), çeşitli çevresel değişkenler için Li ve ark. (2011); Valizadeh ve ark. (2017); Hengl ve ark. (2018); Mariano ve Monica (2021); Taghizadeh-Mehrjardi ve ark. (2021), hava sıcaklığı ve yağışlar için Rigol ve ark. (2001); Chang ve ark. (2005); Kalteh ve Berndtsson (2007); Teegavarapu ve ark. (2009); Appelhans ve ark. (2015); Seo ve ark. (2015); Kajornrit ve ark. (2016); Attar ve ark. (2019); Hu ve ark. (2019); Amato ve ark. (2020); Sekulić ve ark. (2020); Bayat ve ark. (2021); Sekulić ve ark. (2021) çalışmaları gerçekleştirilse de yağışlar için oldukça az sayıda yapay zekâ yöntemleri ile mekânsal tahmin çalışması mevcuttur.

Bu çalışmada kriging, COK ve RK yöntemi karşısında yapay zekâ yöntemlerinden ANN ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (Adaptive Neuro Fuzzy Inference System, ANFIS) yöntemlerinin mekânsal tahmin yöntemi olarak kullanımı araştırılmıştır. Ayrıca çalışma kapsamında jeostatistik analiz yöntemleri ve sezgisel optimizasyon yöntemlerinin hibrit bir şekilde kullanımını sağlayan Bölgeselleşmiş Değişkenlerin Jeostatistiksel ve Sezgisel Mekânsal Tahmini (Geostatistical and Heuristic Spatial Prediction of Regionalized Variables, Geo-HUSREV) yöntemi geliştirilmiştir ve performansı incelenmiştir.

Çalışmada Türkiye'nin İç Anadolu Bölgesi'nde, 193 meteoroloji istasyonuna ait, 2016 yılı aylık ortalama yağış değerleri kullanılarak, mekânsal tahminlerde klasik

yöntemlerin olumsuz etkilerinin yapay zekâ yöntemlerinden ANN ve ANFIS yöntemleri ile giderilip giderilemeyeceği araştırılmıştır.

Araştırmada, Erciyes Dağı'nın 2202 m kotuna daha sonraları tesis edilen otomatik gözlem istasyonu, en yüksek yağış alan istasyon konumu olup, maksimum yağış ekstrapolasyon test noktası olarak çalışmada bir performans ölçütü olarak kullanılmıştır. Çünkü homojen ve durağanlık koşulunun daima sağlanamayacağı gerçek bir yeryüzünde bu türden karakteristik bir konumda gözlem istasyonu bulunmayabilir. Böyle bir duruma rağmen tahmini yapılan konumun öznelilikleri sayesinde, uygun bir mekânsal tahmin yaklaşımı ile gerçeğe en yakın tahmin değerinin elde edilmesi mümkün olabilir. Yapay zekâ yöntemlerinin tahminlerdeki başarısı sadece KOH ile değil daha gerçekçi ve zorlayıcı bir şekilde en yüksek yağış ekstrapolasyon noktası, en yüksek, yüksek, ortalama ve düşük kotlu istasyonlar, yüksek, ortalama, düşük yağış alan istasyonlar ve istasyonların seyrek olduğu bölgelerde bulunan istasyonlar olmak üzere toplamda 11 farklı karakteristik test noktası üzerinde incelenmiştir.

Çalışmada yapay zekâ tahminleri için her istasyona ait 17 farklı değişken girdi verileri olarak kullanılmıştır. Bu değişkenler yağış değerleri ile ilişkili, enlem, boylam, yükseklik, denize uzaklık, bakı, eğim, sırasıyla tahmin noktasına en yakın 5 örnek noktanın değişken değerleri, göllere uzaklık, akarsulara uzaklık, NASA-GPM-IMERG (The National Aeronautics and Space Administration - Global Precipitation Measurement - Integrated Multi-satellite Retrievals for GPM) yağış verisi, sıcaklık, nem ve basınç değişkenleridir. Yapay zekâ uygulamalarında bilinen yağış değerlerine karşılık eğitim süreci için 1, 2, 3, 4 ve 5 girdinin kullanıldığı uygulamalar gerçekleştirilmiştir. Farklı girdilerin birlikte kullanımının etkilerinin ortaya konması için farklı girdi kombinasyonları çok sayıda uygulama ile araştırılmıştır. Ayrıca ANN ve ANFIS yöntemleri farklı öğrenim algoritmaları ve farklı parametreler kullanılarak uygulanmıştır. Bu çalışmada birçok parametre ile denemeler gerçekleştirilmiştir. Ayrıca en iyi tahmin bulgularına sahip uygulamalar, Parçacık Sürü Optimizasyonu (Particle Swarm Optimization, PSO) ve Genetik Algoritma (Genetic Algorithm, GA) yöntemleri ile yeniden eğitilerek PSO ve GA yönteminin eğitim algoritması olarak kullanımının tahminleri nasıl etkilediği de araştırılmıştır. Yüksek performanslı 20 iş istasyonu yardımıyla programatik olarak ANN yöntemi ile 5293400, ANFIS yöntemi ile 22288 yapay zekâ uygulaması gerçekleştirilmiştir. Uygulamaların gerçekleştirilmesinde Konya Teknik Üniversitesi tarafından sağlanan lisans ile MATLAB 2021a yazılımı kullanılmıştır. ANN yöntemi için gizli nöron sayısı, iki farklı eğitim algoritması, ANFIS

yöntemi için farklı üyelik fonksiyonu sayıları ile uygulamalar, iki farklı eğitim algoritması vb. çok sayıda yöntem parametresi incelenmiştir. Bu uygulamalar arasından en iyi mekânsal tahmin bulguları seçilmiştir ve haritası üretilmiştir. Kullanılan girdiler ve yöntem parametreleri hakkında birçok bulgu ortaya konmuştur. En uygun yapay zekâ tahmini bulguları kriging, COK ve RK uygulamaları ile karşılaştırılmıştır.

Yapay zekâ yöntemlerinin mekânsal tahminler için kullanımının araştırılması ve daha doğru tahmin haritaları elde edilmesi çok önemlidir. Çünkü mekânsal tahmin haritaları afetler gibi son derece önemli konular için yapılan analizlerde altlık olarak kullanılmaktadır. Bu çalışmada yağışların mekânsal tahmininde kriging, COK ve RK yöntemleri ile elde edilen haritalara göre yapay zekâ ve Geo-HUSREV yöntemleri ile önemli farklara sahip yağış haritaları ortaya konmuştur. Bu farklılıklar bu haritalar ile yapılan afet benzeri analizlerin sonuçlarının farklı yorumlanmasına neden olabilir. Bu çalışmada kriging, COK ve RK yöntemleri ile özellikle Erciyes Dağı'nda yer alan maksimum yağış ekstrapolasyon test noktasında gerçeği temsil etmeyen yağış tahmini değerleri yerine ANN, ANFIS ve Geo-HUSREV yöntemi ile daha doğru yağış tahmin değerleri elde edilmiştir.

Çalışma, kullandığı metotlar, yapay zekâ yöntemlerinin PSO ve GA algoritmaları ile hibrit bir şekilde kullanılması ve tez çalışması kapsamında geliştirilen Geo-HUSREV yönteminin kullanımı ile özgün bir mekânsal tahmin çalışması ortaya koymuştur. Yapay zekâ yöntemleri ile nokta temelli verilerin kullanımı ile mekânsal tahminlerin gerçekleştirilmesi, tahmin modeli oluşturulması ve tahmin haritalarının üretilmesi için araştırmacılara bir çerçeve sunulmuştur.

Yeryüzünde bulunan meteoroloji istasyonlarına ait gözlemler, yağışların incelenmesi ve haritalanması açısından en önemli veri kaynaklarından (Kühnlein ve ark., 2014; Shi ve ark., 2015; Sun ve ark., 2018; Amato ve ark., 2020). Bu nedenle bu çalışmada ele alınan ve nokta bazlı verilerden faydalanarak yapılan yapay zekâ uygulamaları ile yağış haritalarının üretimi önem arz eder.

Çalışma kapsamında şu araştırma soruları için yanıt aranmıştır;

- Yapay zekâ yöntemlerinin kriging yöntemlerine göre başarısı nasıldır?
- Yapay zekâ yöntemlerinin ekstrapolasyon performansı nasıldır?
- KOH ve karakteristik test noktalarında görülen hataların incelenmesinin tahmin performansı değerlendirmesinde önemi nedir?
- ANN, ANFIS ve kriging yöntemlerinin başarısı nasıldır?

- Sezgisel optimizasyon algoritmaları kullanımı ile ANN ve ANFIS uygulamaları bu çalışmada geliştirilebilir mi?
- Sezgisel optimizasyon algoritmaları ile jeostatistik analiz yöntemleri geliştirilebilir mi?
- Karakteristik noktalarda tahmin performansı hangi yöntemler kullanılırsa en iyidir?
- Çalışma bölgesinde hangi ikincil değişkenlerin kullanımı en uygun tahmin performansını sağlamıştır?
- İkincil değişkenlerin hangi değişkenler ile kombinasyonu uygun bulgular sağlamıştır?
- Yapay zekâ uygulamalarında kaç girdi kullanmak daha iyi tahmin performansı sağlamıştır?
- ANN yöntemi için katman sayısı ve nöron sayısı çalışma alanı ve ele alınan konu bakımından nasıl olmalıdır?
- ANN yöntemi için incelenen eğitim algoritmalarından hangisi daha iyi tahmin bulguları sağlamıştır?
- ANFIS yöntemi için incelenen eğitim algoritmalarından hangisi daha iyi tahmin bulguları sağlamıştır?
- ANFIS yöntemi için kullanılan parametrelerden hangileri tahminler için daha başarılı performans ortaya koymuştur.
- Çalışma alanında yakın olan objelerin benzerliği temelinde tahmin gerçekleştirmek ne ölçüde etkilidir?
- En yakın komşu verileri yapay zekâ tahmin performanslarını geliştirmiş midir?
- Ekstrapolasyon test noktasında maksimum yağışı hangi yöntemler daha iyi tahmin edebilmiştir?
- Tahmin haritalarında sunulan yağış dağılımı dokusu ne ölçüde farklıdır?
- Geo-HUSREV yöntemi ile sunulan yaklaşımın performansı nasıldır?
- Geo-HUSREV yönteminin diğer yöntemlere göre tahmin başarısı nasıldır?
- Yapay zekâ yöntemleri ve Geo-HUSREV yöntemi yağışların mekânsal dağılımının tahmin edilmesinde ve haritalanmasında kullanılabilir mi?
- Klasik yöntemler ile üretilen haritalar sonraki afet ve risk araştırmaları için yanıtıcı altlıklar olabilir mi?

Sonraki bölümlerden Materyal ve Yöntem bölümünde kullanılan veri seti ve yöntemler hakkında genel bilgiler verilmiştir. Araştırma Sonuçları ve Tartışma

bölümünde elde edilen bulgular ile mekânsal tahminlerde kullanılan girdiler, yöntemlerin başarısı, kullanılan parametreler, karakteristik noktalarda görülen hatalar gibi çok sayıda ölçüte göre değerlendirmeler yapılmıştır. En uygun uygulamaların haritaları üretilerek kriging yöntemleri haritaları ile karşılaştırılmıştır. Araştırmanın cevap aradığı sorular yanıtlanmıştır. Sonuç ve Öneriler bölümünde araştırmacılara genel bulgular ve daha sonra yapılabilecek çalışmalar hakkında bilgi verilmiştir.





## 2. KAYNAK ARAŞTIRMASI

Yağışların mekânsal dağılımlarının tahmininde çoğunlukla jeostatistik analiz yöntemleri kullanılırken, yapay zekâ yöntemleri kullanılan çok daha az sayıda mekânsal tahmin çalışmaları gerçekleştirilmiştir. Mekânsal tahminlerde çeşitli konularda yapay zekâ yöntemlerinin son zamanlarda kullanımı artmıştır. Türkiye’de Meteoroloji Genel Müdürlüğü (MGM) tarafından yağışların haritalanması kriging yöntemi ile gerçekleştirilmekle birlikte Dünya’da yapılan diğer araştırmaların ise yine çoğunlukla jeostatistik analiz yöntemleri ile gerçekleştirildiği görülmektedir. İlgili araştırmalara ait bilgiler bu bölümde verilmiştir.

Aşağıda çalışma alanı Türkiye içerisinde olan ve jeostatistik analiz yöntemleri kullanılan akademik çalışmalar için kaynak araştırması bilgileri verilmiştir.

Bostan ve ark. (2012) çalışmalarında Türkiye’de yıllık ortalama yağışların haritalanmasında 225 meteoroloji istasyonundan alınan, 1970-2006 dönemine ait yağış değerlerinin yanında, yağışlar ile ilgili olabilecek yükseklik, bakı, yüzey engebisi, kıyılarına uzaklık gibi diğer ikincil değişkenlerin tahminlerde kullanımı incelenmiştir. Regresyon ve kriging yöntemleri karşılaştırılmıştır. Çoklu lineer regresyon, Coğrafi Ağırlıklı Regresyon (Geographically Weighted Regression, GWR), RK, kriging ve evrensel kriging yöntemleri kullanılmıştır.

İlker (2012) çalışmasında Akdeniz Bölgesi’nde yağışın alansal dağılımını IDW, Spline enterpolasyon yöntemleri ve kriging yöntemi ile araştırmıştır. Akdeniz Bölgesi için yağışın alansal dağılımının belirlenmesinde Mesafenin Tersine Göre Ağırlıklandırma (Inverse Distance Weighting, IDW) yönteminin uygun ve kullanılabilir olduğunu tespit etmiştir.

Aydın ve Çiçek (2013), çalışmalarında 1975-2010 dönemine ait 36 meteoroloji istasyonunun verilerini kullanarak, Ege Bölgesi’nin yıllık ortalama yağışının mekânsal dağılımının tahmin edilmesinde IDW ve kriging yöntemini kullanmışlardır. Kriging yönteminin yağışın genel mekânsal desenini daha iyi yansıttığı sonucuna ulaşmışlardır.

Gündoğdu (2014) , çok değişkenli jeostatistik analiz yaklaşımları ile Türkiye’de yağışların mekânsal dağılımlarının tahmini için lineer regresyon, IDW ve COK yöntemlerini kullanmıştır. Bakı ikincil değişkeni kullanılan COK yönteminin uygulamalar arasında daha iyi performansa sahip olduğunu belirtmiştir.

Güler ve Kara (2014) çalışmalarında Türkiye’nin Kuzeyi için yağışların mekânsal tahmininde 69 meteoroloji istasyonu kullanarak IDW, Spline, basit kriging, COK ve

lineer regresyon yöntemlerinin performanslarını karşılaştırmışlardır. Lineer regresyon haricinde diğer yöntemler arasında önemsiz farklar olduğu ve yağışların haritalanması için yöntemlerin uygun olduğu belirtilmiştir.

Aydın (2014) Türkiye’de 1975-2010 dönemine ait meteoroloji istasyonlarının yıllık ortalama toplam yağış verilerini kullanarak, yağışın mekânsal dağılımı kriging yöntemi ile araştırmıştır. kriging yönteminin bölgesel olarak kullanılması ile mekânsal dokunun daha iyi yansıtıldığını, kriging yönteminin bu konu için uygun bir yöntem olduğunu belirtmiştir.

Gündoğdu (2015) çalışmasında GWR yönteminin yağışlar ile ilişkili ikincil veriler ile kullanımını ele almıştır. Çalışmada ikincil veriler olarak yükseklik, eğim ve bakı değişkenleri kullanılmıştır. Kriging, COK ve GWR yöntemleri ile çalışma alanı Türkiye olan bölge için uygulamalar yapılarak sonuçları karşılaştırılmıştır.

Özelkan ve ark. (2015) çalışmalarında yeni bir Modifiye Edilmiş IDW yöntemini (M-IDW) önermişlerdir. Araştırmada uydulardan elde edilen kara yüzey sıcaklığı verilerini meteorolojik istasyon verileri ile kullanarak iklim verileri ile yüzey sıcaklığı verileri arasındaki korelasyondan M-IDW yöntemi ile faydalanılmıştır. IDW, M-IDW, kriging ve COK yöntemleri mevsimlere göre karşılaştırılmıştır. Bulutluluğun az olduğu dönemlerde uydu verilerinin daha iyi kullanılmasından ötürü M-IDW yöntemi belirli dönemlerde daha iyi sonuçlar göstermiştir.

Aslantaş ve ark. (2016) çalışmalarında, Türkiye'nin toplam yıllık ve uzun yıllar toplam yıllık yağış değerlerinin mekânsal-zamansal dağılımları ve değişimlerini analiz etmişlerdir. Meteorolojik istasyonlarda ölçülmüş aylık yağış değerleri ve bununla mekânsal olarak ilişkili yükseklik, yüzey pürüzlülüğü, deniz kıyısına mesafe, akarsu yoğunluğu, bakı, arazi kullanımı ve ekolojik bölge gibi diğer veriler ile kriging ve evrensel kriging yöntemleri kullanılmıştır. Enterpolasyon yöntemleri karşılaştırılmıştır.

Gündoğdu (2017) çalışmasında Türkiye’de görülen aylık ortalama yağışların haritalanması için IDW, lineer regresyon ve COK yöntemini karşılaştırmıştır. COK yöntemi için yükseklik, eğim ve bakı ikincil değerlerini kullanmıştır. Çalışmada en uygun tahmin bulguları COK yöntemi ile elde edilmiştir.

Raja ve ark. (2017), Türkiye’de 1976-2010 dönemi için 228 meteoroloji istasyonundan alınan yağış verilerini kullanarak yağışların zaman-mekânsal değişimlerini incelemişlerdir. Çalışmalarında yağışların mekânsal dağılımını tahmin etmek için kriging yöntemini kullanmışlardır.

Hüsrevoğlu (2018) tez çalışmasında, Türkiye için aylık ortalama yağış verisinin mekânsal dağılımının tahmini ve haritalanmasında deterministik yöntemlerden Radyal Bazlı Fonksiyonlar (Radial Basis Function, RBF), global polinom enterpolasyonu, yerel polinom enterpolasyonu, IDW, kriging, basit kriging, evrensel kriging ve COK yöntemlerini kullanmıştır. Jeostatistik analiz sonuçlarını etkileyen variogram modeli, verilerin dağılım şekli, anizotropi, komşuluk seçimi gibi çeşitli her bir unsurun tahminlere etkisi çok sayıda uygulamanın gerçekleştirilmesi ile ortaya konmuştur. Uygulamalar sonucunda jeostatistik yöntemlerin deterministik yöntemlere göre daha uygun tahmin sonuçları ortaya çıkardığı ve kriging uygulamalarında dikkat edilmesi gereken hususlar belirlenmiştir.

Gündoğdu ve Hüsrevoğlu (2018) Türkiye'nin İç Anadolu Bölgesi'nde gerçekleştirdikleri çalışmada, kriging yöntemlerinin uygulanışında varsayımların sağlanmaması ve sağlanması durumunda tahminlerin nasıl etkilendiğini ele almıştır. Araştırmacılara jeostatistik analiz içerisindeki yaklaşımlar ve etkileri hakkında bilgiler verilmiştir. Kriging yöntemlerinin kullanılması için incelenmesi önemli olan, durağanlık, mekânsal bağımlılık, anizotropi, izotropi gibi unsurlar incelenmiştir. Veri setinden aykırı değerlerin çıkarılmaması durumunda deneysel araştırmaların yapılmasının önemine dikkat çekilmiştir.

İçağa ve Taş (2018) çalışmalarında iki alt havza bölgesi için mesafenin tersine göre ağırlıklandırma IDW, basit kriging ve COK yöntemlerini kullanarak aylık yağış değerlerinin mekânsal tahmininde yöntemlerin hata değerleri bakımından karşılaştırılmasına yer vermişlerdir. Elde ettikleri bulgulara göre basit kriging yöntemi yakın bir fark ile çalışılan bölge için daha uygun yöntem olarak belirlenmiştir.

Aydın (2018) çalışmasında, Ege Bölgesi için 36 istasyonundan 1976–2010 yıllarında ölçülmüş aylık ortalama yağış değerlerinden elde edilen yıllık toplam yağış verilerini kullanarak Dışsal Drift ile Kriging (Kriging with External Drift, KED) yönteminin bölgenin karakteristik yapısına göre tahmin performansının nasıl olacağını araştırmıştır. Araştırma bulgularına göre yüksekliğin yardımcı değişken olarak kullanıldığı KED analizinin seyrek gözlemlerin olduğu yerlerin yağış haritalarının oluşturulmasına yardımcı bir yöntem olabileceğini belirtmektedir.

Çetin (2018) doktora çalışmasında, Kızılırmak Havzası'nda alansal yağış ile buharlaşma-terlemenin izleme ve değerlendirilmesinde sırasıyla GPM ve Landsat 8 uydu görüntülerinden de faydalanarak COK ve IDW yöntemlerini kullanmıştır.

Kale (2018), çalışmasında Yeşilirmak Havzası için 30 meteoroloji gözlem istasyonuna ait 1954 – 2014 yılları arasındaki yağış verilerini kullanarak, mekânsal yağış dağılımının belirlenmesinde IDW ve kriging yöntemlerini karşılaştırmıştır. Bulgularına göre kriging yönteminin daha iyi sonuçlar verdiği belirtilmiştir.

Tosunoğlu ve Gürbüz (2019) çalışmalarında Türkiye’de görülen yıllık yağış miktarı için 155 istasyon verisini kullanarak en uygun olasılık dağılım fonksiyonunun belirlenmesini amaçlamışlardır. Aynı çalışmada yağış tahminlerinin haritalanması için evrensel kriging yöntemi kullanılmıştır.

Türkiye’de gerçekleştirilen diğer birçok çalışma kriging ve diğer jeostatistiksel analiz yöntemlerini mekânsal tahminler için kullanmıştır (Çetin ve Tülücü, 1998; Apaydın ve ark., 2004; Şensoy ve ark., 2007; Yavuz, 2010; Bostan ve ark., 2012; Bostan, 2013; Aydın, 2014; Özçakal, 2014; Taylan ve Damçayırı, 2016; Çıtakoğlu ve ark., 2017; Eriş ve Ağralıoğlu, 2017).

Türkiye dışında gerçekleştirilen bazı jeostatistik analiz çalışmaları aşağıda sıralanmıştır.

Hutchinson (1995), “Thin Plate Spline” (TPS) yöntemi ile güneydoğu Avustralya’nın bir bölgesi için yıllık yağış miktarının enterpolasyonunu gerçekleştirmiştir. TPS yönteminin jeostatistik yöntemlere göre avantajlı bir yönünün mekânsal otokorelasyonun önceden belirlenmesi gereksiniminin olmayışı olarak değerlendirilebilir.

Guan ve ark. (2005), çalışmalarında Amerika Birleşik Devletleri’nin New Mexico dağlık bölgelerinde aylık yağışların mekânsal dağılımının tahmininde Hibrit bir yöntem olarak “Auto-Searched Orographic Atmospheric Effects Detrended Kriging” yöntemini uygulamışlardır. Sunulan yöntem ile COK, kriging ve “Parameter Elevation Regression of Independent Slopes Model” yöntemleri karşılaştırılmıştır. “Auto-Searched Orographic Atmospheric Effects Detrended Kriging” yönteminin iklimsel ve topografik faktörlerin yağışların mekânsal değişkenliği üzerindeki etkisini daha kapsamlı bir şekilde yansıttığı belirtilmiştir.

Hengl ve ark. (2007) çalışmalarında RK yönteminin karakteristiğini, güçlü yanlarını ve kısıtlamalarını Hırvatistan’da gerçekleştirdikleri 3 farklı uygulama ile ele almışlardır. Uzaktan algılama görüntülerinden vb. elde edilen yardımcı ikincil değerler tahminlerde kullanılmıştır. RK yönteminin performansı ve uygulanış zorlukları değerlendirilmiştir.

Moral (2010), Güneybatı İspanya'nın bir bölgesindeki 136 meteoroloji istasyonunda ölçülen aylık ve yıllık yağış verileri ile gerçekleştirdiği çalışmada bir çalışma bölgesi için uygun jeostatistik analiz yönteminin seçiminin önemini belirtmiştir. Çalışmada kriging, basit kriging, evrensel kriging, RK, basit kriging ile değişen lokal ortalama yöntemi ve yüksekliğin ikincil değer olarak kullanıldığı COK yöntemi kullanılmış ve yöntemler karşılaştırılmıştır. Uygun yöntem seçimi ve ikincil veri olarak yüksekliğin kullanımının önemi vurgulanmıştır.

Ly ve ark. (2011), Belçika'daki iki dağ havzasında, farklı jeostatistik yöntemlerin ve teorik variogram modellerinin günlük yağışların mekânsal dağılımının tahmini üzerindeki etkilerini araştırmıştır. Çalışmada kriging, COK, evrensel kriging, KED, IDW ve Thiessen Poligonları yöntemleri kullanılmıştır. Elde edilen bulgulara göre yüksekliğin ikincil değer olarak kullanıldığı COK ve evrensel kriging yöntemi kriging ve IDW yöntemine göre daha düşük doğrulukta tahminler ortaya çıkarmıştır.

Chen ve ark. (2011), Güney Çin'in Dongjiang Nehri Havzasındaki yıllık yağışların mekânsal dağılımının tahmininde yüksek doğruluklu yüzey modelleme “High Accuracy Surface Modeling”, IDW, kriging ve Spline yöntemlerinin performanslarını karşılaştırmışlardır. Bulgulara göre “High Accuracy Surface Modeling” yöntemi ile daha iyi tahmin sonuçları elde edilmiştir.

Feki ve ark. (2012) Tunus'taki 106 meteoroloji istasyonundan ölçülen aylık ortalama yağış değerlerini kullanarak ilgili bölge için yağışın mekânsal dağılımının tahmin edilmesinde 3 farklı jeostatistik yönteminin performansını incelemiştir. Bu yöntemler yüksekliğin ikincil veri olarak kullanıldığı RK, KED ve COK yöntemleridir. COK yönteminin diğer yöntemlere göre daha düşük KOH ortaya çıkardığı belirtilmiştir.

Sun ve ark. (2015) çalışmalarında, Çin'de yağışların yıllık ortalama değerlerinin haritalanmasında 684 meteoroloji istasyonundan elde edilen yağış verileri ile enlem, boylam, yükseklik, eğim, yüzey pürüzlülüğü ve nehir yoğunluğu olmak üzere 6 ilişkili veri kullanılmıştır. Sıradan lineer regresyon, GWR, Hibrit yöntem olarak sunulan Lokal RK (LRK) ve Coğrafi Ağırlıklı Regresyon Kriging (GWRK) yöntemleri kullanılmıştır. Çalışmada sunulan LRK ve GWRK yöntemlerinin daha iyi tahmin değerleri elde ettiği ve kriging yöntemleri ile regresyon değerlerinden faydalanmanın verimli sonuçlar ortaya çıkarabileceği belirtilmiştir.

Kumari ve ark. (2016) çalışmalarında, Uttarakhand bölgesindeki Hint Himalayalarının engebeli, düzensiz topografyaya sahip arazisindeki yağışların mekânsal enterpolasyonu için tek değişkenli ve çok değişkenli yöntemlerin karşılaştırmasını

gerçekleştirmişlerdir. İkincil değişkenler olarak yükseklik ve eğitim verileri kullanılmıştır. kriging, COK, basit kriging, RK ve IDW yöntemleri karşılaştırılmıştır. İkincil değerlerin kullanımının tahminleri iyileştirdiği ifade edilmiştir.

Aydın ve Raja (2016) çalışmalarında, 1981-2010 dönemine ait 53 meteoroloji istasyonunun verilerini kullanarak Doğu Afrika'nın Mauritius ada ülkesinin yıllık ortalama toplam yağış dağılışı modeli deterministik yöntemlerden, Thiessen Polygon ve IDW ile stokastik yöntemlerden kriging kullanarak gerçekleştirilmişlerdir ve stokastik yöntemlerin daha doğru bir yağış modeli oluşturduğu belirtilmiştir.

Adhikary ve ark. (2017) çalışmalarında, Avustralya'nın Victoria Eyaletindeki iki nehir havzasında yağışların mekânsal dağılımını tahmin etmek için 5 farklı yöntem kullanmışlardır. Bu yöntemler, kriging, COK, RBF, IDF ve KED yöntemidir. Beş yöntem arasında, ikincil değer olarak yüksekliğin kullanıldığı COK ile en iyi tahmin doğruluğunu elde edilmiştir.

Cecinati ve ark. (2017), çalışma bölgesi olarak Güney Hollanda'daki bir nehir havzasında, yağmur ölçümlerindeki hataların mekânsal tahminler üzerindeki etkisini araştırmışlardır. Çalışmada “Kriging for Uncertain Data” ve “KED for Uncertain Data” yöntemleri sunulmuş ve kriging ve KED yöntemleri ile karşılaştırılmıştır. Yağış ölçümlerinde meydana gelen hataların göz önüne alınmasının tahminleri iyileştirebileceği ifade edilmiştir.

Çalışma alanı Türkiye’de yer almayan ve mekânsal tahminler için çeşitli yapay zekâ yöntemlerini kullanan bazı araştırmalar hakkında kaynak araştırması aşağıda verilmiştir.

Rigol ve ark. (2001) çalışma alanı olarak İngiltere, Yorkshire’da gerçekleştirdikleri çalışmalarında ileri beslemeli bir geri yayılım sinir ağı kullanarak günlük minimum hava sıcaklığının mekânsal enterpolasyonunu ele almıştır. Girdi olarak tarih ve arazi değişkenleri, komşu sıcaklık gözlemleri gibi girdiler çeşitli kombine şekillerde kullanılmıştır. Bu çalışma bir sinir ağı kullanarak, trend ve mekânsal ilişkinin mekânsal enterpolasyon yaparken birlikte değerlendirildiği ilk çalışmadır.

Merwin ve ark. (2002) sayısal yükseklik modellerinin oluşturulmasında mekânsal enterpolasyon için ANN kullanımını araştırmıştır. Gerçekleştirdikleri uygulamalara göre kriging ve ANN bulgularını karşılaştırmışlardır. Çalışmada kriging yönteminin daha uygun sonuçlara sahip olduğu belirtilmiştir.

Li ve ark. (2011) çalışmasında Random Forest, destek vektör makineleri, klasik mekânsal tahmin yöntemleri ve bu yöntemlerin kombine şekilde kullanımlarının çamur içeriğinin mekânsal tahmininde gösterdiği performansı incelemiştir.

Appelhans ve ark. (2015) Tanzanya'daki Kilimanjaro Dağı'ndaki aylık hava sıcaklığının enterpolasyonu için 14 farklı makine öğrenimi yöntemini incelemiştir. Yöntemlerin başarısını kriging yöntemine göre değerlendirmiştir.

Chen ve ark. (2017) çalışmalarında Çin'in Wanyuan bölgesinde heyelan duyarlılık haritası üretimi için maksimum entropi, destek vektör makineleri ve ANN olmak üzere 3 farklı makine öğrenmesi yöntemini kullanmışlardır. Duyarlık modelinin elde edilmesinde yükseklik, eğim gibi 11 farklı değişken ele alınmıştır.

Valizadeh ve ark. (2017) akarsu akış tahmin çalışmalarının iyileştirilmesi için hem jeoistatistik yöntemlerini hem de bazı yapay zekâ yöntemlerini ele alarak geniş bir literatür incelemesi yapmıştır.

Hengl ve ark. (2018) potansiyel doğal bitki örtüsünün haritalanması için makine öğrenimi algoritmalarını değerlendirmiştir. Makine öğreniminin, bitki örtüsü dağılımını etkili bir şekilde tahmin edebileceği belirtilmiştir.

Li (2019) çalışmasında mekânsal tahmin yöntemlerinin tahmin süreçlerine, uygun tahmin yaklaşımlarına ve R programlama dili ile yapılan örnek uygulamalara yer vermiştir.

Zhu ve ark. (2020) yükseklik tahmininde yeni bir yaklaşım olarak "Conditional Generative Adversial Neural Networks" yöntemi ile mekânsal tahmin gerçekleştirmiştir. Kriging ve IDW yönteminden daha iyi bulgular elde edilen yöntem ile makine öğrenmesi yöntemlerinin potansiyeli ortaya konmuştur.

Amato ve ark. (2020) çalışmalarında hava sıcaklığı çevresel değişkeni için derin öğrenmenin zaman-mekânsal kullanımını incelemiştir.

Mariano ve Monica (2021) araştırmalarında mahsul verimi haritalaması için Random Forest yöntemi temelinde sundukları algoritmayı incelemiştir. Kriging ve IDW yöntemleri ile yapılan değerlendirmelere göre sunulan yaklaşım daha iyi bir performans elde etmiştir.

Taghizadeh-Mehrjardi ve ark. (2021) çalışmalarında toprak dokusu fraksiyonlarını haritalamak için GA, PSO gibi bazı sezgisel optimizasyon algoritmalarının ANN yöntemi ile hibrit bir şekilde kullanımı ele almıştır. Sezgisel algoritmaların ANN modellerini geliştirmede etkili olabileceği belirtilmiştir.

Yağışların mekânsal tahminleri için çeşitli yapay zekâ yöntemlerini kullanan bazı araştırmalar hakkında kaynak araştırması aşağıda verilmiştir.

Chang ve ark. (2005) çalışmalarında yağışın mekânsal dağılımının tahmin edilmesi için bulanık mantık ve IDW yöntemini kombine etmişlerdir. Modifiye bu metodun bulanık mantık üyelik fonksiyonlarının parametrelerinin belirlenmesi için ise GA kullanılmıştır. Kuzey Tayvan'ın Feitsui havzası bölgesinde yapılan çalışmada modifiye yöntemin geleneksel yöntemlerden daha iyi olabileceği belirtilmiştir.

Kalteh ve Berndtsson (2007), Kuzey İran'da yağışın zaman ve mekânda enterpolasyonu için daha iyi ve verimli yöntemler bulmak adına, yapay sinir ağı yöntemlerinden "Self Organizing Maps" ve "Multi Layer Perceptron" yöntemlerini çalışmalarında kullanmışlardır.

Teegavarapu ve ark. (2009) çalışmalarında eksik yağış verilerinin tahmini için çalışmalarında gösterdikleri "Fixed Functional Set Genetic Algorithm Method" yöntemini kullanmışlardır. Bu yöntem ile yağış gözlemleri ve diğer parametreler arasında fonksiyonel bir form sağlanmış olunur. Çalışma bulguları, yöntemin sonuçlarının geleneksel bir IDW yaklaşımına göre daha iyi olduğu yönündedir.

Seo ve ark. (2015), çalışmalarında Güney Kore Jeju Adasında yağışların mekânsal dağılımının haritalanmasında mevcut yaygın yöntemler ile çalışmalarında sundukları iki yöntemin kombine edilmesi ile hibrit bir yöntem olan "Regression Kriging and Neural Network Residual Kriging" yöntemini karşılaştırmışlardır. Çalışmada karşılaştırma için kullanılan diğer yöntemler kriging, evrensel kriging, basit kriging ve RK yöntemleridir. Sunulan hibrit yöntemin tahmin doğruluklarını iyileştirdiği belirtilmiştir.

Kajornrit ve ark. (2016) çalışmalarında, Tayland'ın kuzeydoğu bölgesinde 80 yağış gözlem istasyonu kullanarak yağışların mekânsal dağılımının tahmin edilmesinde yorumlanabilir bir yöntem ile nasıl bir yaklaşım izlenebileceğini göstermişlerdir. Çalışmada GA ile eğitilen Mamdani tipi bir bulanık çıkarım sistemi yöntemi ele alınmıştır. Mekânsal tahminlerde önerilen yöntem ile ANN, ANFIS, IDW, RBF ağı ve kriging yöntemleri karşılaştırılmıştır. Çeşitli hususlara göre yöntemlerin performansları değerlendirilmiştir. Önerilen yöntemin uygun tahmin sonuçları elde ettiği ve yorumlanabilir olması açısından avantajları belirtilmiştir.

Attar ve ark. (2019) optimum yağış ölçüm ağı tasarımına yönelik bir yaklaşım geliştirmiştir. Jeostatistik ve bir sezgisel optimizasyon yöntemini bir arada kullanan araştırmacılar, yaklaşımın etkili bir şekilde kullanılabileceğini göstermiştir.



Hu ve ark. (2019), yağıřların mekânsal tahmini için farklı veri kaynaklarının entegrasyonu ve mekânsal tahmine yönelik yöntemleri çalışmaları ele almıştır.

Sekulić ve ark. (2020); Sekulić ve ark. (2021) çalışmalarında Random Forest yönteminin yağıř gibi çeşitli meteorolojik deęişkenlerin mekânsal tahmini için kullanılmasını inceleyerek yöntemin potansiyelini göstermişlerdir.

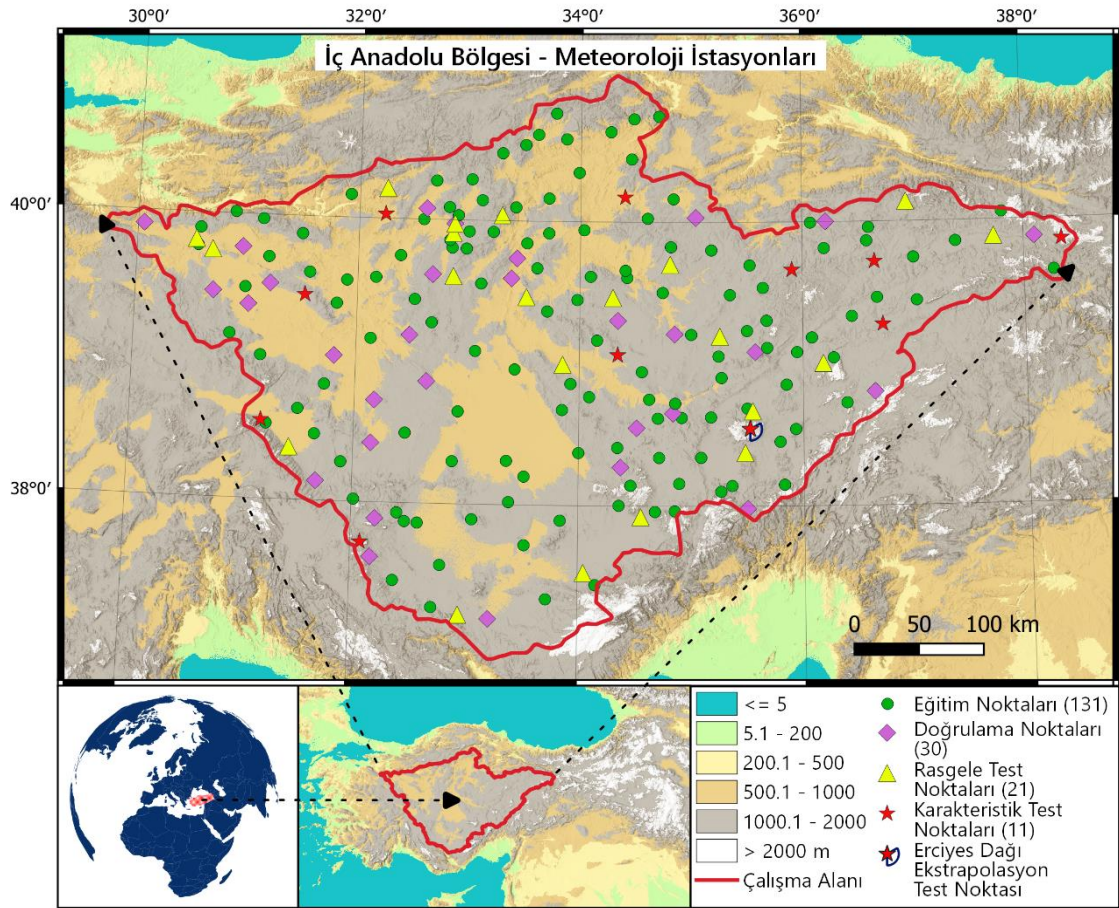
Bayat ve ark. (2021) çalışmalarında yağıř ölçüm aęı tasarımı için bulanık mantık ve IDW mekânsal enterpolasyon yöntemini bir arada kullanan bir yaklaşım sunarak, yağıř verisi toplamak üzere aę tasarımını ele almışlardır.



### 3. MATERYAL VE YÖNTEM

Tez çalışmasında Türkiye'nin İç Anadolu Bölgesi için 2016 yılında görülen aylık ortalama yağış büyüklüklerinin ANN, ANFIS, PSO, GA, Geo-HUSREV, kriging, COK ve RK yöntemlerinin kullanılması ile mekânsal dağılımlarının tahmin edilmesi için uygulamalar gerçekleştirilmiştir.


Çalışma alanı  $29.7219^{\circ}$  –  $38.4601^{\circ}$  doğu boylamları ve  $36.9273^{\circ}$ - $41.0105^{\circ}$  kuzey enlemleri arasında yer almaktadır. Bölgenin 2016 yılı aylık yağış ortalaması 30.01 mm'dir. En yüksek kot yaklaşık 3900 m ve en düşük kot 342 m'dir. Ülkenin nispeten daha engebesiz bir bölgesidir. Bölgede 193 adet meteoroloji istasyonu yer almaktadır. Bu istasyonlara ait yağış büyüklükleri MGM'den temin edilmiştir. Yağış verilerine ait özet istatistikler Çizelge 3.1. ile verilmiştir. ANN ve ANFIS uygulamaları için istasyonların yaklaşık %68'i eğitim %16'sı doğrulama %16'sı ise test noktası olarak belirlenmiştir. Eğitim ve doğrulama verileri rasgele olarak seçilmiştir. Test noktaları hesaplamalarda hiç kullanılmamıştır. Test noktalarından 11 istasyon karakteristik noktalar olarak performans değerlendirmelerinde kullanılmak üzere seçilmiştir. Karakteristik noktaların özellikleri Çizelge 3.2. ile verilmiştir. Geriye kalan test noktaları rasgele olarak belirlenmiştir. Karakteristik test noktası olarak belirlenen noktalardan birisi veri setinin dışında kalan, en yüksek yağış alan ekstrapolasyon test noktasıdır. Bu nokta Erciyes Dağı üzerinde yer almaktadır ve yöntemlerin ekstrapolasyon başarısını incelemek için kullanılmıştır. Kriging uygulamaları için ise eğitim ve doğrulama noktaları bir arada kullanılarak enterpolasyon gerçekleştirilmiştir. Test noktaları ile tahmin performansları değerlendirilmiştir. Şekil 3.1.'de çalışma alanı ve istasyon noktaları gösterilmiştir. Şekil 3.2. ile yağış değerlerinin mekânsal trend grafiği gösterilmiştir. Şekil 3.3. ile yağış değerlerinin histogram ve Q-Q çizimi grafiği gösterilmiştir. Çizelge 3.3. ile uygulamalarda kullanılan girdiler, girdilerin tahmin bulguları çizelgelerinde temsil edildiği kısaltmaları ve girdilere ait veri setlerinin çözünürlük bilgileri verilmiştir.




Şekil 3.1. Çalışma alanı ve meteoroloji istasyonları

Çizelge 3.1. 2016 Yılı aylık yağış gözlemlerinin özet istatistikleri

Meteorolojik İstasyon Sayısı	193	Minimum değer	9.22 mm
Ortalama	30.01 mm	Maksimum değer	85.38 mm
1. Çeyrek değer	22.31 mm	Standart sapma	10.66 mm
Ortanca	29.5 mm	Çarpıklık	0.83
3. Çeyrek değer	36.76 mm	Basıklık	5.82



Şekil 3.2. Yağış değerlerinin mekânsal trend grafiği



Şekil 3.3. Yağış değerlerinin histogram ve Q-Q çizim grafiği

Çizelge 3.2. Karakteristik test noktaları ve özellikleri

Karakteristik Test Noktaları		Sayı	Tahmin türü
Test noktasının özelliği	En yüksek yağış ekstrapolasyon noktası	1	Ekstrapolasyon
	Maksimum yağış	1	Enterpolasyon
	Ortalama yağış	1	Enterpolasyon
	Minimum yağış	1	Enterpolasyon
	Maksimum yükseklik ekstrapolasyon noktası	1	Ekstrapolasyon
	Maksimum yükseklik	1	Enterpolasyon
	Ortalama yükseklik	1	Enterpolasyon
	Düşük yükseklik	1	Enterpolasyon
	Seyrek istasyon bulunan konumlar	3	Enterpolasyon

Çizelge 3.3. Tahminlerde kullanılan girdiler ve kısaltmaları

Tahminlerde Kullanılan Girdiler	Kısaltma	Çözünürlük
1 Enlem	En.	0.01°X0.01°
2 Boylam	Boy.	0.01°X0.01°
3 Yükseklik	Yük.	0.01°X0.01°
4 Denize Uzaklık	D.U.	0.01°X0.01°
5 Bakı	Bakı	0.01°X0.01°
6 Eğim	Eğim	0.01°X0.01°
7 1. En yakın komşu değeri	K1	0.01°X0.01°
8 2. En yakın komşu değeri	K2	0.01°X0.01°
9 3. En yakın komşu değeri	K3	0.01°X0.01°
10 4. En yakın komşu değeri	K4	0.01°X0.01°
11 5. En yakın komşu değeri	K5	0.01°X0.01°
12 Akarsulara Uzaklık	A.U.	0.01°X0.01°
13 Göllere Uzaklık	G.U.	0.01°X0.01°
14 NASA GPM IMERG V3	GPM	0.1°X0.1°
15 FLDAS Hava Sıcaklığı	Sıc.	0.1°X0.1°
16 FLDAS Nem	Nem	0.1°X0.1°
17 FLDAS Yüzey Basıncı	Bas.	0.1°X0.1°

Çalışmada yağışların mekânsal dağılımının tahmini için ANN, ANFIS, kriging, COK, RK ve Geo-HUSREV yöntemleri kullanılmıştır. ANN için Levenberg-Marquardt (LM) algoritması ve Ölçeklenmiş Konjüge Gradyen Algoritması (Scaled Conjugate Gradient, SCG) algoritmaları kullanılmıştır. Ayrıca ANN için tek ve iki gizli katmanlı olarak 2'den 20 ye kadar değişen nöron sayıları denenmiştir. Her uygulama 5 kez yeniden eğitilmiştir. ANN yöntemi ile 5293400 uygulama gerçekleştirilmiştir. ANFIS yöntemi için lineer ve sabit bulanık çıkarım sistemi çıktısı ile farklı bulanık çıkarım sistemleri kullanılmıştır. Bulanık C-Ortalamalar (Fuzzy C-Means, FCM) kümeleme yöntemi ile elde edilen iki, üç ve dört üyelik fonksiyonundan oluşan uygulamalar ile geri yayılım (GY) ve hibrit öğrenme algoritmaları kullanılmıştır. Böylece ANFIS ile 22288 uygulama gerçekleştirilmiştir. Kullanılan girdiler, yöntemlere ait eğitim algoritmaları ve kullanılan bazı parametrelerin tahminlere etkisinin araştırılması için çok sayıda uygulama gerçekleştirilmiştir. Uygulama akışı Şekil 3.4. ile verilmiştir. En uygun tahmin bulgularına sahip uygulamaların haritaları elde edilmiştir. Ayrıca en iyi bulgulara sahip ANN ve ANFIS uygulamaları PSO ve GA ile hibrit şekilde yeniden uygulanarak PSO ve GA yöntemlerinin tahminlerde kullanımı da araştırılmıştır. ANN, ANFIS, kriging, COK, RK ve Geo-HUSREV yöntemleri ile elde edilen en iyi tahmin bulguları karşılaştırılmıştır. Konya Teknik Üniversitesi tarafından lisansı sağlanan MATLAB 2021a ve açık kaynak kodlu QGIS 3.16.16 yazılımı kullanılan çalışmada yapay zekâ yöntemleri ile elde edilen uygun tahmin modelleri, çalışma alanı için üretilen  $0.01^\circ \times 0.01^\circ$  çözünürlüklü grid noktaları üzerinde simüle edilerek bölgenin yağış haritaları elde edilmiştir. Yapay zekâ uygulamaları ve Geo-HUSREV yöntemi için tasarlanan mekânsal tahmin metodolojisi MATLAB ortamında programlanmıştır. Yağışların mekânsal dağılımının tahmini için enlem, boylam, yükseklik (Advanced Spaceborne Thermal Emission and Reflection Radiometer - Global Digital Elevation Model Version 3, ASTER-GDEM 003) (NASA ve ark., 2019), denize uzaklık, bakı, eğim, en yakın istasyondan beşinci en yakın istasyona kadar istasyon yağış değerleri, NASA GPM'in GPM\_3IMERG\_06 (The Integrated Multi-satellitE Retrievals for GPM) (Final Run) (Huffman ve ark., 2019) 2016 yılı aylık ortalama yağış gözlemleri, göllere uzaklık, akarsulara uzaklık sıcaklık, nem ve basınç verisi olmak üzere 17 farklı değişken ele alınmıştır. Sıcaklık, nem ve basınç verileri NASA-FLDAS (Famine Early Warning Systems Network Land Data Assimilation System) projesinden temin edilmiştir (McNally ve NASA/GSFC/HSL, 2018). Akarsulara ve göllere uzaklık değişkenleri OpenStreetMap platformundan sağlanan akarsu ve göl verileri ile yağış istasyonları arasındaki uzaklık hesaplanarak oluşturulmuştur. Yağış

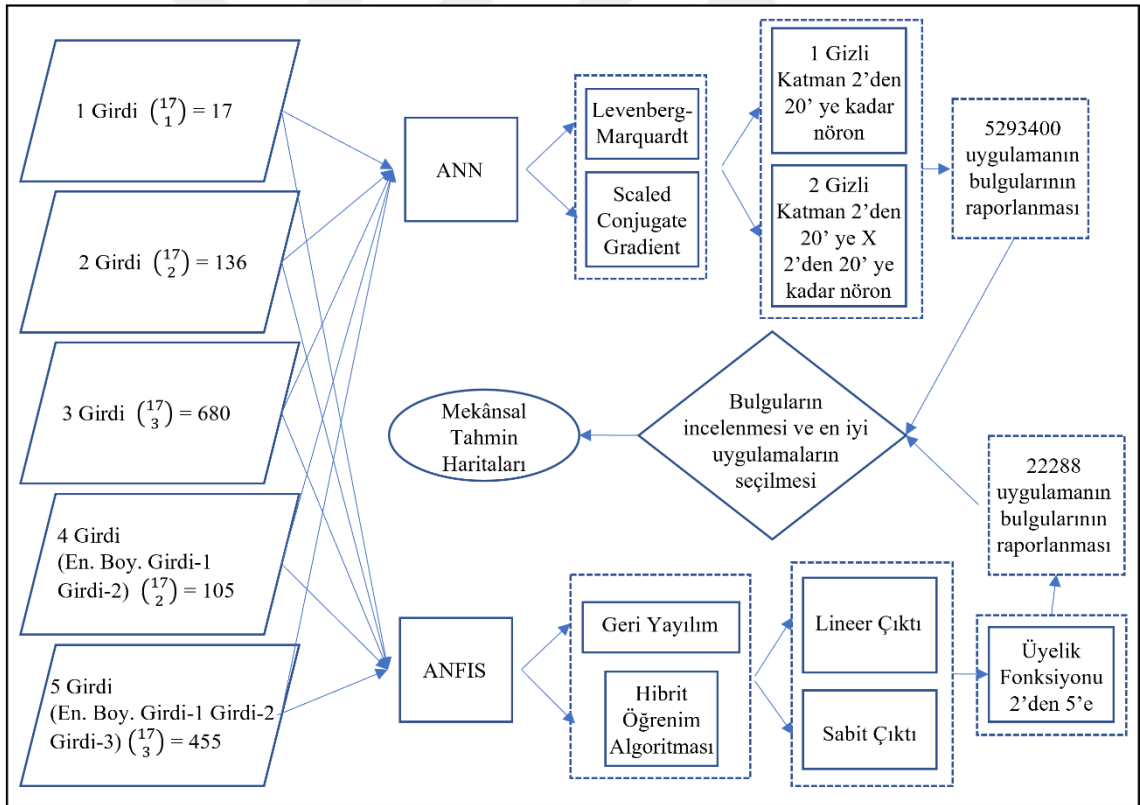
değeri bilinmeyen konumların tahmini için çalışma alanı boyunca 172157 nokta ile  $0.01^\circ \times 0.01^\circ$  derece ( $\sim 1\text{km}$ ,  $\sim 36$  yay saniyesi) çözünürlükte grid veri seti oluşturulmuştur. Bu grid veri setine ait her nokta için tahminlerde girdi olarak kullanılan 17 değişkenin değeri sağlanmıştır. Grid veri setinde yer alan noktaların tahminlerde kullanılan yağış istasyonlarına göre en yakın komşu değerlerinin hesaplanması, akarsulara, göllere, denize uzaklıkların hesaplanması işlemleri QGIS 3.16.16 yazılımı ile gerçekleştirilmiştir. Bu sayede yağış değeri bilinmeyen ancak tahmin modellerinde kullanılan girdi değerleri bilinen noktalar için eğitilmiş yapay zekâ tahmin modelleri kullanılarak mekânsal yağış tahminleri gerçekleştirilmiştir.

Tahmin girdileri olarak 1 değişken, 2 değişken, 3 değişken, 4 değişken ve 5 değişken bir arada olacak şekilde uygulamalar gerçekleştirilmiştir. Değişkenlerin tüm girdi kombinasyonları incelenmiştir ancak 4 ve 5 değişkenli uygulamalarda enlem ve boylam girdileri ilk iki girdi olarak sabit tutulmuştur.

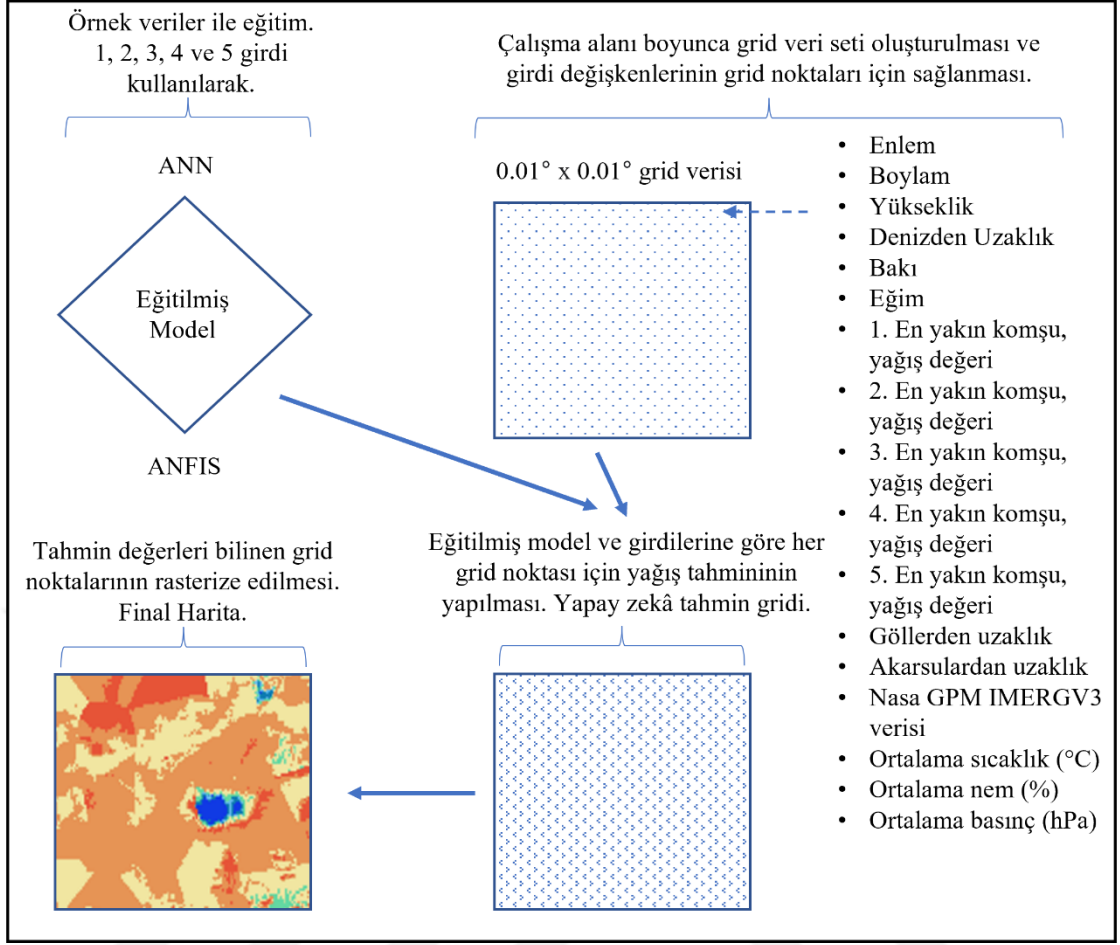
Çalışmada farklı girdiler, öğrenim algoritmaları gibi farklı parametrelere göre binlerce uygulama gerçekleştirilmiştir. Her uygulama için 1000 iterasyon gerçekleştirilmiş olup en iyi doğrulama hatası elde edilen iterasyona ait bulguların, sınır ağı yapısı ve bulanık çıkarım sistemi yapısı kaydedilmiştir. En düşük doğrulama hatası görülen iterasyonun test, doğrulama ve eğitim noktalarına ait KOH, korelasyon katsayısı (R) ve karakteristik noktalarda görülen hata değerleri ile tahmin bulguları kaydedilerek raporlanmıştır. En uygun tahmin performansına sahip uygulamayı belirlemek ve parametreleri kıyaslayabilmek için binlerce uygulama arasından farklı girdi sayıları ve kullanılan eğitim algoritmalarının her biri için en düşük test KOH değeri ve en düşük ekstrapolasyon hatası sağlayan uygulamalar belirlenmiştir. Böylece ANN ve ANFIS için farklı uygulama performansları incelenerek bulgular tartışılmıştır. Elde edilen ANN ve ANFIS bulgularından en iyi tahmin performansına sahip uygulamalar ile aynı girdileri kullanan COK, RK ve Geo-HUSREV uygulamaları gerçekleştirilmiştir. Yalnızca KOH ve R değerleri değil karakteristik noktalarda görülen hataların da ele alınması ile daha gerçekçi bir şekilde en uygun mekânsal tahmin yaklaşımı araştırılmıştır.

Jeostatistik veya deterministik yöntemler ile hali hazırda tahmin yüzeyi matematiksel olarak temsil edilirken yapay zekâ yöntemleri ile yapılacak her tahmin, tahmini yapılan noktaya özeldir. Bu çalışmada örnek noktalara ait girdi ve hedef değerleri ile eğitilen yapay zekâ modellerinin haritalanması için bir çerçeve sunulmuştur. Bu çerçeve ile nokta özellikli verilerin eğitimi sonrasında nasıl harita üretilebileceği gösterilmiştir. Çalışmada çalışma alanını kapsayan bölge için oluşturulan grid veri seti ile

haritalar üretilmiştir. Bu grid veri seti içinde yer alan her nokta için tahminlerde girdi olarak kullanılan 17 değişkenin değerleri elde edilmiştir. Örneğin enlem, boylam ve yüksekliğe göre gerçekleştirilen ANN veya ANFIS eğitim modellerine, grid veri setinde yer alan noktaların enlem, boylam ve yükseklik değerleri verilerek bu noktalar için eğitim modeli simüle edilir ve tahminler elde edilir. Grid veri seti için her noktada yapılan simülasyon ya da tahmin işlemi sonrasında grid veri seti rasterize edilerek yağışların mekânsal dağılım haritaları elde edilmiştir. Bu yaklaşım oldukça pratik ve nokta bazlı verilere sahip uygulamalar için oldukça verimlidir. Haritalama işlemi Şekil 3.5. ile temsil edilmiştir. Böylece araştırmacılar çalışmada sunulan yaklaşımı kullanarak belirli noktalara ait öznitelikler sayesinde yapay zekâ yöntemleri ile elde ettikleri eğitim modeline ait tahminleri haritalayabilecekleridir. Bu şekilde sunulan haritalama çerçevesi istasyon noktaları değerleri ile tahminlerini zamansal boyutta da ele alacak çalışmaların haritalanması için de faydalı olacaktır.



Şekil 3.4. Uygulama akış diyagramı




Şekil 3.5. Yapay zekâ mekânsal tahminlerinin haritalanması

### 3.1. Yapay Sinir Ağları (ANN)


McCulloch ve Pitts (1943) tarafından sunulan ANN, biyolojik sinir ağlarının yapısına dayanır ve insan beyninin taklit edilmesi amacıyla sinir hücrelerini temel alan ve birbirine ağ şeklinde bağlı yapay nöronlardan oluşan bir hesaplama modelidir. (McCulloch ve Pitts, 1943; Sammut ve Webb, 2017; Yılmaz, 2019). ANN, yapay zekâ yöntemlerinden biri olarak insan beynini modelleyerek taklit etme çabası olarak insan beyninde bulunan biyolojik sinir (Nöron) hücrelerini temel alır (Yılmaz, 2019). Görüntü işlemeden tercüme kadar çok çeşitli alanlarda kullanılmaktadır. ANN yöntemi öğrenme yeteneği sayesinde, kümeleme, tahmin etme gibi işlemleri gerçekleştirilebilmektedir. Biyolojik sinir ağlarını taklit eden ANN yöntemi yapay bir sinir yapısı kullanır. Yapay bir sinir yapısal olarak girdiler, sabit (Bias) ve çıktı değerinden oluşur (Özkaya, 2020). Aktivasyon fonksiyonu olarak sigmoid çıkışı kullanan yapay bir sinir modeli ve bağlantıları Şekil 3.6. ile gösterilmektedir.





Şekil 3.6. Yapay sinir modeli

Sinir hücreleri ayrı bellek yapılarına sahiptir ve birbirlerine üzerinde ağırlık olarak isimlendirilen değerler bulunan bağlantılar aracılığıyla bağlanmaktadır. ANN mantığında problemi kendi kendine öğrenme yatmaktadır (Yılmaz, 2019). Öğrenme işlemi ağırlıkların değişmesi ile gerçekleştirilir (Kubat, 2014). ANN yapılarına göre farklı öğrenme algoritmaları kullanılır ve bu öğrenme yaklaşımlarına göre ağırlıklar değiştirilir. Danışmanlı öğrenimde verilen girdilere, karşılığı olan hedef değerler verilir. ANN en basit haliyle girdi verilerini içeren giriş, gizli ve çıktı katmanları olmak üzere üç ana katmandan oluşur. Bu katmanlar arasında çıktı katmanında elde edilen değerler hedef değerlere yaklaşıncaya kadar yapay nöronları temsil eden düğümler arasındaki ağırlıklar ayarlanabilir şekilde yinelemeli olarak ayarlanır ve öğrenme süreci gerçekleşir (Kubat, 2014; Sammut ve Webb, 2017; Sadighi ve ark., 2020). Ağırlıkların değişimi öğrenme sürecini ifade eder ve ağırlıklar değişmediğinde öğrenme işlemi sonlanmış anlamına gelir (Sağiroğlu ve ark., 2003). Sinir hücrelerini ve bu sinirlerin birbirleri arasındaki bağlantılarını temel alan ANN için farklı çeşitlerde sinir ağı yaklaşımları kullanılmaktadır. Uygulanan ağ modeline göre farklı özellikler elde edilebilmektedir. Sinir ağları çok katmanlı olarak kullanılmakla birlikte sinir hücresi sayısının, katman sayısının ve öğrenme fonksiyonu gibi çeşitli yaklaşımların seçimi, yöntemi uygulayan kişi tarafından belirlenir. Şekil 3.7. ile çok katmanlı bir sinir ağı modeli gösterilmektedir.



**Şekil 3.7.** Çok katmanlı bir sinir ağı modeli

Sinir ağının eğitimi için danışmanlı öğrenim yaklaşımında girdi verilere karşılık çıktı veriler verilir ve ağ kendini iteratif olarak belirlenen öğrenme algoritmasına göre uyarlar. Sonuç olarak girdi ve çıktı veriler arasındaki ilişki ağ yapısında temsil edilebilir hale gelir. Böylece çıktı değeri bilinmeyen, araştırılan değişkenler için sinir ağından faydalanılarak tahminler gerçekleştirmek mümkün olur. Ayrıca ANN yöntemi ile çıktı veriler verilmeden danışmansız eğitim ile kümeleme, sınıflandırma yaklaşımları da uygulanabilir. ANN yöntemi genellikle doğrusal olmayan ve karmaşık veriler arasındaki ilişkileri öğrenerek modellemek veya veriler arasındaki dokuları tespit etmek için başarılı bir yöntem olarak yaygın kullanılır (Daniel, 2013).

ANN'nin avantajları ve dezavantajları hakkında bazı bilgiler Yılmaz (2019)'a göre şu şekildedir;

- Doğrusal olmayan problemlerin çözümü için de başarılıdır.
- Öğrenme sırasında hiç karşılaşılmayan örnekler hakkında da bilgi üretilebilir.
- Matematik bir modele ihtiyaç duymaz.
- Paralel işlem yapabilme yeteneğine sahiptir.
- Uygun ağın oluşturulması için belirli kurallar yoktur, tecrübe ve deneme yanılma gerektirebilir.
- Sayısal olmayan parametreler sayısal değerlere dönüştürülmelidir.
- Eğitim süreci yetersiz veya aşırı ezberleme ile sonuçlanabilir.

- Eğitilen ağ, çözümlerinin nasıl, neden olduğuna dair bilgi vermez ve bazı ağlar dışında ne derece kararlı olduğu analiz edilemez.

ANN'lar çok sayıda mevcut olan, farklı eğitim algoritmaları ile eğitilebilir. LM algoritması robust ve hızlı olması nedeniyle ANN'ları eğitmek için sıklıkla kullanılır. Gauss-Newton algoritması ile en dik iniş algoritmalarının özelliklerinin bir kombinasyonu olarak görülebilir. Bu sayede hızlı yakınsama ve lokal minimuma takılmama yeteneklerinden faydalanılır. LM algoritması, ağırlıklarını ve yanlılık değerlerini iteratif olarak belirleyen bir eğitim algoritması olarak kullanılır. Bu işlemin amacı, ağırlıkların tahmin çıktılarını ile gerçek hedef çıktılarını arasındaki farkı en aza indirmektir (Sağiroğlu ve ark., 2003).

SCG, ANN'ları eğitmek için başka bir optimizasyon algoritmasıdır. Geleneksel gradyan iniş algoritmalarından farklı olarak kullanıcı tanımlı kritik parametreler içermez ve zaman alan doğrudan arama işlemine olan ihtiyacı ortadan kaldırır. SCG'nin, özellikle çok sayıda girdi veya gizli birim içeren problemler için GY'dan daha hızlı olması beklenir ve hesap yükü azdır (Møller, 1993; Sağiroğlu ve ark., 2003).

Uygulama açısından, her iki algoritma da uygun fonksiyonlar ve araç kutuları kullanılarak bir MATLAB ortamında uygulanabilir (Çakır, 2018).

Bu çalışmada girdi katmanı için 1'den 5 girdiye kadar farklı uygulamalar gerçekleştirilmiştir. Gizli katman için tek katmanlı ve iki gizli katmanlı uygulamalar gerçekleştirilmiştir. Tek katmanlı sinir ağı yapısında 2 nöron dan 20 nöron a kadar, çift katmanlı sinir ağı uygulamalarında ise her katmanda 2 nöron dan 20 nöron a kadar muhtemel tüm kombinasyonlar denenmiştir. ANN uygulamalarında yaygın olarak kullanılan LM algoritması ve SCG öğrenme algoritmaları kullanılmıştır. Bu parametrelerin hepsi ile deneysel uygulamalar gerçekleştirilmiştir. Uygulamalar rasgele ağırlıklar ile başladığı için her uygulama 5 kez yeniden eğitilmiştir. Girdiler, katman sayısı, nöron sayısı ve algoritmalar hakkında yorum yapabilmek için çok sayıda uygulama sonucu elde edilmiştir. Ayrıca en uygun ANN uygulamaları sonraki başlıklarda anlatılacak olan PSO ve GA yöntemleri ile eğitilerek, sezgisel optimizasyon algoritmalarının ANN eğitiminde kullanımı da araştırılmıştır.

### 3.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS)

Elmas (2018)' a göre ANN öğrenme ve tanımlama konularında oldukça başarılı iken kararların nasıl alındığı konusunda iyi değildir. Bulanık mantık ise karar verme

mekanizması açısından karar verme problemlerinde son derece etkilidir. Ancak bulanık mantık ile karar verme için karar alma sürecindeki kural oluşturmayı bir uzmanın tecrübesine dayanarak gerçekleştirmek gerekir (Elmas, 2018; Yılmaz, 2019). Farklı her konu için yapılacak bulanık çıkarımlar için o konulardaki uzmanlara ihtiyaç duyulur ve uzmanlar deneme yanılma yöntemi ile bulanık çıkarım sistemini tasarlarlar. ANN yönteminin öğrenme yeteneği ve bulanık mantığın karar verme yeteneği bir arada kullanılarak hibrit bir sistem olan sinirsel bulanık mantık yaklaşımı, Jang (1993) tarafından ortaya konmuştur. ANFIS bir sinirsel bulanık çıkarım yöntemidir. “Adaptive Neuro Fuzzy Inference System” veya “Adaptive Network Based Fuzzy Inference System” olarak bilinir ve bu sistemin baş harfleri kullanılarak adını almıştır. “Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi” anlamına gelmektedir. Bulanık mantık ve ANN’ların birlikte kullanıldığı hibrit bir yapay zekâ yöntemidir. ANFIS, Jang (1993) tarafından, 1993 yılında hibrit öğrenme algoritması ve Takagi-Sugeno sinirsel bulanık çıkarımı kullanılarak geliştirilmiştir. Bulanık çıkarım sisteminin oluşturulmasına ANN’dan faydalanılır. Böylece öğrenme yeteneği ve karar verme yeteneğinin birleşimi sonucunda insan gibi karar verme yeteneği ve avantajlarına sahip bir sistem ortaya çıkar (Yılmaz, 2019). ANFIS sistemi araştırılan konuya ait girdi parametreleri ve bilinen çıktılar yardımıyla uyarlanabilir bir bulanık çıkarım sistemi oluşturmaktadır. Beş katmandan oluşan ANFIS, girdi değerlerine karşılık bilinen hedef değerleri yardımıyla, GY ya da diğer öğrenme algoritmaları kullanılarak eğitim yoluyla ve iteratif olarak probleme uyarlanır (Jang, 1993; Sadighi ve ark., 2020; Hamdia ve ark., 2021). İki girişli ve iki kurallı ANFIS mimarisi Şekil 3.8. ile verilmiştir. Şekil 3.9.’da görülen üyelik fonksiyonlarının başlangıç, tepe, bitiş noktaları gibi parametreleri ve Takagi-Sugeno temelli bulanık çıkarım sisteminin sonuç hesaplamasında kullanılan fonksiyonların parametrelerinin probleme uygun şekilde uyarlanması sağlanır. Bu sayede uygun şekilde gerçekleştirilen eğitim sonucunda giriş ve çıkış verileri ilişkilendirilerek bulanık çıkarım sistemi probleme uyarlanmış olur. Ayrıca öğrenme sayesinde uzman bir kişiye gerek duyulmayabilir. ANFIS yönteminin ayırıcı ve önemli bir avantajı doğrusal olmayan ve zor problemler için bile iyi sonuçlar üretebilmesidir (Yılmaz, 2019). ANFIS hakkında ayrıntılı açıklamalar Jang (1993) tarafından verilmiştir. Ayrıca ANFIS katmalarının ayrıntılı işlem açıklamaları Elmas (2018) tarafından verilmiştir.

ANFIS uygulamalarında sıklıkla GY ve hibrit öğrenme algoritmaları kullanılır.

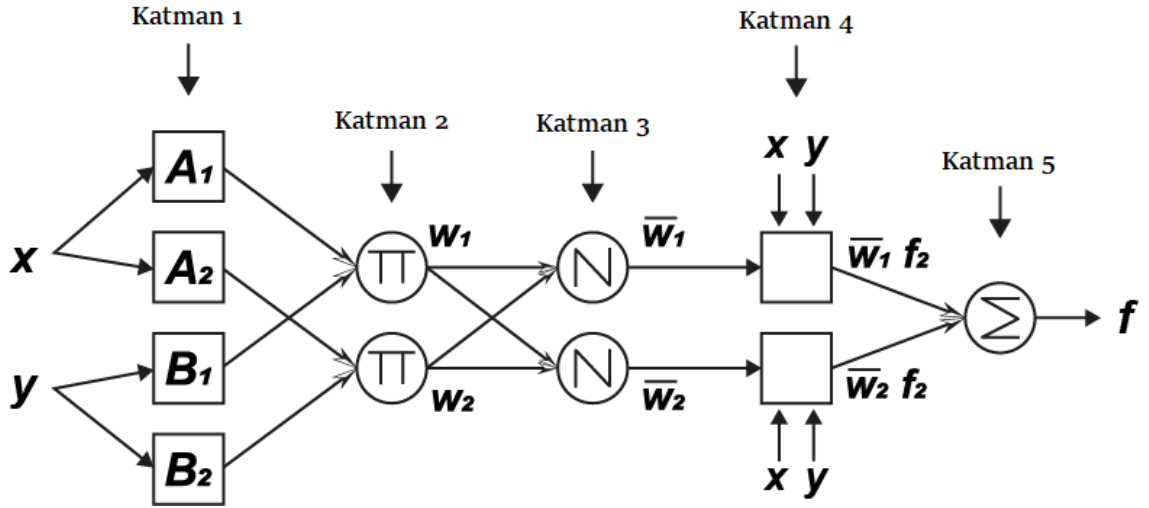
GY algoritması çıktı değerinin bilinen değeri ile tahmin değerini karşılaştırarak, tahmin hatasını hesaplar ve hatayı en aza indirmek için ağırlıkları değiştirerek ağ üzerinde

yeni ağırlıkları iteratif olarak ağı geri yayar. GY algoritması, ANN için temel ve yaygın bir eğitim algoritmasıdır (Sağırođlu ve ark., 2003).


Buna karřılık, ANFIS için Jang (1993) tarafından geliştirilmiř olan Hibrit Öğrenme algoritması, hem gradyan iniř hem de en küçük kareler tahmini tekniklerini içerir. Bu birleřik yaklařım, lokal minimuma takılmayı önlemek ve daha hızlı çözümler elde etmek için kullanılmıřtır (Jang, 1993).

Bu çalıřmada ANFIS uygulamaları için ‘‘Gaussian’’ tip üyelik fonksiyonu kullanılmıřtır. Hem lineer hem de sabit çıktı üyelik fonksiyonları kullanılmıřtır. Öğrenme algoritması için GY ve Jang (1993) tarafından geliştirilen hibrit öğrenme algoritması kullanılmıřtır.

Bir, iki, üç, dört ve beř girdi ile yağıř tahmini yapılan ayrı uygulamalar gerçekleřtirilmiřtir. Sugeno bulanık çıkarım sisteminin oluřturulmasında ‘‘boyut laneti’’ (Curse of dimensionality) olarak ifade edilen problemten kaçınmak için FCM kümeleme yöntemi kullanılmıřtır (Jang, 2023). Bu sayede ANFIS yöntemi için daha az sayıda kural oluřturularak girdi ve veri sayısına göre eğitim süreci için daha kolay bir yapı sađlanır. FCM yöntemi ile eğitim setine göre her girdi için 2, 3, 4 ve 5 üyelik fonksiyonlarından oluřan bulanık çıkarım sistemleri oluřturularak ayrı uygulamalar gerçekleřtirilmiřtir.



řekil 3.8. İki giriřli ve iki kurallı ANFIS mimarisi (Jang, 1993)



Şekil 3.9. Sugeno tipi bulanık çıkarım sistemi (Jang, 1993)

### 3.3. Yapay Zekâ Optimizasyon Algoritmaları

Bu çalışmada ANN ve ANFIS için kullanılan klasik eğitim algoritmaları yerine literatürde sıklıkla kullanılan PSO ve GA yöntemlerinin eğitim sürecinde kullanılması da incelenmiştir. Ayrıca tez çalışmasında tanıtilen Kriging-HUSREV yönteminin uygulanışı sırasında Yapay Arı Kolonisi Algoritması (Artificial Bee Colony, ABC) algoritması kullanılmıştır.

Yapay zekâ optimizasyon algoritmaları karmaşık problemleri çözmek ve çözüme en hızlı şekilde ulaşmak için kullanılmaktadır. Optimizasyon, çözüm uzayında en iyi çözümün yani bilinmeyen parametre değerlerinin aranıp bulunması ile ilgilidir. Genellikle belirlenen çözüm uzayından en uygun olanın seçilmesini ifade eder. Minimize veya maksimize edilmesi istenen bir maliyet ya da kâr fonksiyonu sonucuna göre iteratif olarak, kullanılan optimizasyon yöntemine göre çözüm aranır (Karaboğa, 2018). Analitik olarak çözülmesi çok zor olan veya karmaşık ve lineer olmayan problemlerin çözümlerini bulabilmek için çeşitli sezgisel optimizasyon algoritmalarının çözüm uzaylarında çözüm bulma stratejilerinden faydalanılmaktadır. PSO, GA ve ABC algoritmaları en çok bilinen sezgisel optimizasyon algoritmalarındandır.

Sezgisel optimizasyon algoritmaları ANN ve ANFIS çalışmalarında lokal minimuma takılma sorunu olan, yaygın olarak kullanılan klasik eğitim algoritmaları yerine daha iyi eğitim modelleri elde etmek için araştırmalarda kullanılmaktadır (Azad ve ark., 2019; Moayedı ve ark., 2019). Bu çalışmada, PSO ve GA en iyi tahmin bulguları gösteren ANN ve ANFIS yöntemlerinin eğitim algoritması olarak uygulanmıştır. PSO ve GA kullanımının tahminlere belirgin bir etkisinin olup olmayacağı araştırılmıştır. PSO ve GA uygulamalarında popülasyon büyüklüğü 25, 50, 100 ve 200, iterasyon sayısı 1000

olarak belirlenmiştir. Minimize edilmesi istenen değer için, maliyet fonksiyonu olarak tahminlerin KOH değerini bulan bir fonksiyon kullanılmıştır.

### 3.3.1. Parçacık sürü optimizasyonu (PSO)

PSO, Kennedy ve Eberhart (1995) tarafından geliştirilen bir sezgisel optimizasyon yöntemi olup incelenen problemler için en iyi çözümün bulunması için kullanılır.

PSO, doğadaki sürülerin davranışını taklit eden popülasyon tabanlı optimizasyon teknikleri arasındadır. Bu yöntem çözüm aramak için, yiyecek araştırma hedefi olan bir kuş sürüsü gibi sürü davranışlarından faydalanır (Karaboğa, 2018). PSO'da, ilk olarak rasgele konuma sahip olan popülasyon en iyi çözüm buluna kadar iteratif olarak, sürü halinde konumunu günceller. Her konum bir çözümü temsil eder. Parçacıklar adı verilen aday çözümler sürü halinde en iyi çözüm için hızlarını, yönlerini güncelleyerek en iyi çözümü arar. En iyi çözümler daha iyisi bulunana kadar depolanır. Belirtilen koşul sağlandığında veya iterasyon sayısı tamamlandığında saklanan en iyi çözüm kullanılır (Kennedy ve Eberhart, 1995; Poli ve ark., 2007; Kennedy, 2017; Karaboğa, 2018).

### 3.3.2. Genetik algoritma (GA)

GA, Michigan Üniversitesi'nde, John Holland tarafından tanıtıldı (Holland, 1975). Biyolojiden ve evrim teorisinden ilham alan bu algoritma, evrimsel algoritmalar sınıfındadır. GA işleyişi, seçim, çaprazlama ve mutasyon dahil olmak üzere, tabii seçme ve genetik gelişim temelinde tasarlanmıştır (Karaboğa, 2018). Başlangıçta, rasgele çözümlerden oluşan bir popülasyon oluşturulur ve her birey araştırılan sorun için potansiyel bir çözümü temsil eder. Kalitesi yüksek olanın hayatta kalması ilkesine dayanan seçim, sorunu ne kadar iyi çözdüklerini ölçen bir uygunluk fonksiyonunda daha yüksek puan alan bireyleri tercih eder. Bu seçilen bireyler daha sonra, yeni potansiyel çözümler yaratmak için çaprazlamaya tabi tutulur. Mutasyon sürecinde ise belirli bir oranda, bu yeni bireylerde küçük, rasgele değişiklikler ortaya çıkarılarak popülasyonun çeşitliliğine katkıda bulunulur ve algoritmanın lokal en iyi çözümlere takılmasının önlenmesi sağlanır. Bu süreç, istenen koşulları sağlayan bir çözüm bulunana kadar veya bir sonlandırma koşulu sağlanana kadar iteratif olarak sürdürülür (Karaboğa, 2018).

### 3.3.3. Yapay arı kolonisi algoritması (ABC)

ABC algoritması ilk olarak Karaboğa (2005) tarafından geliştirilmiştir. Bu algoritma, bal arılarının yiyecek arama davranışlarından esinlenmiştir (Karaboğa, 2018) Basitliği, hızı, esnekliği ve çözüm yetenekleri nedeniyle optimizasyon problemlerinde yaygın olarak kullanılmaktadır.

ABC algoritması üç tür arının davranışları aracılığıyla çalışır. İşçi arılar, gözcü arılar ve kâşif arılar. Görevli işçi arılar, daha önceden bilinen kaynakları kullanarak nektarın kovana getirilmesini sağlarlar. Aynı zamanda nektarın yeri ve kalitesi hakkındaki bilgileri kovandaki diğer arılarla paylaşırlar (Karaboğa, 2018). Gözcü arılar, paylaşılan bilgilere göre yeni bir kaynağa yönelirler. Kâşif arılar ise yeni yiyecek kaynakları keşfetmek için rastgele kaynak arayışı yaparlar. Bu şekilde ABC algoritması, en iyi çözümün bulunması için çözüm uzayını iteratif bir şekilde arayarak, etkili bir şekilde optimizasyon probleminin çözülmesini sağlar (Karaboğa, 2018).

### 3.4. Kriging, CoKriging (COK) ve Regresyon Kriging (RK) Yöntemi

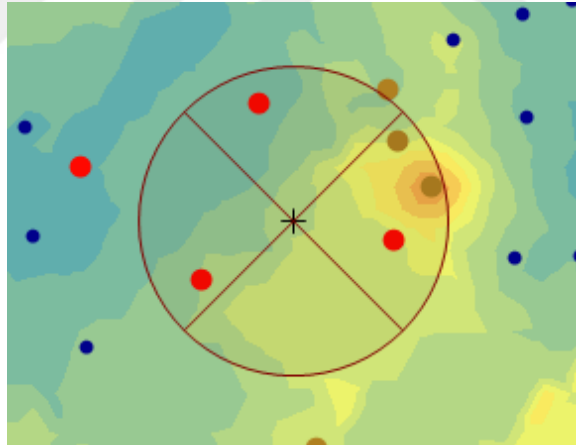
Bir mekân boyunca dağılmış, yağış gibi çevresel değişkenler çeşitli etkenler sonucunda meydana gelir ve tüm etkenleriyle birlikte matematiksel veya istatistiksel olarak tamamen açıklanamayan bu değişkenlere rasgele değişkenler veya bölgeselleşmiş değişkenler denir (Şen, 2009; Oliver ve Webster, 2015).

Yeryüzünde mekânsal dağılımı araştırılan herhangi bir bölgeselleşmiş değişken için ancak kısıtlı sayıda örnek toplanabildiğinden örneklenmemiş konumlardaki değişken değeri jeostatistik analiz yöntemleri ile tahmin edilebilmektedir. Bölgeselleşmiş değişkenlerin rasgele doğaları içerisinde kendi aralarında belirli bir düzen içerisinde ilişkiler içermesi bu değişkenlerin matematiksel olarak betimlenmesine imkân sağlayabilir (Webster, 2000; Şen, 2009; Oliver ve Webster, 2015; Hüsrevoğlu, 2018). Bundan faydalanarak belirlenen bir matematiksel fonksiyon ile örneklenmemiş konumlar için örnek değerlerden faydalanarak tahminde bulunulabilir. En uygun ve yansız tahminin yapılması için uygun bir tahmin metodolojisi aranır.

Jeostatistik analiz yöntemleri, Matheron (1963) tarafından ele alınan “bölgeselleşmiş değişkenler teorisi” (Theory of Regionalized Variables) ve Waldo Tobler’in “her şey diğer her şey ile ilişkilidir ancak yakın şeyler uzak şeylerden daha fazla ilişkilidir” (Tobler, 1970), şeklinde ifade ettiği Tobler’in ilk coğrafya kanunu ışığında



mekânsal tahmin süreçlerini gerçekleştirmektedir. Buna göre genellikle jeostatistik analiz yöntemleri rasgele değişkenler veya bölgeselleşmiş değişkenler olarak ifade edilen çevresel değişkenler arasında yakınlığa ya da mesafeye bağlı bir ilişki arar. Bu ilişkiyi kullanarak örneklememiş konumlar için tahminde bulunulur. Tahminler yapılırken Tobler'in kanununa göre yakın olanların benzer olması, artan mesafe ile benzerliğin örnekler arasında azalması beklenir (Tobler, 1970; Uzunlar, 2006; Topal, 2007; Uyguçgil, 2007; Oliver ve Webster, 2015; Hüsrevoğlu, 2018). Bu şekilde rasgele değişkenlerin mekânsal dağılımları hakkında, değişkenlerin rasgele ve tam anlamıyla matematiksel olarak ifade edilemeyen doğalarına rağmen mekânsal tahmin yapılabilecek bir metodoloji işletilir. Jeostatistik analizin yakın olan benzerdir ilişkisi ile yürütülebilmesi için veriler arasında mekânsal bağımlılık ya da diğer adıyla mekânsal otokorelasyon olması gerekir (Krivoruchko, 2005; Hüsrevoğlu, 2018). Yakın olanların daha benzer olması beklendiğinden temel olarak tahmini yapılacak konum için o konuma en yakın komşu örnek noktalarının değişken değerlerinden ve komşuların mesafe bilgilerinden faydalanılır. Şekil 3.10. ile bir mekânsal tahmin sırasında tahmini yapılan konum etrafındaki komşu noktalar gösterilmiştir.




Şekil 3.10. Komşuluk arama örneği

Jeostatistik analiz için içsel durağanlık (Intrinsic stationary) varsayımı yapılır. Bu varsayımına göre tahmini yapılan rastgele değişkenlerin arasındaki ilişki, bu değişkenlerin konumlarından bağımsız olarak sadece aralarındaki mesafeye bağlıdır (Sarma, 2010; Hüsrevoğlu, 2018). Değişkenlerin mekânsal bir trend göstermesi içsel durağanlık varsayımının sağlanmadığını gösterir. Ayrıca uygun bir jeostatistik analiz için değişken değerlerinin normal dağılımlı olması istenir (Krivoruchko, 2005).

Jeostatistik analizin bir kabulü olan mekânsal otokorelasyon ve içsel durağanlık varsayımından gelen mesafeye bağlı ilişki, kriging yöntemlerinde yarı variogram fonksiyonu ile belirlenir. Variogram modelinin belirlenmesi ile mekânsal bağımlılık belirlenmiş olur. Artan mesafe karşısında değişkenler arasındaki varyansın değişimi ve mesafeye bağlı ilişki bu şekilde matematiksel olarak belirlenir. (Hüsrevoğlu, 2018).

Örnek bir yarı variogram modeli grafiği Şekil 3.11. ile verilmiştir.



Şekil 3.11. Örnek bir yarı variogram modeli

Kriging yöntemleri en yakın komşu örnek noktaların değişken değerlerini ve variogram modeli tarafından sağlanan mesafeye bağlı ağırlık katsayılarını kullanarak tahmin değerini elde eder (Krivoruchko, 2005; Şen, 2009).

Bölgesel değişkenlerin birbirleri arasındaki mekânsal ilişkisini tanımlayan yarı variogram fonksiyonu şu şekilde tanımlanır (Matheron, 1967);

$$\gamma(h) = \frac{1}{2} \text{Var}[z(x+h) - z(x)], \quad (3.1)$$

bu denkleme göre yarı variogram fonksiyonu (Sarma, 2010);

$$\hat{\gamma}(h) = \frac{1}{2N} \sum_{i=1}^N \{z(x_i+h) - z(x_i)\}^2 \quad (3.2)$$

Burada,  $N$ : karşılaştırılan örnek çifti sayısı, “ $h$ ” adım aralığı ve  $z(x_i+h)$ :  $x_i+h$  konumundaki bölgeselleşmiş değişkenin beklenen değeridir.

Genel kriging tahmin bağıntısı Webster ve Oliver (2007) tarafından şu şekilde verilmiştir (Hüsrevoğlu, 2018);

$$\hat{Z}(x_0) = \sum_{i=1}^N w_i z(x_i) \quad (3.3)$$

Burada  $x_0$ : tahmini yapılan nokta,  $\hat{Z}(x_0)$ :  $x_0$  noktasındaki rastgele değişkenin tahmin edilen değeri,  $w_i$ : ağırlık,  $n$ : örnek noktası sayısı,  $z(x_i)$ :  $x_i$  örneğinin rastgele değişken değeridir (Hüsrevoğlu, 2018). Tahminde kullanılan ağırlıkların toplamı 1'dir.

Tahmini yapılan rasgele değişken ile ilişkili farklı özneliklerin tahminlere dahil edilmesi ile tahminlerin geliştirilmesi için COK yöntemi kullanılır. COK yöntemi, tahmini yapılan değişken değeri ve değişkene ait ikincil veya daha fazla sayıda sayısal özneliğin tahminlerde kullanılması ile gerçekleştirilir (Hüsrevoğlu, 2018). Webster ve Oliver (2007) tarafından COK bağıntısı genel Kriging bağıntısına benzer olarak şu şekilde verilmiştir (Hüsrevoğlu, 2018);

$$\hat{Z}(x_0) = \sum_{j=1}^N \sum_{i=1}^N w_{ji} z_j(x_i) \quad (3.4)$$

Ayrıntılı bilgiler için Hüsrevoğlu (2018) çalışması incelenebilir.

COK yöntemi, tahminlere rasgele değişken ile ilgili ikincil değerleri de dahil ederken tahmini yapılan konum için kullanılan komşu noktaların ikincil değerlerinden faydalanmaktadır. Bu durum tahmini yapılan konumun ikincil verilerinin formülasyonda kullanılmadığı anlamına gelir ve tahmini yapılan konuma ait öznelikler kullanılmamış olur.

RK, mekânsal veri analizinde sıklıkla kullanılan bir yaklaşımdır. Bu yöntem temel olarak çevresel bir değişkenin, ilişkili diğer değişkenler ile regresyon modelinin belirlenmesine ve tahmin farklılıklarının kriging yöntemi kullanılarak giderilmesine dayanır (Hengl, 2009). RK hem regresyon analizi hem de kriging yönteminin avantajlarını birleştirebildiği için çevresel değişkenlerin daha doğru tahminlerinin yapılmasını sağlayabilir.

RK ile ilk olarak bir model oluşturmak için değişkenler üzerinde bir regresyon analizi yürütülür. Bunu takiben gerçek ve tahmin edilen değerler arasındaki ortaya çıkan fark, kriging yönetimi kullanılarak enterpole edilir. Farklılıkların modelden giderilmesi ile RK süreci gerçekleştirilir (Hengl, 2009).

Bu çalışmada ANN ve ANFIS yöntemlerinin en iyi bulguları ile kriging uygulamaları karşılaştırılmıştır. Bunun için eğitim ve doğrulama noktaları birlikte kullanılarak 1 kriging, 3 COK ve 3 RK uygulaması gerçekleştirilmiştir. COK ve RK uygulamaları en iyi bulgular görülen ANN ve ANFIS girdilerine benzer girdiler ile uygulanmıştır. Test noktalarında görülen hatalar ve tahmin noktalarında görülen hatalar incelenmiştir.

### 3.5. Bölgeselleşmiş Değişkenlerin Jeostatistiksel ve Sezgisel Mekânsal Tahmini (Geo-HUSREV)

Geo-HUSREV yöntemi bir jeostatistik analiz yönteminin ve bir yapay zekâ optimizasyon algoritmasının birlikte kullanımı ile jeostatistiksel tahminlerin optimize edilmesini sağlar. Yöntemin isminin açılımı “Geostatistical and Heuristic Spatial Prediction of Regionalized Variables: Bölgeselleşmiş Değişkenlerin Jeostatistiksel ve Sezgisel Mekânsal Tahmini” şeklindedir. Geo-HUSREV yaklaşımının arkasında, ele alınan bölgesel değişkenin mekânsal dağılım tahmin haritasının sezgisel bir optimizasyon yöntemi ile daha iyi bir hale getirilmesi için tahmin haritası ile optimum harita arasında dönüşüm parametreleri bulmak yatar. Çapraz değerlendirme yaklaşımları ile sadece tahmin değerleri kullanılarak veya tahmini yapılan bölgesel değişkene ait ikincil verilerin değişken değerleri ile mekânsal tahmin haritası arasında dönüşüm parametreleri bulunarak jeostatistik analiz haritası optimize edilir. Çapraz değerlendirme için test noktası olarak belirlenen noktalar bloklar, kümeler ya da sadece bir örnek noktası olarak belirlenebilir. Bir blok dışarı çıkararak k-katlı (k-fold cross validation) çapraz değerlendirme yaklaşımı yürütülmesi için örnek noktaların mekânsal ya da diğer özniteliklerine göre bir kümeleme analizi yapılır. Dışarıda bırakılan her küme için tahmin değerleri, diğer kümeler kullanılarak jeostatistik analiz ile tahmin edilir. Dışarıda bırakılan küme için yapılan tahminlerin iyileştirilmesi için uygun parametreler sezgisel optimizasyon algoritmaları ile aranır. Bu yaklaşım her küme için iteratif olarak tekrar edilir. Her küme için jeostatistik analiz tahminlerini optimize eden ortak, global parametreler veya her kümeye özgü lokal parametreler sezgisel optimizasyon yöntemleri ile bulunur. Kümeler sadece bir noktadan oluşursa, birini çıkar (Leave one out) çapraz değerlendirme yaklaşımı kullanılmış olur. Jeostatistik analiz haritasının optimize edilmesi için kullanılacak fonksiyon kullanıcı tarafından tanımlanır. Sezgisel optimizasyon algoritmaları ise kullanıcının tanımladığı fonksiyonun bilinmeyen parametrelerini, belirlenen maliyet fonksiyonuna göre bulur. Temel olarak maliyet fonksiyonu çapraz değerlendirme sürecinde ortaya çıkan toplam hataları minimize eden bir fonksiyon olarak belirlenebilir. Elde edilen dönüşüm fonksiyonuna başlangıçta elde edilen tahmin haritası uygulandığında optimize edilmiş tahmin haritası elde edilir. Ele alınan bölgesel değişken ile ilişkili ikincil verilerin kullanımını durumunda da tahmin değerleri ile ikincil değişkenler arasında bir dönüşüm fonksiyonu kullanıcı tanımlı olarak belirlenir.

ANN yönteminde olduğu gibi, girdi ve hedef veriler arasında kullanıcı tanımlı bir modelin parametreleri araştırılır. Optimum dönüşüm parametreleri sezgisel optimizasyon algoritmaları ile iteratif olarak bulunur. K-katlı çapraz değerlendirme için ikincil değişkenleri de dikkate alan kümeleme analizleri ile veri, uygulamaya özel kümelere ayrılabilir. Örneğin incelenen çevresel değişkenler konumlarına göre veya yükseklik ve yağış gibi ikincil değerlerine göre çeşitli şekillerde kümelere ayrılabilir. Kümeleme aşamasında birden fazla kriter kullanılabilir. Bu şekilde optimizasyon algoritmaları için öğrenme stratejisi tasarlanabilir. Bu yönleriyle Geo-HUSREV yöntemi oldukça esnekler.

Temel Geo-HUSREV fonksiyonları denklem 3.5 ve 3.6 ile verilmiştir. Denklem 3.5 ile verilen tahmin fonksiyonu tüm çalışma alanı için ortak parametrelerin kullanıldığı örnek bir global Geo-HUSREV tahmin denklemidir. Denklem 3.6 ile verilen fonksiyon ise “c” kümeler/bloklara ayrılan veri için her kümeye özel parametrelerin kullanıldığı örnek bir temel Geo-HUSREV tahmin fonksiyonudur. Verilen bağıntılar  $\varphi_i, \lambda_i$  konumu için tahmin değeri sağlar.

$$H(\hat{X}_{\varphi_i, \lambda_i}) = P_1 Cov_{1, \varphi_i, \lambda_i} + P_2 Cov_{2, \varphi_i, \lambda_i} + \dots + P_{(j-1)} Cov_{(j-1), \varphi_i, \lambda_i} + P_j \quad (3.5)$$

$$H(\hat{X}_{c_k, \varphi_i, \lambda_i}) = P_{c_k, 1} Cov_{1, \varphi_i, \lambda_i} + P_{c_k, 2} Cov_{2, \varphi_i, \lambda_i} + \dots + P_{c_k, (j-1)} Cov_{(j-1), \varphi_i, \lambda_i} + P_{c_k, j} \quad (3.6)$$

Burada  $H(\hat{X}_{\varphi_i, \lambda_i})$ :  $\varphi_i, \lambda_i$  konumu için yapılan tahmin değeri,  $H(\hat{X}_{c_k, \varphi_i, \lambda_i})$ : k'inci c kümesinin elemanı olan  $\varphi_i, \lambda_i$  konumunun tahmin değeri,  $Cov_{1, \varphi_i, \lambda_i}$ :  $\varphi_i, \lambda_i$  konumunun bilinen ilk kovaryete değeri,  $P_1$ : ilk kovaryete değeri için bulunan optimum parametre,  $P_{c_k, 2} Cov_{2, \varphi_i, \lambda_i}$ : k'inci c kümesi için bulunan, ikinci kovaryete için 2. optimum parametre,  $P_j$ : optimum yanlılık değeri,  $P_{c_k, j}$ : k'inci c kümesi için bulunan optimum yanlılık değeridir.

Kullanılacak jeostatistik analiz yöntemi ve sezgisel optimizasyon yöntemi kullanıcı tarafından belirlenir. Yukarıda verilen denklemlerde birinci kovaryete yerine klasik kriging tahmini değeri kullanılarak mevcut kriging tahmin değerlerinin optimizasyonu sağlanabilir. Örneğin, bu çalışmada Geo-HUSREV yöntemi ile jeostatistik analiz yöntemlerinden kriging yöntemi, sezgisel optimizasyon yöntemlerinden ise ABC yöntemi bir araya getirilerek uygulamalar yapılmıştır. Optimize edilen jeostatistik analiz yöntemini işaret edecek şekilde ortaya konan yaklaşıma

Kriging-HUSREV yöntemi denilmiştir. Global bir Kriging-HUSREV uygulaması için denklem 3.7, lokal bir Kriging-HUSREV uygulaması için denklem 3.8 verilmiştir.

$$H(\hat{X}_{\varphi i, \lambda i}) = P_1 Kriging_{\varphi i, \lambda i} + P_2 Cov_{2, \varphi i, \lambda i} + \dots + P_{(j-1)} Cov_{(j-1), \varphi i, \lambda i} + P_j \quad (3.7)$$

$$H(\hat{X}_{c_k, \varphi i, \lambda i}) = P_{c_k, 1} Kriging_{\varphi i, \lambda i} + P_{c_k, 2} Cov_{2, \varphi i, \lambda i} + \dots + P_{c_k, (j-1)} Cov_{(j-1), \varphi i, \lambda i} + P_{c_k, j} \quad (3.8)$$

Burada  $Kriging_{\varphi i, \lambda i}$ :  $\varphi i, \lambda i$  konumu için yapılan kriging tahmin değeridir.

Yukarıdaki denklemler en küçük kareler yöntemi ile kolayca çözülebilecek lineer denklemler olarak düşünülebilir. Ancak Geo-HUSREV yaklaşımının temel bir gösterimi olarak verilen bu denklemler kullanıcı tarafından lineer veya lineer olmayan birçok şekilde tasarlanabilir. Sezgisel optimizasyon algoritmaları ile farklı veri setleri ve farklı veri kümeleri için tahmin parametrelerinin ne olduğu tahminler için bir maliyet fonksiyonu kullanarak kolayca bulunabilir. Sezgisel optimizasyon algoritmaları çözüm için belirlenen çapraz değerlendirme stratejisine göre örneğin tahmin değerlerinin KOH büyüklüklerini minimize eden bir maliyet fonksiyonu ile tahmin bağıntısında yer alan parametrelerin en optimum değerlerini bulabilir. Bu yaklaşım, tasarlanan çeşitli tahmin fonksiyonları için kullanılabilir.

Optimum parametrelerin bulunması için ilk olarak rasgele parametre değerleri ile kullanıcı tanımlı dönüşüm denklemi kullanılarak tahmin değeri elde edilir. Örneğin denklem 3.5.'te bilinen değerler ve tahmin değerleri arasındaki farkı minimize eden optimum parametreler sezgisel optimizasyon algoritmaları ile bulunur. Minimize edilmesi gereken hata değeri maliyet fonksiyonunun sonucu olup, maliyet fonksiyonu için en basit şekilde aşağıdaki 3.9 ve 3.10 denklemi örnek verilebilir. Yukarıdaki tahmin denklemlerinde olduğu gibi maliyet fonksiyonu da kullanıcı tanımlıdır. Örneğin, maliyet fonksiyonu çapraz değerlendirme bulgularını minimize edecek şekilde tasarlanabilir.

$$Cost = \sum_i^n (H(\hat{X}_{\varphi i, \lambda i}) - X_{\varphi i, \lambda i})^2 \quad (3.9)$$

Ya da;

$$Cost_{c_k} = \sum_i^n (H(\hat{X}_{c_k, \varphi i, \lambda i}) - X_{\varphi i, \lambda i})^2 \quad (3.10)$$

Burada  $X_{\varphi_i, \lambda_i}$ :  $\varphi_i, \lambda_i$  konumunda bilinen gerçek gözlem değeridir. *Cost*: Optimize edilecek maliyet değeridir.  $Cost_{c_k}$ : k'inci c kümesi için optimize edilecek maliyet değeridir. Sezgisel optimizasyon algoritmaları kullanılarak *Cost* değerini en iyi minimize eden parametreler bulunur.

Parametrelerin, sezgisel optimizasyon yöntemlerinin çözüm uzayında bulunması için en üst ve en alt sınırları belirlenir. İteratif olarak, en iyi parametreler kullanılan sezgisel optimizasyon yönteminin stratejisine göre bulunur. Bu stokastik bir süreçtir. Rasgele değerler kullanılarak en iyi çözüm arandığı için çözüm kümesi değerleri her denemede farklı olabilir. Matematiksel olarak, bulunan optimum parametrelerin çözüm kümesi olduğu kanıtlanamasa da çözüme en yakın değerler elde edilir. Böylece hem jeostatistiksel hem de sezgisel şekilde çözüm bulunur. Daha sonra kullanıcı tanımlı, örnek denklem 3.5 veya 3.6 kullanılarak her konum için tahminler gerçekleştirilir.

Bu çalışmada Geo-HUSREV yöntemi ile İç Anadolu Bölgesi için yağış değerlerinin mekânsal tahmini incelenmiştir. Tahmin sonuçları, klasik kriging uygulamaları ve bölge için bulunan en iyi ANN ve ANFIS sonuçları ile karşılaştırılmıştır. Geo-HUSREV tahmin haritaları üretilmiştir.

Geo-HUSREV uygulamalarında klasik kriging tahmin değerleri optimize edilmiştir. Tahminler için ikincil veri olarak yükseklik ve en iyi ANN ve ANFIS uygulamalarında kullanılan değişkenler incelenmiştir. Veriler kümelenecek bir bloğu çıkar (Leave one block out) çapraz değerlendirme yaklaşımı kullanılmıştır. Sırayla her bir kat/blok/küme verisi dışarıda bırakılarak kriging tahminleri gerçekleştirilmiştir. Dışarıda bırakılan her küme için gerçekleştirilen kriging tahmini ile bilinen gerçek değerler arasındaki farklar bulunarak tüm kümeler için toplam farkı minimize edecek bir parametre optimizasyonu stratejisi seçilmiştir. Daha sonra bulunan en iyi optimizasyon parametreleri tüm alanda yapılan kriging tahmini ve ikincil değişken değerlerine uygulanarak, optimize edilmiş Kriging-HUSREV değerleri elde edilmiştir. Kriging-HUSREV tahminleri bu şekilde haritalanmıştır. Geo-HUSREV yöntemi ve Kriging-HUSREV yöntemi ilk kez bu tez çalışmasında geliştirilmiştir.

Daha kolay anlaşılması için klasik kriging tahmin değerlerini ve yükseklik değişkeni verisini kullanan, veri setinin 3 kümeye/bloğa ayrıldığı varsayılan ve tüm çalışma alanı için ortak (Global) optimizasyon parametreleri arayan bir Kriging-Husrev uygulamasının iş akışı Şekil 3.13.'te verilmiştir. Şekil sayesinde yöntemin işleyişi daha kolay anlaşılabilir.

Optimum parametrelerin bulunması için veri k-katlara diğer bir deyişle kümelerle ayrılmıştır ve k-katlı çapraz değerlendirme yaklaşımından faydalanılmıştır. Her veri kümesi için ortak optimum global parametreler aranmıştır.


Dışarıda bırakılan her küme için diğer kümelerin kullanımı ile mekânsal tahmin gerçekleştirilmiştir. Sırasıyla dışarıda bırakılan kümelerde görülen tahmin hatalarını toplayan bir maliyet fonksiyonu geliştirilmiştir. ABC yöntemi kullanarak bu maliyet fonksiyonunu minimize eden parametreler iteratif olarak araştırılmıştır.

Örnek uygulamanın tahmin ve maliyet denklemi fonksiyonları sırasıyla denklem 3.11 ve denklem 3.12 ile verilmiştir.;

$$H(\hat{X}_{\phi_i, \lambda_i}) = P_1 Kriging_{\phi_i, \lambda_i} + P_2 Yükseklik_{\phi_i, \lambda_i} + P_3 \quad (3.11)$$

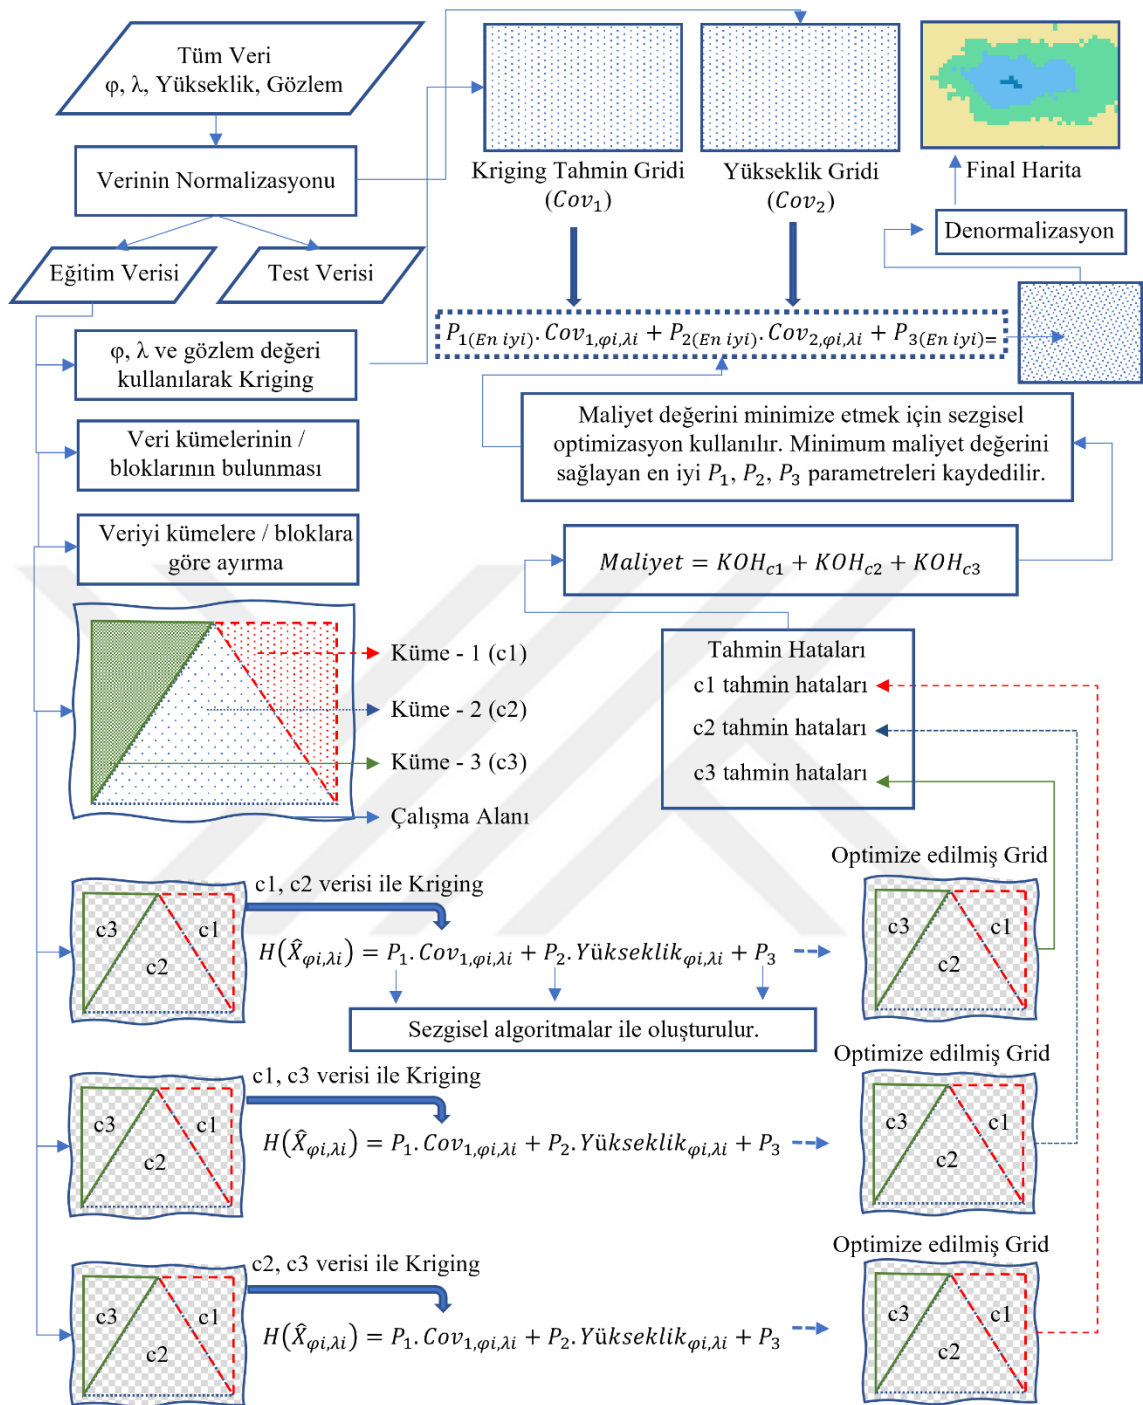
$$Maliyet = KOH_{c1} + KOH_{c2} + KOH_{c3} \quad (3.12)$$

K-katlı çapraz değerlendirme için k-ortalamlar algoritması ile konumlarına ve yağış değerlerine göre kümelerle ayrılmış bir veri setinin örnek gösterimi Şekil 3.12. ile verilmiştir.



Şekil 3.12. K-ortalamlar algoritması ile konumlarına göre kümelenmiş yağış istasyonları





Şekil 3.13. Geo-HUSREV yöntemi ile örnek bir Kriging-HUSREV tahmininin iş akışı

#### 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Tez çalışmasında ANN yöntemi ile 5293400 uygulama, ANFIS yöntemi ile 22288 uygulama gerçekleştirilmiştir. Farklı girdi sayıları ve farklı öğrenim algoritmaları kullanılarak yapılan her uygulama setinden en düşük KOH test değerine sahip 25 uygulama sıralanarak çizelgeler halinde verilmiştir. Uygulamalara ait test noktalarında görülen KOH değeri, eğitim noktalarında görülen KOH değeri, eğitim ve test noktaları üzerindeki tahminlerin R değerleri, karakteristik test noktalarında görülen tahmin hataları, tahminlerde kullanılan değişkenlerin neler olduğu ve yöntemler için uygulamada kullanılan parametreler çizelgeler ile gösterilmiştir. Her girdi sayısı ve eğitim algoritması için en uygun yöntem ve parametrelerin neler olduğu bulgular incelenerek yorumlanmıştır.

##### 4.1. Yapay Sinir Ağları (ANN) Bulguları

ANN yöntemi ile her uygulama setinde en düşük test KOH değerine sahip ilk 25 uygulamanın sonuçları, 1 girdili ve LM algoritması kullanılan uygulamalar için Çizelge 4.1. ile, 1 girdili ve SCG algoritması kullanılan uygulamalar için Çizelge 4.2. ile, 2 girdili ve LM algoritması kullanılan uygulamalar için Çizelge 4.3. ile, 2 girdili ve SCG algoritması kullanılan uygulamalar için Çizelge 4.4. ile, 3 girdili ve LM algoritması kullanılan uygulamalar için Çizelge 4.5. ile, 3 girdili ve SCG algoritması kullanılan uygulamalar için Çizelge 4.6. ile, 4 girdili ve LM algoritması kullanılan uygulamalar için Çizelge 4.7. ile, 4 girdili ve SCG algoritması kullanılan uygulamalar için Çizelge 4.8. ile, 5 girdili ve LM algoritması kullanılan uygulamalar için Çizelge 4.9. ile ve 5 girdili ve SCG algoritması kullanılan uygulamalar için Çizelge 4.10. ile verilmiştir.

Çizelge 4.1. LM algoritması ve 1 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik								
1	11	3	27216	10.5	8.5	0.3	0.7	7.2	31.2	0.1	6.6	0.7	16.3	4.2	15.8	9.1	7.7	Nem	-	-	-	-	LM
2	8	5	27393	10.8	8.7	0.3	0.7	4.4	29.3	5.5	5.4	1.3	17.7	2.9	21.3	9.4	7.4	Nem	-	-	-	-	LM
3	11	14	28261	10.9	8.6	0.4	0.7	5.3	29.2	10.9	7.9	3.7	21.0	0.4	18.8	9.5	3.7	Nem	-	-	-	-	LM
4	16	3	27244	10.9	8.4	0.4	0.7	8.0	30.7	1.1	7.6	1.7	18.7	1.9	20.4	9.1	9.0	Nem	-	-	-	-	LM
5	15	13	28189	11.0	8.5	0.4	0.7	3.5	29.4	6.7	6.5	0.2	18.2	2.4	20.1	9.8	6.5	Nem	-	-	-	-	LM
6	11	4	27314	11.0	8.5	0.3	0.7	4.6	32.4	2.3	6.6	0.7	20.7	0.1	17.8	9.4	6.7	Nem	-	-	-	-	LM
7	9	5	27398	11.0	8.6	0.3	0.7	5.7	29.8	6.0	4.0	1.5	16.8	3.8	22.2	9.6	7.3	Nem	-	-	-	-	LM
8	14	3	27235	11.0	8.7	0.3	0.7	4.7	30.1	0.7	7.1	1.2	16.5	4.0	22.5	9.5	8.1	Nem	-	-	-	-	LM
9	9	13	28159	11.0	8.2	0.4	0.7	6.1	26.0	5.6	3.4	5.1	17.5	3.0	21.3	9.9	9.0	Nem	-	-	-	-	LM
10	12	5	27411	11.0	8.6	0.3	0.7	7.5	30.3	3.8	6.8	0.9	16.3	4.3	22.7	9.4	8.1	Nem	-	-	-	-	LM
11	6	19	28714	11.0	8.5	0.4	0.7	7.1	31.4	1.7	6.1	5.7	20.4	0.2	18.9	9.4	6.7	Nem	-	-	-	-	LM
12	15	10	27904	11.0	8.4	0.4	0.7	5.2	32.7	2.4	4.5	1.7	19.7	0.9	19.8	9.4	6.7	Nem	-	-	-	-	LM
13	9	11	27968	11.0	8.4	0.4	0.7	4.7	31.4	9.1	7.2	0.5	20.0	0.6	18.9	9.3	8.1	Nem	-	-	-	-	LM
14	6	0	1447	11.0	8.7	0.3	0.7	3.8	29.9	8.5	6.1	2.1	16.7	3.9	22.3	9.5	8.2	Nem	-	-	-	-	LM
15	5	18	28613	11.1	8.5	0.4	0.7	6.3	31.1	2.6	6.3	1.0	20.1	0.5	20.5	9.5	6.8	Nem	-	-	-	-	LM
16	13	16	30266	11.1	8.7	0.3	0.6	3.9	22.7	2.8	3.8	4.0	23.8	1.6	16.4	10.7	5.3	Bas.	-	-	-	-	LM
17	8	4	27299	11.1	8.6	0.3	0.7	7.6	29.7	8.3	5.9	0.4	16.9	3.6	22.1	9.5	7.8	Nem	-	-	-	-	LM
18	8	3	27204	11.1	8.5	0.3	0.7	5.5	31.7	3.2	5.3	1.5	20.3	0.2	19.8	9.5	7.5	Nem	-	-	-	-	LM
19	4	7	27564	11.1	8.5	0.4	0.7	6.7	32.2	8.3	5.3	0.3	20.2	0.4	18.9	9.4	6.9	Nem	-	-	-	-	LM
20	14	5	27421	11.1	8.7	0.3	0.7	5.2	30.1	8.3	7.0	1.1	16.4	4.1	22.6	9.5	8.1	Nem	-	-	-	-	LM
21	2	17	28503	11.1	8.8	0.2	0.7	4.7	29.3	3.5	5.5	0.5	17.7	2.9	21.4	9.8	8.7	Nem	-	-	-	-	LM
22	8	10	27867	11.1	8.4	0.4	0.7	6.2	32.1	7.2	5.0	2.2	20.1	0.4	19.0	9.4	7.4	Nem	-	-	-	-	LM
23	5	4	27281	11.1	8.5	0.4	0.7	6.1	32.5	6.0	6.3	0.4	20.0	0.6	18.9	9.4	7.1	Nem	-	-	-	-	LM
24	14	14	28280	11.1	8.5	0.3	0.7	4.4	27.0	14.1	5.8	2.6	18.2	2.4	20.7	10.0	6.1	Nem	-	-	-	-	LM
25	14	2	27140	11.1	8.6	0.3	0.7	3.5	31.3	4.8	4.3	1.6	18.2	2.4	21.0	9.6	8.0	Nem	-	-	-	-	LM

Çizelge 4.2. SCG algoritması ve 1 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konular KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik								
1	15	14	4817	10.5	8.8	0.3	0.7	3.4	17.2	6.8	10.1	8.1	18.6	0.1	18.6	10.2	5.4	Yük.	-	-	-	-	SCG
2	3	18	30409	10.7	9.8	0.1	0.7	1.3	26.5	0.8	7.2	5.8	18.9	4.9	17.3	9.7	8.6	Bas.	-	-	-	-	SCG
3	9	8	27681	10.8	9.3	0.2	0.7	2.0	29.2	9.7	2.4	8.2	15.9	4.7	23.6	9.0	7.0	Nem	-	-	-	-	SCG
4	16	9	27814	10.9	9.2	0.2	0.7	9.9	28.5	11.5	3.5	1.2	17.3	3.3	20.6	9.4	6.9	Nem	-	-	-	-	SCG
5	16	5	27433	10.9	8.8	0.2	0.7	10.0	29.1	2.0	7.4	2.0	17.6	3.0	20.9	9.5	7.7	Nem	-	-	-	-	SCG
6	19	9	29635	11.0	8.9	0.2	0.7	2.7	26.7	13.2	6.1	4.6	20.1	2.5	20.0	9.6	7.0	Bas.	-	-	-	-	SCG
7	17	0	1502	11.0	8.5	0.4	0.7	7.2	32.1	3.6	4.1	5.5	21.1	0.5	19.5	9.1	7.0	Nem	-	-	-	-	SCG
8	13	20	30650	11.0	9.2	0.2	0.7	9.5	21.9	16.7	2.8	12.5	16.9	0.9	19.0	9.9	6.5	Bas.	-	-	-	-	SCG
9	7	16	28435	11.0	9.5	0.1	0.7	3.1	25.3	4.5	7.1	1.7	17.7	2.9	21.7	10.2	7.6	Nem	-	-	-	-	SCG
10	7	11	27956	11.0	8.8	0.3	0.7	5.2	30.0	3.4	2.8	0.9	16.1	4.4	22.9	9.6	7.9	Nem	-	-	-	-	SCG
11	4	20	28796	11.0	8.7	0.3	0.7	6.0	30.0	2.2	6.6	1.5	16.7	3.9	22.3	9.6	7.8	Nem	-	-	-	-	SCG
12	2	17	28501	11.0	9.0	0.1	0.7	6.4	29.0	1.7	7.9	2.0	17.6	2.9	21.4	9.6	8.6	Nem	-	-	-	-	SCG
13	15	11	28000	11.0	8.7	0.3	0.7	5.2	32.0	7.3	6.7	1.5	19.2	1.4	21.8	9.1	7.5	Nem	-	-	-	-	SCG
14	16	17	5106	11.0	8.9	0.2	0.7	2.4	25.4	2.3	5.5	4.6	19.6	0.4	19.0	10.5	6.2	Yük.	-	-	-	-	SCG
15	10	15	28355	11.0	9.4	0.1	0.7	5.0	26.6	3.3	4.0	1.6	18.5	2.0	21.0	10.3	6.8	Nem	-	-	-	-	SCG
16	15	13	28190	11.1	8.5	0.3	0.7	8.5	31.3	6.2	3.8	2.6	19.2	1.3	21.0	9.3	7.7	Nem	-	-	-	-	SCG
17	7	19	30525	11.1	8.8	0.3	0.7	4.6	27.9	7.8	9.8	8.0	17.0	3.5	21.8	9.7	7.2	Bas.	-	-	-	-	SCG
18	6	14	30042	11.1	9.2	0.0	0.7	4.9	24.1	8.4	7.9	16.8	16.1	3.6	20.6	9.9	7.0	Bas.	-	-	-	-	SCG
19	11	4	27314-1	11.1	8.8	0.2	0.7	5.9	30.9	0.2	6.9	2.2	17.6	3.0	22.1	9.5	8.5	Nem	-	-	-	-	SCG
20	11	0	1471	11.1	8.7	0.3	0.7	4.9	31.4	1.3	4.3	2.4	17.4	3.2	22.2	9.6	8.1	Nem	-	-	-	-	SCG
21	18	6	27540	11.1	8.7	0.3	0.7	3.9	33.3	0.3	6.3	0.2	18.6	2.0	21.3	9.4	7.2	Nem	-	-	-	-	SCG
22	5	7	29372	11.1	9.9	0.0	0.7	5.9	20.3	18.9	10.5	4.0	26.0	2.6	24.0	8.8	6.8	Bas.	-	-	-	-	SCG
23	7	6	27483	11.1	8.7	0.3	0.7	5.6	30.4	0.5	5.7	0.8	17.5	3.1	21.7	9.7	8.5	Nem	-	-	-	-	SCG
24	16	4	27338	11.1	8.5	0.3	0.7	7.7	32.6	11.0	4.9	1.1	18.6	2.0	19.8	9.3	7.2	Nem	-	-	-	-	SCG
25	20	11	28023	11.2	8.7	0.3	0.7	3.3	31.6	13.8	5.2	0.8	17.7	2.8	22.1	9.2	7.0	Nem	-	-	-	-	SCG

Çizelge 4.3. LM algoritması ve 2 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik								
1	11	13	103980	10.0	9.0	0.3	0.8	5.6	24.7	15.3	6.1	6.7	19.6	4.2	21.7	7.9	4.5	D.U.	Bas.	-	-	-	LM
2	4	8	61952	10.0	7.1	0.6	0.7	6.6	10.6	12.6	18.6	8.5	13.3	0.6	18.1	9.1	9.2	Yük.	K1	-	-	-	LM
3	19	10	244521	10.2	9.1	0.3	0.7	5.5	19.5	2.2	9.9	3.8	18.1	2.1	14.9	10.2	3.3	Nem	Bas.	-	-	-	LM
4	12	13	103984	10.2	8.3	0.5	0.7	0.7	27.9	11.2	1.1	4.1	19.7	4.2	22.1	8.2	5.6	D.U.	Bas.	-	-	-	LM
5	19	15	102405	10.2	8.0	0.5	0.7	1.3	30.6	2.2	2.3	9.1	15.7	6.3	17.9	8.6	6.9	D.U.	Nem	-	-	-	LM
6	6	13	103953	10.2	8.5	0.4	0.7	2.9	23.3	5.4	6.8	1.0	18.2	2.8	21.9	8.9	8.6	D.U.	Bas.	-	-	-	LM
7	18	13	104015	10.2	8.3	0.4	0.7	4.5	24.6	3.2	4.0	3.7	13.0	3.9	19.7	9.4	9.4	D.U.	Bas.	-	-	-	LM
8	19	0	5502	10.2	8.8	0.4	0.7	1.6	27.1	7.5	5.8	2.7	14.0	5.5	19.5	9.3	5.8	D.U.	Bas.	-	-	-	LM
9	12	8	244296	10.3	8.1	0.5	0.7	0.1	25.2	3.7	9.0	8.7	18.9	4.2	20.6	8.9	5.5	Nem	Bas.	-	-	-	LM
10	10	20	57710	10.3	7.8	0.5	0.7	4.3	31.4	6.7	5.6	2.7	18.1	8.1	14.7	8.6	6.0	Yük.	D.U.	-	-	-	LM
11	5	17	102525	10.3	7.5	0.6	0.7	0.4	27.9	14.4	8.3	10.5	16.2	3.0	23.6	7.7	7.2	D.U.	Nem	-	-	-	LM
12	19	0	12913	10.3	8.3	0.4	0.7	4.7	26.1	5.3	10.6	5.0	21.4	4.6	18.1	8.7	6.4	Nem	Bas.	-	-	-	LM
13	13	9	244397	10.3	8.1	0.4	0.7	6.5	28.9	8.4	4.7	2.9	16.3	2.0	22.0	8.5	7.2	Nem	Bas.	-	-	-	LM
14	5	9	244357	10.4	8.1	0.5	0.7	7.0	28.2	5.4	5.4	4.7	18.5	2.5	21.0	8.8	5.9	Nem	Bas.	-	-	-	LM
15	11	0	6510	10.4	9.2	0.2	0.7	3.3	23.3	9.3	4.8	0.9	19.5	0.2	15.3	9.9	6.6	Bakı	Nem	-	-	-	LM
16	17	18	245272	10.4	7.4	0.6	0.7	3.0	26.9	7.2	10.2	10.6	13.4	2.2	22.2	8.9	6.0	Nem	Bas.	-	-	-	LM
17	11	13	215888	10.4	9.7	0.3	0.7	0.6	25.3	17.4	9.4	10.9	17.1	1.8	13.9	9.2	4.1	K5	Nem	-	-	-	LM
18	17	14	102297	10.5	9.4	0.4	0.7	7.9	24.1	11.0	6.8	3.3	19.8	11.0	18.2	9.2	3.7	D.U.	Nem	-	-	-	LM
19	9	20	102826	10.5	7.5	0.6	0.7	8.9	25.8	7.6	1.5	9.7	11.9	5.0	17.2	9.2	10.9	D.U.	Nem	-	-	-	LM
20	10	6	244096	10.5	7.6	0.6	0.7	0.0	34.1	11.2	8.6	3.2	10.2	0.9	22.6	8.1	7.0	Nem	Bas.	-	-	-	LM
21	18	15	104205	10.5	8.1	0.5	0.7	3.0	28.1	8.4	1.4	13.4	10.9	4.3	20.7	8.8	10.0	D.U.	Bas.	-	-	-	LM
22	12	10	101892	10.5	7.9	0.5	0.7	2.5	29.6	4.8	9.7	4.2	10.7	3.7	19.5	9.2	9.5	D.U.	Nem	-	-	-	LM
23	20	18	102691	10.5	7.8	0.5	0.7	0.4	26.7	17.5	5.3	5.9	13.6	2.8	19.6	8.8	9.2	D.U.	Nem	-	-	-	LM
24	6	0	12849	10.5	8.6	0.3	0.7	4.6	29.5	3.3	7.6	3.0	18.3	4.2	19.8	8.9	7.6	Nem	Bas.	-	-	-	LM
25	7	15	225083	10.6	8.9	0.3	0.7	3.2	28.8	1.4	8.0	8.8	18.8	3.0	19.1	9.1	6.3	A.U.	Nem	-	-	-	LM

Çizelge 4.4. SCG algoritması ve 2 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm							Rasgele Test KOH ± mm	Seyrek Konular KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem	
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış									Ortalama Yükseklik
1	16	5	123099	10.4	9.4	0.1	0.7	5.2	27.2	11.9	3.2	5.1	15.0	1.1	19.7	9.0	8.0	Bakı	Nem	-	-	-	SCG
2	3	14	206918	10.6	10.4	0.0	0.7	7.1	4.7	7.6	2.9	17.2	18.0	2.9	22.8	10.1	7.2	K4	Bas.	-	-	-	SCG
3	17	15	244988	10.6	9.4	0.0	0.7	0.7	22.3	11.7	3.0	2.0	21.3	3.3	22.5	9.2	8.7	Nem	Bas.	-	-	-	SCG
4	12	15	244965	10.6	8.5	0.4	0.7	2.8	25.9	12.3	5.2	1.7	22.0	3.7	19.0	9.1	6.9	Nem	Bas.	-	-	-	SCG
5	6	9	56645	10.7	9.2	0.2	0.7	10.1	28.2	2.1	7.8	0.4	19.4	6.7	18.4	9.1	8.0	Yük.	D.U.	-	-	-	SCG
6	15	12	102099	10.7	8.4	0.4	0.7	2.9	28.7	4.9	7.6	1.3	12.8	8.2	21.1	9.2	9.7	D.U.	Nem	-	-	-	SCG
7	18	20	245468	10.7	10.2	0.2	0.7	3.3	14.3	7.1	3.8	17.0	26.1	3.2	17.4	9.8	5.8	Nem	Bas.	-	-	-	SCG
8	19	6	103354	10.7	8.4	0.4	0.7	2.0	29.7	10.9	4.2	0.9	11.4	3.9	23.1	8.9	10.4	D.U.	Bas.	-	-	-	SCG
9	12	0	12878	10.7	8.8	0.3	0.7	2.1	23.1	11.7	1.1	19.3	19.1	2.1	21.5	8.8	8.0	Nem	Bas.	-	-	-	SCG
10	5	20	245401	10.7	8.2	0.4	0.7	4.2	33.1	0.4	6.1	4.1	13.6	3.6	18.8	9.1	8.7	Nem	Bas.	-	-	-	SCG
11	16	19	102766	10.8	8.1	0.5	0.7	4.1	31.9	4.7	6.2	8.4	16.5	6.3	20.3	8.6	9.5	D.U.	Nem	-	-	-	SCG
12	17	12	177920	10.8	8.1	0.4	0.7	2.3	30.0	10.1	5.8	8.2	12.4	3.5	22.6	9.1	8.1	K2	Nem	-	-	-	SCG
13	20	14	104116	10.8	10.0	0.1	0.7	4.6	27.3	10.3	0.3	7.9	13.3	10.5	25.3	8.9	7.8	D.U.	Bas.	-	-	-	SCG
14	14	18	245259	10.8	8.8	0.3	0.8	1.8	24.3	22.2	5.4	4.5	17.8	5.2	22.6	8.8	5.1	Nem	Bas.	-	-	-	SCG
15	7	18	245221	10.8	9.0	0.2	0.8	8.3	20.4	28.0	7.6	0.7	16.4	3.8	23.5	8.1	7.4	Nem	Bas.	-	-	-	SCG
16	17	5	244040	10.8	8.8	0.3	0.7	3.6	27.5	5.4	4.1	0.8	16.9	4.2	20.2	9.8	7.7	Nem	Bas.	-	-	-	SCG
17	8	8	224424	10.8	9.8	0.2	0.7	8.4	32.3	12.6	6.9	8.0	15.8	7.7	19.8	8.2	8.8	A.U.	Nem	-	-	-	SCG
18	5	18	245214	10.8	8.4	0.4	0.7	4.4	28.1	5.4	8.9	12.1	18.4	4.2	20.5	9.0	7.8	Nem	Bas.	-	-	-	SCG
19	17	14	57171	10.8	8.6	0.3	0.7	2.5	23.5	14.0	10.8	1.7	16.2	3.3	20.2	9.7	7.9	Yük.	D.U.	-	-	-	SCG
20	20	17	124258	10.8	9.0	0.2	0.7	1.1	32.6	11.8	13.0	0.7	20.0	1.2	18.9	8.5	5.3	Bakı	Nem	-	-	-	SCG
21	20	17	245195	10.8	10.3	0.2	0.7	3.5	21.3	11.8	5.4	7.9	24.9	5.4	25.5	8.7	7.2	Nem	Bas.	-	-	-	SCG
22	16	12	244699	10.8	9.1	0.2	0.7	11.4	25.3	4.0	6.0	13.8	19.5	5.6	20.7	9.1	7.3	Nem	Bas.	-	-	-	SCG
23	6	15	225079	10.8	9.2	0.2	0.7	4.2	29.4	10.4	0.5	2.2	18.7	3.7	19.6	9.2	8.9	A.U.	Nem	-	-	-	SCG
24	12	16	57338	10.8	9.0	0.3	0.7	3.8	30.1	2.8	5.9	1.2	15.4	8.3	23.1	9.2	7.9	Yük.	D.U.	-	-	-	SCG
25	5	14	102237	10.9	9.2	0.2	0.7	2.9	27.2	5.3	7.5	3.7	16.2	5.2	23.2	9.3	9.6	D.U.	Nem	-	-	-	SCG

Çizelge 4.5. LM algoritması ve 3 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm							Rasgele Test KOH ± mm	Seyrek Konular KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem	
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış									Ortalama Yükseklik
1	10	8	709978	9.6	7.3	0.6	0.8	0.1	21.9	9.5	2.6	9.2	9.6	0.1	22.0	8.9	4.1	D.U.	Nem	Bas.	-	-	LM
2	14	11	981032	9.8	12.5	0.1	0.7	8.4	11.7	5.6	3.5	10.1	18.5	3.4	12.0	9.8	8.7	K1	K5	Nem	-	-	LM
3	16	17	591735	9.9	8.8	0.5	0.7	9.2	32.2	9.4	6.1	2.4	11.8	0.3	13.6	8.3	6.3	D.U.	Bakı	Bas.	-	-	LM
4	12	8	406750	9.9	11.6	0.0	0.7	3.9	6.9	6.9	1.7	0.8	20.0	11.4	20.2	9.7	6.7	Yük.	D.U.	Bakı	-	-	LM
5	18	17	1216271	10.0	7.4	0.6	0.7	5.5	26.7	2.6	6.6	1.0	21.1	4.6	20.7	8.3	5.6	G.U.	Sıc.	Nem	-	-	LM
6	7	16	658377	10.0	8.1	0.5	0.7	1.7	29.2	17.0	12.1	4.1	18.4	6.1	18.3	7.4	4.9	D.U.	K3	Nem	-	-	LM
7	11	18	777719	10.1	10.6	0.2	0.7	6.5	22.0	13.0	20.7	16.6	9.9	4.3	16.7	8.1	5.3	Bakı	K3	Nem	-	-	LM
8	5	19	1220007	10.2	10.2	0.1	0.7	0.8	23.9	2.7	9.7	10.9	20.7	5.2	22.6	8.2	6.2	G.U.	Nem	Bas.	-	-	LM
9	14	10	710189	10.2	9.7	0.2	0.7	0.6	25.1	0.9	4.6	0.4	24.1	2.1	16.9	9.0	4.7	D.U.	Nem	Bas.	-	-	LM
10	4	13	414402	10.2	8.7	0.4	0.7	1.2	26.7	1.3	7.4	4.4	16.1	8.8	19.3	9.0	6.6	Yük.	D.U.	K3	-	-	LM
11	19	20	711162	10.2	7.2	0.6	0.7	2.0	31.7	6.0	4.3	0.4	12.3	3.7	20.6	8.5	7.5	D.U.	Nem	Bas.	-	-	LM
12	14	19	711043	10.2	7.7	0.5	0.7	0.3	28.2	1.0	10.4	1.3	17.6	4.9	23.6	8.2	6.8	D.U.	Nem	Bas.	-	-	LM
13	8	13	1205011	10.2	7.8	0.5	0.7	5.9	20.0	9.9	6.3	0.7	22.1	5.1	21.2	8.8	7.3	A.U.	Sıc.	Nem	-	-	LM
14	11	8	1218994	10.2	7.7	0.5	0.7	6.2	26.7	6.2	5.7	0.9	20.7	6.6	19.7	8.6	5.5	G.U.	Nem	Bas.	-	-	LM
15	4	13	820527	10.2	11.1	0.2	0.7	5.3	20.5	0.3	9.7	4.7	22.7	4.1	18.7	8.9	8.7	Bakı	GPM	Sıc.	-	-	LM
16	6	8	410327	10.3	6.7	0.7	0.7	3.1	22.7	10.6	6.0	1.0	17.8	0.3	16.3	9.5	8.7	Yük.	D.U.	K1	-	-	LM
17	6	18	627877	10.3	7.7	0.6	0.7	1.6	26.0	2.4	8.7	1.4	21.2	5.2	16.3	9.0	7.9	D.U.	K1	Nem	-	-	LM
18	13	11	1215676	10.3	6.6	0.7	0.7	4.8	18.1	3.7	0.7	1.1	14.4	3.7	20.1	10.3	8.2	G.U.	Sıc.	Nem	-	-	LM
19	20	9	710121	10.4	7.1	0.6	0.7	1.2	29.6	13.0	0.9	5.6	14.3	4.2	23.3	7.6	11.2	D.U.	Nem	Bas.	-	-	LM
20	9	11	1219269	10.4	8.2	0.4	0.7	5.9	27.4	5.4	1.6	0.1	18.9	3.3	18.5	9.1	7.2	G.U.	Nem	Bas.	-	-	LM
21	8	18	133320	10.4	8.9	0.3	0.7	3.6	21.2	7.7	8.3	0.3	16.6	5.4	24.3	9.4	6.0	En.	K1	Nem	-	-	LM
22	16	9	706495	10.4	7.7	0.6	0.7	7.5	27.5	1.7	4.6	6.7	20.2	6.1	21.5	8.5	6.5	D.U.	Sıc.	Nem	-	-	LM
23	15	18	1219965	10.4	8.3	0.4	0.7	7.8	21.9	8.7	14.1	7.3	20.5	7.9	16.0	8.9	7.4	G.U.	Nem	Bas.	-	-	LM
24	18	6	706217	10.4	6.7	0.7	0.7	5.0	18.7	8.9	6.1	5.7	26.5	6.6	14.5	9.4	5.4	D.U.	Sıc.	Nem	-	-	LM
25	4	19	709189	10.4	7.3	0.6	0.7	1.9	4.5	0.9	4.2	8.4	11.2	5.6	21.3	10.2	13.6	D.U.	Sıc.	Bas.	-	-	LM

Çizelge 4.6. SCG algoritması ve 3 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm							Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem	
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış									Ortalama Yükseklik
1	17	7	218959	9.7	10.9	0.2	0.8	9.0	17.9	21.4	5.7	12.8	6.2	0.3	16.6	8.1	9.2	Boy.	Yük.	Bakı	-	-	SCG
2	20	16	710788	10.0	11.2	0.0	0.7	9.6	15.7	10.3	9.1	7.3	24.2	10.2	13.2	8.9	5.8	D.U.	Nem.	Bas.	-	-	SCG
3	20	11	441366	10.1	11.1	0.1	0.7	3.9	21.6	6.0	0.1	13.1	11.7	0.2	17.8	9.3	10.3	Yük.	Bakı	A.U.	-	-	SCG
4	9	14	1104031	10.2	10.9	0.0	0.7	4.7	30.5	5.3	0.7	7.6	11.6	2.6	17.2	8.8	8.4	K3	A.U.	Sic.	-	-	SCG
5	18	0	36470	10.2	9.1	0.3	0.8	4.2	23.2	17.4	6.9	2.3	16.7	7.8	21.0	8.4	7.7	D.U.	A.U.	Bas.	-	-	SCG
6	18	12	672491	10.2	11.8	0.1	0.7	0.5	14.8	21.1	4.4	12.4	16.8	13.6	22.6	8.3	4.9	D.U.	K4	Bas.	-	-	SCG
7	7	10	887043	10.2	10.3	0.0	0.7	9.2	3.1	3.0	6.5	1.2	22.6	5.1	20.0	10.1	6.3	Eğim	K4	Sic.	-	-	SCG
8	18	16	829910	10.3	8.5	0.3	0.7	11.0	26.8	0.5	3.5	2.1	17.8	3.3	19.0	8.5	10.2	Bakı	Nem	Bas.	-	-	SCG
9	20	18	909528	10.4	12.1	0.1	0.7	0.8	23.5	28.9	4.4	0.2	16.6	1.3	20.6	7.3	8.4	Eğim	A.U.	Nem	-	-	SCG
10	14	13	1118402	10.4	11.2	0.2	0.7	3.2	22.5	9.7	1.7	0.4	18.7	5.0	23.5	9.4	4.1	K3	GPM	Nem	-	-	SCG
11	4	16	2013980	10.4	9.6	0.2	0.7	7.4	24.3	0.3	10.4	3.6	17.5	5.2	22.6	8.9	8.1	K4	GPM	Nem	-	-	SCG
12	20	0	31065	10.4	9.0	0.3	0.7	7.2	27.9	8.3	8.2	7.3	19.4	6.8	18.9	8.6	6.3	D.U.	Bakı	Nem	-	-	SCG
13	20	11	569524	10.4	8.9	0.3	0.7	7.2	22.2	1.0	12.0	6.3	21.9	6.3	18.2	9.1	7.7	Yük.	Nem	Bas.	-	-	SCG
14	5	13	427044	10.5	8.9	0.2	0.7	0.6	30.0	4.4	3.1	2.6	15.5	5.6	22.9	8.5	9.1	Yük.	D.U.	Nem	-	-	SCG
15	8	12	972075	10.5	9.5	0.1	0.7	6.8	21.5	7.8	1.6	7.3	13.6	3.6	24.3	9.4	8.3	K1	K4	Bas.	-	-	SCG
16	2	19	875238	10.5	8.9	0.2	0.7	8.1	4.8	8.7	9.8	3.9	21.2	2.3	20.8	10.1	8.0	Eğim	K3	Sic.	-	-	SCG
17	11	19	817524	10.5	10.1	0.1	0.7	0.2	26.1	13.0	12.1	2.1	15.2	4.0	20.7	8.9	7.7	Bakı	G.U.	Nem	-	-	SCG
18	15	7	727960	10.5	9.5	0.1	0.7	5.4	20.2	2.8	5.8	1.6	18.0	5.3	19.8	9.9	8.3	Bakı	Eğim	Nem	-	-	SCG
19	12	15	95146	10.5	9.9	0.2	0.7	2.9	22.6	0.2	0.1	11.2	17.1	0.2	19.3	9.3	11.6	En.	Bakı	Nem	-	-	SCG
20	12	10	405133	10.5	10.2	0.1	0.7	3.8	16.9	1.2	12.6	1.0	28.9	5.5	16.7	9.1	7.7	Boy.	Nem	Bas.	-	-	SCG
21	12	19	2048596	10.5	8.9	0.3	0.7	7.2	18.3	6.0	3.2	3.2	27.9	10.4	17.5	9.2	7.0	K5	Nem	Bas.	-	-	SCG
22	18	15	1006704	10.6	8.1	0.5	0.7	8.5	21.4	9.2	5.3	15.1	17.9	0.7	17.8	9.6	6.1	K1	Sic.	Nem	-	-	SCG
23	10	11	365510	10.6	9.5	0.1	0.7	2.8	20.4	5.4	3.4	1.9	13.5	3.7	23.9	9.8	10.3	Boy.	K4	Nem	-	-	SCG
24	9	20	763457	10.6	11.2	0.0	0.7	6.6	19.1	27.9	0.5	4.3	25.3	7.8	15.9	7.6	8.3	Bakı	K2	Nem	-	-	SCG
25	19	16	97085	10.6	9.5	0.2	0.7	8.1	17.3	8.2	1.7	1.7	20.6	0.4	26.0	9.4	8.1	En.	Bakı	Bas.	-	-	SCG



Çizelge 4.7. LM algoritması ve 4 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konular KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik								
1	3	7	67269	10.5	8.6	0.4	0.7	3.2	27.9	5.7	8.6	3.2	20.6	0.2	17.0	9.4	4.4	En.	Boy.	Bakı	Nem	-	LM
2	3	12	11788	10.8	8.0	0.5	0.7	1.1	16.9	2.9	5.0	11.3	17.0	1.8	19.8	10.8	7.0	En.	Boy.	Yük.	K4	-	LM
3	11	9	184825	11.2	8.5	0.5	0.6	6.2	25.0	15.8	17.9	3.0	22.0	1.3	18.6	9.4	5.3	En.	Boy.	Sic.	Nem	-	LM
4	11	6	59992	11.2	13.3	0.1	0.6	4.0	27.1	2.6	7.2	2.5	20.4	0.9	19.9	10.4	6.1	En.	Boy.	Bakı	A.U.	-	LM
5	4	6	67176	11.2	8.1	0.5	0.6	0.3	29.8	13.3	20.9	3.6	17.3	1.4	17.7	9.4	4.6	En.	Boy.	Bakı	Nem	-	LM
6	3	10	67553	11.2	7.2	0.6	0.7	3.7	36.4	1.6	10.0	1.3	9.1	2.2	18.3	9.7	7.9	En.	Boy.	Bakı	Nem	-	LM
7	11	11	67690	11.3	8.4	0.4	0.6	2.8	24.0	6.3	11.3	1.4	14.7	1.9	16.8	11.3	7.0	En.	Boy.	Bakı	Nem	-	LM
8	12	5	180836	11.3	8.8	0.4	0.6	3.4	26.8	6.0	7.5	4.4	20.2	1.4	22.1	10.4	6.0	En.	Boy.	GPM	Nem	-	LM
9	2	15	46363	11.3	8.2	0.4	0.7	2.9	31.6	8.9	6.6	1.2	19.2	6.6	21.7	9.8	5.7	En.	Boy.	D.U.	Nem	-	LM
10	16	19	48620	11.4	5.3	0.8	0.6	4.1	24.4	10.8	17.4	9.1	13.3	5.5	15.5	11.0	3.6	En.	Boy.	D.U.	Bas.	-	LM
11	3	11	51403	11.4	8.2	0.5	0.7	4.7	27.3	7.6	4.4	4.2	13.6	0.5	17.8	11.3	6.0	En.	Boy.	Bakı	K1	-	LM
12	2	12	121890	11.4	8.7	0.3	0.6	7.7	20.2	3.2	7.5	4.7	30.5	2.9	21.4	9.9	7.6	En.	Boy.	K2	Nem	-	LM
13	20	16	181922	11.4	11.1	0.5	0.6	1.5	16.3	7.5	23.7	6.6	25.1	11.8	12.2	10.2	7.1	En.	Boy.	GPM	Nem	-	LM
14	19	6	22127	11.5	8.6	0.5	0.7	2.7	26.9	20.3	12.5	0.5	19.9	2.9	16.9	10.1	5.0	En.	Boy.	Yük.	Nem	-	LM
15	17	19	182195	11.5	5.4	0.8	0.6	0.1	30.5	6.0	10.0	8.1	13.9	4.7	21.9	10.6	1.4	En.	Boy.	GPM	Nem	-	LM
16	6	7	135873	11.5	6.6	0.7	0.7	7.1	29.9	7.8	7.8	5.5	16.3	6.3	21.4	10.1	8.5	En.	Boy.	K3	Nem	-	LM
17	5	19	182134	11.5	9.0	0.4	0.6	4.8	26.3	2.0	14.7	19.7	19.9	2.1	16.5	10.2	3.5	En.	Boy.	GPM	Nem	-	LM
18	5	4	66992	11.5	6.8	0.7	0.7	3.4	30.2	3.3	8.9	6.9	14.6	1.9	22.8	10.3	8.0	En.	Boy.	Bakı	Nem	-	LM
19	3	14	149158	11.5	9.4	0.3	0.7	9.2	32.5	12.1	1.5	2.2	11.0	2.6	12.6	10.4	11.4	En.	Boy.	K4	Nem	-	LM
20	3	6	168252	11.6	8.2	0.4	0.6	8.1	27.8	2.3	4.9	4.2	18.6	6.1	15.5	11.1	8.0	En.	Boy.	A.U.	Nem	-	LM
21	5	10	67564	11.6	8.4	0.5	0.6	0.8	27.8	5.0	10.2	4.9	18.0	1.0	20.7	11.0	4.6	En.	Boy.	Bakı	Nem	-	LM
22	20	10	45980	11.6	7.3	0.6	0.6	3.7	29.4	2.9	6.9	4.2	22.0	2.5	20.9	10.4	6.2	En.	Boy.	D.U.	Nem	-	LM
23	11	18	46695	11.6	7.6	0.6	0.7	6.5	30.0	4.3	8.0	3.5	13.1	10.9	22.7	10.1	10.1	En.	Boy.	D.U.	Nem	-	LM
24	4	9	65660	11.6	11.2	-0.1	0.6	7.9	21.8	14.5	8.1	4.7	15.6	10.2	19.9	11.0	7.3	En.	Boy.	Bakı	Sic.	-	LM
25	14	19	189400	11.6	9.1	0.5	0.6	2.6	27.6	4.8	25.3	5.7	15.8	2.8	15.1	10.5	1.5	En.	Boy.	Nem	Bas.	-	LM

Çizelge 4.8. SCG algoritması ve 4 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik								
1	18	0	3693	10.5	8.2	0.4	0.7	4.9	27.7	7.1	6.0	1.1	17.7	4.9	14.8	9.6	7.1	En.	Boy.	Bakı	Bas.	-	SCG
2	4	7	67275	10.9	10.3	0.1	0.7	1.9	24.3	26.4	14.3	7.8	18.0	5.8	8.8	9.0	7.2	En.	Boy.	Bakı	Nem	-	SCG
3	3	9	69263	11.2	8.7	0.3	0.7	6.7	28.3	8.6	5.5	2.2	18.0	1.9	19.4	10.2	7.7	En.	Boy.	Bakı	Bas.	-	SCG
4	20	0	9403	11.2	11.9	0.0	0.7	6.2	16.4	21.3	0.6	1.2	22.0	3.7	20.6	9.8	10.4	En.	Boy.	G.U.	Bas.	-	SCG
5	20	0	7787	11.3	11.4	0.2	0.7	20.9	12.6	1.3	18.2	13.1	5.6	1.4	10.4	10.0	15.8	En.	Boy.	K4	Sic.	-	SCG
6	2	17	21282	11.3	8.9	0.2	0.7	7.3	26.7	8.9	7.6	0.4	19.1	2.2	20.7	10.2	7.9	En.	Boy.	Yük.	Sic.	-	SCG
7	9	0	9441	11.3	8.2	0.4	0.7	1.8	28.3	13.5	11.6	1.1	18.9	7.5	20.2	9.9	5.7	En.	Boy.	GPM	Sic.	-	SCG
8	15	19	45004	11.3	9.6	0.3	0.7	3.6	22.3	13.8	4.2	5.3	24.3	4.4	21.3	10.0	8.0	En.	Boy.	D.U.	Sic.	-	SCG
9	5	12	148979	11.4	9.4	0.2	0.7	8.9	24.5	0.2	4.9	8.3	13.1	5.0	23.9	10.0	12.5	En.	Boy.	K4	Nem	-	SCG
10	14	12	188731	11.4	8.9	0.3	0.6	1.5	31.4	7.6	9.9	0.5	21.6	7.8	16.0	9.7	8.9	En.	Boy.	Nem	Bas.	-	SCG
11	3	7	11311	11.4	10.1	0.0	0.7	9.2	28.9	4.7	4.0	3.4	13.4	7.2	22.9	9.9	11.3	En.	Boy.	Yük.	K4	-	SCG
12	10	14	67966	11.4	8.4	0.4	0.7	5.5	30.5	11.4	5.3	9.9	15.0	3.8	20.8	9.8	9.4	En.	Boy.	Bakı	Nem	-	SCG
13	12	7	135903	11.5	9.1	0.3	0.6	0.0	27.9	13.0	11.3	6.4	20.4	7.3	23.5	9.5	7.5	En.	Boy.	K3	Nem	-	SCG
14	2	20	184019	11.5	13.1	-0.1	0.6	8.6	24.1	17.9	17.1	12.5	16.6	6.7	11.7	9.5	12.2	En.	Boy.	GPM	Bas.	-	SCG
15	5	12	150782	11.6	12.6	0.1	0.6	4.9	24.5	12.8	19.1	2.0	14.4	3.8	22.9	9.8	10.8	En.	Boy.	K4	Bas.	-	SCG
16	17	14	183522	11.6	7.5	0.6	0.6	3.9	27.6	26.6	16.4	3.6	20.1	7.2	9.8	9.4	5.8	En.	Boy.	GPM	Bas.	-	SCG
17	7	16	151171	11.6	11.3	0.2	0.6	3.5	18.2	11.4	20.0	8.0	27.6	12.7	8.5	10.3	6.7	En.	Boy.	K4	Bas.	-	SCG
18	4	9	184789	11.6	8.9	0.3	0.6	6.7	20.8	16.9	9.7	3.8	26.5	5.7	16.5	10.2	8.7	En.	Boy.	Sic.	Nem	-	SCG
19	8	6	184524	11.6	7.8	0.5	0.6	9.6	27.2	18.7	15.1	0.5	20.8	6.6	14.1	10.2	4.7	En.	Boy.	Sic.	Nem	-	SCG
20	7	18	149556	11.6	9.4	0.2	0.6	0.4	7.7	3.4	3.5	6.2	23.1	10.0	21.5	11.9	6.3	En.	Boy.	K4	Nem	-	SCG
21	18	17	183813	11.6	8.6	0.4	0.6	3.7	30.0	19.7	0.5	11.3	24.4	7.8	12.1	9.9	3.2	En.	Boy.	GPM	Bas.	-	SCG
22	7	19	88283	11.6	10.0	0.1	0.6	7.0	21.1	1.5	8.1	26.9	21.8	5.6	17.4	9.8	8.9	En.	Boy.	Eğim	Nem	-	SCG
23	11	15	69874	11.7	15.1	0.1	0.6	3.5	15.2	12.8	4.5	2.2	9.7	11.1	11.4	10.8	19.3	En.	Boy.	Bakı	Bas.	-	SCG
24	5	17	162086	11.7	10.1	0.2	0.6	4.7	30.7	12.1	13.2	7.1	22.8	14.6	17.6	9.0	9.8	En.	Boy.	K5	Bas.	-	SCG
25	13	15	174575	11.7	7.5	0.6	0.6	7.5	28.5	15.2	7.9	3.2	23.1	8.7	21.0	10.1	1.6	En.	Boy.	G.U.	Sic.	-	SCG

Çizelge 4.9. LM algoritması ve 5 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm							Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem	
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış									Ortalama Yükseklik
1	16	15	629450	10.3	8.1	0.5	0.7	9.3	25.9	10.8	2.0	9.1	10.0	0.8	5.7	9.9	8.5	En.	Boy.	K2	K4	Nem	LM
2	17	20	803210	10.3	10.0	0.4	0.7	1.7	35.0	8.4	9.0	6.3	11.6	3.5	11.1	8.2	9.7	En.	Boy.	A.U.	Nem	Bas.	LM
3	12	17	340817	10.5	11.2	0.5	0.7	5.5	17.2	8.2	14.5	0.9	5.0	9.3	14.3	10.9	6.2	En.	Boy.	Bakı	K1	Nem	LM
4	3	14	809789	10.5	7.6	0.5	0.7	6.5	29.6	5.9	3.0	3.0	16.2	5.5	15.8	9.4	7.8	En.	Boy.	G.U.	Sic.	Nem	LM
5	13	17	689186	10.5	7.8	0.6	0.7	2.9	27.1	3.0	2.9	1.8	18.7	5.0	2.5	10.5	5.8	En.	Boy.	K3	K5	Sic.	LM
6	14	14	817061	10.6	8.5	0.5	0.7	0.6	25.8	6.4	7.4	5.2	15.3	5.2	19.7	10.1	2.9	En.	Boy.	GPM	Sic.	Bas.	LM
7	12	17	265006	10.7	9.1	0.5	0.7	3.3	21.0	16.3	13.4	16.0	13.8	7.5	24.9	8.1	8.9	En.	Boy.	D.U.	K4	Nem	LM
8	2	18	586345	10.7	9.0	0.2	0.7	5.7	21.0	12.1	1.1	8.1	14.9	0.3	21.7	10.1	6.2	En.	Boy.	K1	A.U.	Bas.	LM
9	10	14	250271	10.7	9.7	0.5	0.7	1.1	23.3	3.5	11.1	2.1	25.2	10.5	15.2	9.8	1.8	En.	Boy.	D.U.	K3	Sic.	LM
10	4	13	419818	10.8	10.0	0.3	0.7	6.8	23.9	2.9	7.2	14.7	18.2	2.8	13.1	10.3	5.0	En.	Boy.	Bakı	Sic.	Nem	LM
11	2	20	593754	10.8	9.3	0.3	0.7	0.3	27.4	11.3	10.8	3.0	16.8	0.8	14.7	10.2	3.1	En.	Boy.	K1	G.U.	Bas.	LM
12	8	0	5069	10.8	8.8	0.3	0.7	5.2	27.6	8.4	14.2	6.7	16.8	4.0	9.7	10.1	6.0	En.	Boy.	Yük.	K2	Nem	LM
13	19	0	43026	10.8	8.8	0.4	0.7	8.7	27.4	1.2	11.4	4.1	14.0	9.6	12.7	10.3	5.0	En.	Boy.	GPM	Sic.	Bas.	LM
14	19	5	290977	10.8	6.3	0.7	0.7	4.4	23.8	14.2	10.7	0.4	9.4	5.8	11.4	10.7	8.5	En.	Boy.	D.U.	G.U.	Nem	LM
15	17	12	679710	10.9	8.2	0.5	0.7	6.0	25.0	10.5	6.2	3.0	13.4	5.6	18.1	10.5	6.0	En.	Boy.	K3	K4	Nem	LM
16	2	17	562784	10.9	8.2	0.4	0.7	7.7	27.4	1.6	17.0	2.6	15.5	2.5	14.1	10.2	3.8	En.	Boy.	K1	K4	Sic.	LM
17	19	9	275114	10.9	9.1	0.1	0.7	6.4	28.9	9.6	13.0	4.1	15.9	4.8	14.5	9.4	9.9	En.	Boy.	D.U.	K5	Nem	LM
18	7	11	795084	10.9	8.8	0.3	0.7	3.9	27.2	5.2	11.9	2.1	18.3	1.6	17.2	10.0	6.6	En.	Boy.	A.U.	GPM	Nem	LM
19	10	9	778665	10.9	6.6	0.7	0.7	5.3	33.8	10.5	9.1	1.2	14.8	8.9	2.9	9.7	7.6	En.	Boy.	K5	GPM	Bas.	LM
20	9	16	483301	10.9	7.1	0.7	0.7	4.5	12.0	30.6	6.2	2.9	19.2	3.1	14.7	9.3	9.1	En.	Boy.	Eğim	K4	Nem	LM
21	14	20	707527	10.9	7.0	0.7	0.7	7.0	23.2	6.1	5.2	7.8	16.9	10.1	23.0	9.9	6.6	En.	Boy.	K3	G.U.	Nem	LM
22	10	19	416806	10.9	5.8	0.8	0.7	1.6	32.5	7.4	10.8	3.7	7.0	5.3	15.4	10.2	4.8	En.	Boy.	Bakı	GPM	Nem	LM
23	14	5	653757	11.0	6.2	0.8	0.7	6.7	26.0	27.6	0.6	0.7	18.1	4.0	8.9	9.3	7.3	En.	Boy.	K2	G.U.	Sic.	LM
24	6	19	750712	11.0	10.7	0.0	0.7	7.0	28.3	24.5	11.6	0.3	14.3	5.0	8.2	8.1	14.5	En.	Boy.	K4	GPM	Nem	LM
25	6	18	797548	11.0	8.8	0.5	0.6	1.6	25.7	11.1	17.4	5.7	22.2	9.5	2.0	10.1	3.9	En.	Boy.	A.U.	GPM	Bas.	LM

Çizelge 4.10. SCG algoritması ve 5 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANN uygulamaları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm							Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem	
								Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış									Ortalama Yükseklik
1	7	19	1591880	9.9	9.7	0.2	0.7	1.0	17.9	1.6	7.2	5.5	17.6	9.8	20.2	9.1	7.5	En.	Boy.	K2	K4	Bas.	SCG
2	13	5	1383002	10.4	10.1	0.1	0.8	5.1	23.6	20.5	9.0	2.4	15.7	2.2	11.6	8.8	10.7	En.	Boy.	Bakı	Nem	Bas.	SCG
3	14	19	1041387	10.6	8.4	0.4	0.7	0.2	24.8	22.5	7.7	3.6	11.5	2.2	14.6	9.6	6.8	En.	Boy.	Yük.	K1	Nem	SCG
4	17	16	1329918	10.7	8.9	0.3	0.7	8.4	19.5	0.4	12.8	6.0	22.1	7.9	20.7	9.3	8.2	En.	Boy.	Bakı	K3	Sıc.	SCG
5	7	17	1759553	10.8	9.7	0.3	0.7	1.9	28.4	12.3	4.5	9.6	21.7	8.3	12.2	8.6	12.1	En.	Boy.	A.U.	Sıc.	Nem	SCG
6	2	11	1282440	10.9	9.6	0.1	0.7	4.7	8.7	16.5	6.3	3.5	17.0	6.1	20.0	11.0	6.2	En.	Boy.	Bakı	Eğim	Nem	SCG
7	7	18	23209	10.9	8.4	0.4	0.7	5.7	33.0	2.6	6.8	1.9	20.9	8.4	13.5	9.1	8.6	En.	Boy.	Yük.	D.U.	Bas.	SCG
8	11	20	1754444	11.0	8.0	0.5	0.7	2.7	28.5	7.7	7.8	7.9	18.7	9.3	11.3	10.3	5.3	En.	Boy.	A.U.	GPM	Sıc.	SCG
9	6	12	1013606	11.0	11.4	-0.1	0.7	2.8	20.4	19.3	4.5	8.9	22.6	4.1	16.6	9.8	8.2	En.	Boy.	Yük.	Eğim	K5	SCG
10	8	18	1759652	11.1	8.2	0.4	0.7	4.2	30.1	4.7	15.0	0.3	17.3	3.1	17.0	9.8	7.5	En.	Boy.	A.U.	Sıc.	Nem	SCG
11	16	12	1712191	11.1	11.1	0.1	0.7	14.4	11.1	14.1	10.1	6.8	8.3	5.9	10.5	11.0	13.1	En.	Boy.	K4	GPM	Bas.	SCG
12	2	12	1284337	11.1	8.7	0.3	0.7	6.2	26.4	13.7	4.9	2.2	18.7	0.9	20.2	10.0	6.9	En.	Boy.	Bakı	Eğim	Bas.	SCG
13	9	13	1261004	11.1	12.4	0.0	0.7	8.6	21.3	8.0	2.7	5.6	28.4	13.8	23.1	9.0	6.5	En.	Boy.	D.U.	Sıc.	Nem	SCG
14	3	19	30505	11.1	10.0	0.1	0.7	1.3	17.6	18.0	10.8	11.5	3.1	5.3	22.1	10.7	7.1	En.	Boy.	Yük.	Bakı	K3	SCG
15	20	20	1263528	11.2	9.9	0.2	0.7	1.6	28.9	14.1	10.4	1.2	14.5	9.9	13.0	9.9	9.7	En.	Boy.	D.U.	Sıc.	Bas.	SCG
16	18	14	1317098	11.2	8.5	0.4	0.7	1.7	34.5	11.6	14.3	1.2	13.5	0.9	18.2	9.1	8.0	En.	Boy.	Bakı	K2	Nem	SCG
17	8	0	39838	11.2	8.7	0.4	0.6	8.5	17.2	14.1	11.3	14.5	19.5	7.4	19.2	9.9	8.9	En.	Boy.	K4	Nem	Bas.	SCG
18	9	15	1777423	11.2	9.5	0.1	0.7	2.5	31.9	13.2	5.7	7.3	10.7	6.1	24.1	8.7	11.3	En.	Boy.	GPM	Sıc.	Bas.	SCG
19	11	8	1758718	11.2	9.2	0.3	0.7	5.3	33.2	4.0	8.6	11.7	18.5	7.3	5.3	9.7	9.0	En.	Boy.	A.U.	Sıc.	Nem	SCG
20	2	15	1445270	11.2	9.4	-0.1	0.7	7.2	18.3	2.6	7.7	8.7	18.9	2.2	21.5	10.7	8.6	En.	Boy.	Eğim	K4	Bas.	SCG
21	9	19	14287	11.2	9.8	0.1	0.7	0.6	28.2	17.8	15.3	3.4	23.4	7.3	17.4	8.3	10.1	En.	Boy.	Yük.	D.U.	A.U.	SCG
22	5	14	1280931	11.2	12.9	-0.1	0.6	2.8	16.3	21.6	5.9	11.9	9.4	5.6	17.6	11.2	4.1	En.	Boy.	Bakı	Eğim	Sıc.	SCG
23	17	9	1589171	11.2	8.4	0.4	0.7	1.0	27.4	22.8	3.0	9.4	15.1	7.7	13.0	9.8	7.8	En.	Boy.	K2	K4	Nem	SCG
24	9	20	1698478	11.2	7.6	0.5	0.7	9.2	30.7	5.0	6.5	0.8	16.3	8.9	15.7	10.2	7.6	En.	Boy.	K4	A.U.	Nem	SCG
25	5	14	1690668	11.2	9.2	0.3	0.7	11.3	16.7	27.1	6.5	9.0	16.2	4.9	16.3	10.1	5.5	En.	Boy.	K4	K5	Bas.	SCG

Çizelge 4.1.'de verilen uygulama bulgularına göre 1 girdi kullanılarak, ANN-LM ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 10.49$  mm hata değeri ile 27216 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak nem değişkeni kullanılmıştır. En düşük eğitim KOH değeri 28159 yöntem numaralı (Çizelge sırası: 9) uygulama ile nem girdisi kullanılarak  $\pm 8.19$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 27140 yöntem numaralı (Çizelge sırası: 25) uygulama ile nem girdisi kullanılarak  $\pm 3.53$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 27216 yöntem numaralı (Çizelge sırası: 1) uygulama ile nem girdisi kullanılarak  $\pm 15.84$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 28159 yöntem numaralı (Çizelge sırası: 9) uygulama ile nem girdisi kullanılarak  $\pm 3.35$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 28189 yöntem numaralı (Çizelge sırası: 5) uygulama ile nem girdisi kullanılarak  $\pm 0.22$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 27411 yöntem numaralı (Çizelge sırası: 10) uygulama ile nem girdisi kullanılarak  $\pm 16.29$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 27314 yöntem numaralı (Çizelge sırası: 6) uygulama ile nem girdisi kullanılarak  $\pm 0.13$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 30266 yöntem numaralı (Çizelge sırası: 16) uygulama ile basınç girdisi kullanılarak  $\pm 22.67$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 27216 yöntem numaralı (Çizelge sırası: 1) uygulama ile nem girdisi kullanılarak  $\pm 0.11$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 27216 yöntem numaralı (Çizelge sırası: 1) uygulama ile nem girdisi kullanılarak  $\pm 9.10$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 28261 yöntem numaralı (Çizelge sırası: 3) uygulama ile nem girdisi kullanılarak  $\pm 3.71$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 28159 yöntem numaralı (Çizelge sırası: 9) uygulama ile nem girdisi kullanılarak, R eğitim 0.43, R test 0.68 ve  $\pm 11.0$  mm test KOH değeri ile gerçekleştirilmiştir. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler nem ve basınç dışındaki değişkenlerdir. En düşük test KOH değerine göre sıralanan çizelgede, nöron

sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın 24'ü çift katmanlı sinir ağı yapısı ile gerçekleştirilirken 1'i tek katmanlı olarak gerçekleştirilmiştir. Nöron sayıları 1. ve 2. katman için genellikle 2 ila 19 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.1.'de yer alan bilgilere göre 27216 yöntem numaralı (Çizelge sırası: 1), nem girdisi kullanılan uygulama, 1 girdili ve LM algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 27216 uygulamasının 1. katman nöron sayısı 11, 2. katman nöron sayısı ise 3'tür.

Çizelge 4.2.'de verilen uygulama bulgularına göre 1 girdi kullanılarak, ANN-SCG ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 10.46$  mm hata değeri ile 4817 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak yükseklik değişkeni kullanılmıştır. En düşük eğitim KOH değeri 1502 yöntem numaralı (Çizelge sırası: 7) uygulama ile nem girdisi kullanılarak,  $\pm 8.51$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 30409 yöntem numaralı (Çizelge sırası: 2) uygulama ile basınç girdisi kullanılarak  $\pm 1.29$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 30409 yöntem numaralı (Çizelge sırası: 2) uygulama ile basınç girdisi kullanılarak  $\pm 1.29$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 27681 yöntem numaralı (Çizelge sırası: 3) uygulama ile nem girdisi kullanılarak  $\pm 2.45$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 27540 yöntem numaralı (Çizelge sırası: 21) uygulama ile nem girdisi kullanılarak  $\pm 0.23$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 27681 yöntem numaralı (Çizelge sırası: 3) uygulama ile nem girdisi kullanılarak  $\pm 15.85$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 4817 yöntem numaralı (Çizelge sırası: 1) uygulama ile yükseklik girdisi kullanılarak  $\pm 0.07$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 4817 yöntem numaralı (Çizelge sırası: 1) uygulama ile yükseklik girdisi kullanılarak  $\pm 17.22$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 27314 yöntem numaralı (Çizelge sırası: 19) uygulama ile nem girdisi kullanılarak  $\pm 0.16$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 29372 yöntem numaralı (Çizelge sırası: 22) uygulama

ile basınç girdisi kullanılarak  $\pm 8.84$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 4817 yöntem numaralı (Çizelge sırası: 1) uygulama ile yükseklik girdisi kullanılarak  $\pm 5.37$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 1502 yöntem numaralı (Çizelge sırası: 7) uygulama ile nem girdisi kullanılarak R eğitim 0.35, R test 0.68 ve  $\pm 0.7$  mm test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkeni nem olup, en az kullanılan değişkenler basınç ve yükseklik olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler nem, basınç ve yükseklik dışındaki değişkenlerdir. En düşük test KOH değerine göre sıralanan çizelgede, nöron sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın 23'ü çift katmanlı sinir ağı yapısı ile gerçekleştirilirken 2'si tek katmanlı olarak gerçekleştirilmiştir. Nöron sayıları 1. ve 2. katman için genellikle 7 ila 20 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.2.'de yer alan bilgilere göre 4817 yöntem numaralı (Çizelge sırası: 1) yükseklik girdisi kullanılan uygulama, 1 girdili ve SCG algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 4817 uygulamasının 1. katman nöron sayısı 15, 2. katman nöron sayısı ise 14'tür.

Çizelge 4.3.'te verilen uygulama bulgularına göre 2 girdi kullanılarak, ANN-LM ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 10.02$  mm hata değeri ile 103980 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada girdi olarak denize uzaklık ve basınç değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 61952 yöntem numaralı (Çizelge sırası: 2) uygulama ile yükseklik ve 1. en yakın komşu girdileri kullanılarak  $\pm 7.07$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 244096 yöntem numaralı (Çizelge sırası: 20) uygulama ile nem ve basınç girdileri kullanılarak  $\pm 0.01$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 215888 yöntem numaralı (Çizelge sırası: 17) uygulama ile nem ve 5. en yakın komşu girdileri kullanılarak  $\pm 13.90$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 103984 yöntem numaralı (Çizelge sırası: 4) uygulama ile denize uzaklık ve basınç girdileri kullanılarak  $\pm 1.11$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 6510 yöntem numaralı (Çizelge sırası: 15) uygulama ile bakı ve nem girdileri kullanılarak  $\pm 0.90$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test

noktası için en düşük tahmin hatası 244096 yöntem numaralı (Çizelge sırası: 20) uygulama ile nem ve basınç girdileri kullanılarak  $\pm 10.24$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 6510 yöntem numaralı (Çizelge sırası: 15) uygulama ile bakı ve nem girdileri kullanılarak  $\pm 0.24$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 61952 yöntem numaralı (Çizelge sırası: 2) uygulama ile yükseklik ve 1. en yakın komşu girdileri kullanılarak  $\pm 10.60$  mm hata değeri ile elde edilmiştir. Maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 225083 yöntem numaralı (Çizelge sırası: 25) uygulama ile akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 1.39$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 102525 yöntem numaralı (Çizelge sırası: 11) uygulama ile denize uzaklık ve nem girdileri kullanılarak  $\pm 7.72$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 244521 yöntem numaralı (Çizelge sırası: 3) uygulama ile nem ve basınç girdileri kullanılarak  $\pm 3.31$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 61952 yöntem numaralı (Çizelge sırası: 2) uygulama ile yükseklik ve 1. en yakın komşu girdileri kullanılarak R eğitim 0.63, R test 0.73 ve  $\pm 10.03$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri basınç, denize uzaklık ve nem olup, en az kullanılan değişkenler akarsulara uzaklık, bakı, denize uzaklık, en yakın 1. ve 5. komşu ve yükseklik olmuştur. Diğer değişkenler kullanılmamıştır. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler nem ve basınç dışındaki değişkenlerdir. En düşük test KOH değerine göre sıralanan çizelgede, nöron sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın 21'i çift katmanlı sinir ağı yapısı ile gerçekleştirilirken 4'ü tek katmanlı olarak gerçekleştirilmiştir. Nöron sayıları 1. ve 2. katman için genellikle 6 ile 20 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.3.'te yer alan bilgilere göre 61952 yöntem numaralı (Çizelge sırası: 2), yükseklik ve 1. en yakın komşu girdisi kullanılan uygulama, 2 girdili ve LM algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 61952 uygulamasının 1. katman nöron sayısı 4, 2. katman nöron sayısı ise 8'dir.

Çizelge 4.4.'te verilen uygulama bulgularına göre 2 girdi kullanılarak, ANN-SCG ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 10.40$  mm hata değeri ile 123099 yöntem numaralı (Çizelge sırası: 5) uygulama olmuştur. Uygulamada eğitim için girdi olarak bakı ve nem değişkenleri



kullanılmıştır. En düşük eğitim KOH değeri 102766 yöntem numaralı (Çizelge sırası: 11) uygulama ile denize uzaklık ve nem girdileri kullanılarak  $\pm 8.10$  mm hata değeri ile elde edilmiştir. Düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 244988 yöntem numaralı (Çizelge sırası: 3) uygulama ile nem ve basınç girdileri kullanılarak  $\pm 0.67$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 245468 yöntem numaralı (Çizelge sırası: 7) uygulama ile nem ve basınç girdileri kullanılarak  $\pm 17.40$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 104116 yöntem numaralı (Çizelge sırası: 13) uygulama ile denize uzaklık ve basınç girdileri kullanılarak  $\pm 0.30$  mm hata değeri ile elde edilmiştir. Maksimum yükseklik ekstrapolasyon test noktası için en düşük tahmin hatası 56645 yöntem numaralı (Çizelge sırası: 5) uygulama ile yükseklik ve denize uzaklık girdileri kullanılarak  $\pm 0.38$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 103354 yöntem numaralı (Çizelge sırası: 8) uygulama ile denize uzaklık ve basınç girdileri kullanılarak  $\pm 11.38$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 123099 yöntem numaralı (Çizelge sırası: 1) uygulama ile bakı ve nem girdileri kullanılarak  $\pm 1.11$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 206918 yöntem numaralı (Çizelge sırası: 2) uygulama ile 4. en yakın komşu ve basınç girdileri kullanılarak  $\pm 4.68$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 245401 yöntem numaralı (Çizelge sırası: 10) uygulama ile nem ve basınç girdileri kullanılarak  $\pm 0.39$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 245221 yöntem numaralı (Çizelge sırası: 15) uygulama ile nem ve basınç girdileri kullanılarak  $\pm 8.10$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 245259 yöntem numaralı (Çizelge sırası: 14) uygulama ile nem ve basınç girdileri kullanılarak  $\pm 5.14$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 102766 yöntem numaralı (Çizelge sırası: 11) uygulama ile denize uzaklık ve nem girdileri kullanarak, R eğitim 0.45, R test 0.70 ve  $\pm 10.75$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri basınç, denize uzaklık ve nem olup, en az kullanılan değişkenler akarsulara uzaklık, bakı, en yakın 2. ve 4. komşu ve yükseklik olmuştur. Diğer değişkenler kullanılmamıştır. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler nem ve basınç dışındaki değişkenlerdir. En düşük test KOH değerine göre sıralanan çizelgede,

nöron sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın 24'ü çift katmanlı sinir ağı yapısı ile gerçekleştirilirken 1'i tek katmanlı olarak gerçekleştirilmiştir. Nöron sayıları 1. ve 2. katman için genellikle 5 ila 20 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.4.'te yer alan bilgilere göre 102766 yöntem numaralı (Çizelge sırası: 11) denize uzaklık ve nem girdisi kullanılan uygulama, 2 girdili ve SCG algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 102766 uygulamasının 1. katman nöron sayısı 16, 2. katman nöron sayısı ise 19'dur.

Çizelge 4.5.'te verilen uygulama bulgularına göre 3 girdi kullanılarak, ANN-LM ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 9.62$  mm hata değeri ile 709978 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak denize uzaklık, nem ve basınç değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 1215676 yöntem numaralı (Çizelge sırası: 18) uygulama ile göllere uzaklık, sıcaklık ve nem girdileri kullanılarak  $\pm 6.57$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 709978 yöntem numaralı (Çizelge sırası: 1) uygulama ile denize uzaklık, nem ve basınç girdileri kullanılarak  $\pm 0.05$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 981032 yöntem numaralı (Çizelge sırası: 2) uygulama ile 1. ve 5. en yakın komşu değeri ile nem girdileri kullanılarak  $\pm 12.04$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 1215676 yöntem numaralı (Çizelge sırası: 18) uygulama ile göllere uzaklık, sıcaklık ve nem girdileri kullanılarak  $\pm 0.69$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 1219269 yöntem numaralı (Çizelge sırası: 20) uygulama ile göllere uzaklık, nem ve basınç girdileri kullanılarak  $\pm 0.11$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 709978 yöntem numaralı (Çizelge sırası: 1) uygulama ile denize uzaklık, nem ve basınç girdileri kullanılarak  $\pm 9.55$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 709978 yöntem numaralı (Çizelge sırası: 1) uygulama ile denize uzaklık, nem ve basınç girdileri kullanılarak  $\pm 0.13$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 709189 yöntem numaralı (Çizelge sırası: 25) uygulama ile denize uzaklık, sıcaklık ve basınç girdileri kullanılarak  $\pm 4.51$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum

yağış ekstrapolasyon test noktası için en düşük tahmin hatası 820527 yöntem numaralı (Çizelge sırası: 15) uygulama ile bakı, GPM ve sıcaklık girdileri kullanılarak  $\pm 0.30$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 658377 yöntem numaralı (Çizelge sırası: 6) uygulama ile denize uzaklık, 3. en yakın komşu ve nem girdileri kullanılarak  $\pm 7.39$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 709978 yöntem numaralı (Çizelge sırası: 1) uygulama ile denize uzaklık, nem ve basınç girdileri kullanılarak  $\pm 4.12$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 709978 yöntem numaralı (Çizelge sırası: 1) uygulama ile girdileri kullanılarak R eğitim 0.61, R test 0.76 ve  $\pm 9.62$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri basınç, denize uzaklık, nem, sıcaklık ve göllere uzaklık olup, en az kullanılan değişkenler akarsulara uzaklık, bakı, GPM, enlem ve en yakın 1., 3., ve 5. komşu noktalar olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler boylam, eğim, en yakın 2. ve 4. komşu nokta değişkenleri olmuştur. En düşük test KOH değerine göre sıralanan çizelgede, nöron sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın hepsi çift katmanlı sinir ağı yapısı ile gerçekleştirilirken hiçbir uygulama tek katmanlı olarak gerçekleştirilmemiştir. Nöron sayıları 1. ve 2. katman için genellikle 6 ila 20 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.5.'te yer alan bilgilere göre 709978 yöntem numaralı (Çizelge sırası: 1) denize uzaklık, nem ve basınç girdisi kullanılan uygulama, 3 girdili ve LM algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 709978 uygulamasının 1. katman nöron sayısı 10, 2. katman nöron sayısı ise 8'dir.

Çizelge 4.6.'da verilen uygulama bulgularına göre 3 girdi kullanılarak, ANN-SCG ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 9.71$  mm hata değeri ile 218959 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak boylam, yükseklik ve bakı değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 1006704 yöntem numaralı (Çizelge sırası: 22) uygulama ile 1. en yakın komşu, sıcaklık ve nem girdileri kullanılarak  $\pm 8.05$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 817524 yöntem numaralı (Çizelge sırası: 17) uygulama ile bakı, göllere uzaklık ve nem girdileri kullanılarak  $\pm 0.24$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası

710788 yöntem numaralı (Çizelge sırası: 2) uygulama ile denize uzaklık, nem ve basınç girdileri kullanılarak  $\pm 13.23$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 441366 yöntem numaralı (Çizelge sırası: 3) uygulama ile yükseklik, bakı ve akarsulara uzaklık girdileri kullanılarak  $\pm 0.11$  mm hata değeri ile elde edilmiştir. Maksimum yüksekliğin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 909528 yöntem numaralı (Çizelge sırası: 9) uygulama ile eğim, akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 0.20$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 218959 yöntem numaralı (Çizelge sırası: 1) uygulama ile boylam, yükseklik ve bakı girdileri kullanılarak  $\pm 6.24$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 95146 yöntem numaralı (Çizelge sırası: 19) uygulama ile enlem, bakı ve nem girdileri kullanılarak  $\pm 0.20$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 887043 yöntem numaralı (Çizelge sırası: 7) uygulama ile eğim, 4. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 3.06$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 95146 yöntem numaralı (Çizelge sırası: 19) uygulama ile enlem, bakı ve nem girdileri kullanılarak  $\pm 0.16$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 909528 yöntem numaralı (Çizelge sırası: 9) uygulama ile eğim, akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 7.29$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 1118402 yöntem numaralı (Çizelge sırası: 10) uygulama ile 3. en yakın komşu, GPM ve nem girdileri kullanılarak  $\pm 4.05$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 1006704 yöntem numaralı (Çizelge sırası: 22) uygulama ile 1. en yakın komşu, sıcaklık ve nem girdileri kullanılarak R eğitim 0.46, R test 0.72 ve  $\pm 10.57$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri nem, basınç ve bakı olup, en az kullanılan değişkenler diğer 14 değişken olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler yoktur. En düşük test KOH değerine göre sıralanan çizelgede, nöron sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın 23'ü çift katmanlı sinir ağı yapısı ile gerçekleştirilirken 2'si tek katmanlı olarak gerçekleştirilmiştir. Nöron sayıları 1. ve 2. katman için genellikle 9 ila 20 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.6.'da yer alan bilgilere göre 1006704 yöntem numaralı (Çizelge

sırası: 22), 1. en yakın komşu, sıcaklık ve nem girdisi kullanılan uygulama, 3 girdili ve SCG algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 1006704 uygulamasının 1. katman nöron sayısı 18, 2. katman nöron sayısı ise 15'tir.

Çizelge 4.7.'de verilen uygulama bulgularına göre 4 girdi kullanılarak, ANN-LM ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 10.53$  mm hata değeri ile 67269 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak enlem, boylam, bakı ve nem değişkenleri kullanılmıştır. En düşük eğitim KOH değeri, 48620 yöntem numaralı (Çizelge sırası: 10) uygulama ile enlem, boylam, denize uzaklık ve basınç girdileri kullanılarak  $\pm 5.33$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 182195 yöntem numaralı (Çizelge sırası: 15) uygulama ile enlem, boylam, GPM ve nem girdileri kullanılarak  $\pm 0.12$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 181922 yöntem numaralı (Çizelge sırası: 13) uygulama ile enlem, boylam, 4. en yakın komşu ve nem girdileri kullanılarak  $\pm 12.18$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 149158 yöntem numaralı (Çizelge sırası: 19) uygulama ile enlem, boylam, 4. en yakın komşu ve nem girdileri kullanılarak  $\pm 1.48$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 22127 yöntem numaralı (Çizelge sırası: 14) uygulama ile enlem, boylam, yükseklik ve nem girdileri kullanılarak  $\pm 0.53$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 67553 yöntem numaralı (Çizelge sırası: 6) uygulama ile enlem, boylam, bakı ve nem girdileri kullanılarak  $\pm 9.14$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 67269 yöntem numaralı (Çizelge sırası: 1) uygulama ile enlem, boylam, bakı ve nem girdileri kullanılarak  $\pm 0.20$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 181922 yöntem numaralı (Çizelge sırası: 13) uygulama ile enlem, boylam, GPM ve nem girdileri kullanılarak  $\pm 16.35$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 67553 yöntem numaralı (Çizelge sırası: 6) uygulama ile enlem, boylam, bakı ve nem girdileri kullanılarak  $\pm 1.64$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 184825 yöntem numaralı (Çizelge sırası: 3) uygulama ile enlem, boylam, sıcaklık ve nem girdileri kullanılarak  $\pm 9.36$  mm hata değeri ile elde edilmiştir.

İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 182195 yöntem numaralı (Çizelge sırası: 15) uygulama ile enlem, boylam, GPM ve nem girdileri kullanılarak  $\pm 1.39$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 182195 yöntem numaralı (Çizelge sırası: 15) uygulama ile girdileri kullanılarak R eğitim 0.81, R test 0.64 ve  $\pm 11.46$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri bakı ve nem olup, en az kullanılan değişkenler akarsulara uzaklık, denizlere uzaklık, basınç, GPM, 1., 2., 3., 4. en yakın komşular, sıcaklık ve yükseklik olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler 5. en yakın komşu, eğim ve göllere uzaklık değişkenleridir. En düşük test KOH değerine göre sıralanan çizelgede, nöron sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın hepsi çift katmanlı sinir ağı yapısı ile gerçekleştirilmişken hiçbiri tek katmanlı olarak gerçekleştirilmemiştir. Nöron sayıları 1. ve 2. katman için genellikle 3 ila 20 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.7.'de yer alan bilgilere göre 182195 yöntem numaralı (Çizelge sırası: 15) enlem, boylam, GPM ve nem girdisi kullanılan uygulama, 4 girdili ve LM algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 182195 uygulamasının 1. katman nöron sayısı 17, 2. katman nöron sayısı ise 19'dur.

Çizelge 4.8.'de verilen uygulama bulgularına göre 4 girdi kullanılarak, ANN-SCG ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 10.51$  mm hata değeri ile 3693 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak enlem, boylam, bakı ve basınç değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 183522 yöntem numaralı (Çizelge sırası: 16) uygulama ile enlem, boylam, GPM ve basınç girdileri kullanılarak  $\pm 7.48$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 135903 yöntem numaralı (Çizelge sırası: 13) uygulama ile enlem, boylam, 3. en yakın komşu ve nem girdileri kullanılarak  $\pm 0.04$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 151171 yöntem numaralı (Çizelge sırası: 17) uygulama ile enlem, boylam, 4. en yakın komşu ve basınç girdileri kullanılarak  $\pm 8.46$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 183813 yöntem numaralı (Çizelge sırası: 21) uygulama ile enlem, boylam, GPM ve basınç girdileri kullanılarak  $\pm 0.55$  mm hata değeri ile elde edilmiştir. Eğitim setinin

maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 21282 yöntem numaralı (Çizelge sırası: 6) uygulama ile enlem, boylam, yükseklik ve sıcaklık girdileri kullanılarak  $\pm 0.35$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 7787 yöntem numaralı (Çizelge sırası: 5) uygulama ile enlem, boylam, 4. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 5.63$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 7787 yöntem numaralı (Çizelge sırası: 5) uygulama ile enlem, boylam, 4. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 1.44$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 149556 yöntem numaralı (Çizelge sırası: 20) uygulama ile enlem, boylam, 4. en yakın komşu ve nem girdileri kullanılarak  $\pm 7.75$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 148979 yöntem numaralı (Çizelge sırası: 9) uygulama ile enlem, boylam, 4. en yakın komşu ve nem girdileri kullanılarak  $\pm 0.21$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 67275 yöntem numaralı (Çizelge sırası: 2) uygulama ile enlem, boylam, bakı ve nem girdileri kullanılarak  $\pm 8.97$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 174575 yöntem numaralı (Çizelge sırası: 25) uygulama ile enlem, boylam, göllere uzaklık ve sıcaklık girdileri kullanılarak  $\pm 1.59$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 3693 yöntem numaralı (Çizelge sırası: 1) uygulama ile enlem, boylam, bakı ve basınç girdileri kullanılarak R eğitim 0.44, R test 0.71 ve  $\pm 10.51$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri bakı, basınç, nem ve sıcaklık olup, en az kullanılan değişkenler denize uzaklık, eğim, göllere uzaklık, GPM, 3., 4. ve 5. komşu nokta ve yükseklik olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler 1. ve 2. en yakın komşu ile akarsulara uzaklık değişkenleridir. En düşük test KOH değerine göre sıralanan çizelgede, nöron sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın 21'i çift katmanlı sinir ağı yapısı ile gerçekleştirilirken 4'ü tek katmanlı olarak gerçekleştirilmiştir. Nöron sayıları 1. ve 2. katman için genellikle 5 ila 20 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.8.'de yer alan bilgilere göre 3693 yöntem numaralı (Çizelge sırası: 1) enlem, boylam, bakı ve basınç girdisi kullanılan uygulama, 4 girdili ve SCG algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 3693

uygulamasının 1. katman nöron sayısı 18, 2. katman nöron sayısı ise tek katmanlı olduğu için 0'dır.

Çizelge 4.9.'da verilen uygulama bulgularına göre 5 girdi kullanılarak, ANN-LM ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 10.27$  mm hata değeri ile 629450 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak enlem, boylam, 2. en yakın komşu, 4. en yakın komşu ve nem değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 416806 yöntem numaralı (Çizelge sırası: 22) uygulama ile enlem, boylam, bakı, GPM ve nem girdileri kullanılarak  $\pm 5.80$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 593754 yöntem numaralı (Çizelge sırası: 11) uygulama ile enlem, boylam, GPM, sıcaklık ve basınç girdileri kullanılarak  $\pm 0.34$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 797548 yöntem numaralı (Çizelge sırası: 25) uygulama ile enlem, boylam, akarsulara uzaklık, GPM ve basınç girdileri kullanılarak  $\pm 2.03$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 653757 yöntem numaralı (Çizelge sırası: 23) uygulama ile enlem, boylam, 2. en yakın komşu, göllere uzaklık ve sıcaklık girdileri kullanılarak  $\pm 0.62$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 750712 yöntem numaralı (Çizelge sırası: 24) uygulama ile enlem, boylam, 4. en yakın komşu, GPM ve nem girdileri kullanılarak  $\pm 0.29$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 340817 yöntem numaralı (Çizelge sırası: 3) uygulama ile enlem, boylam, bakı, 1. en yakın komşu ve nem girdileri kullanılarak  $\pm 5.03$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 586345 yöntem numaralı (Çizelge sırası: 8) uygulama ile enlem, boylam, 1. en yakın komşu, akarsulara uzaklık ve basınç girdileri kullanılarak  $\pm 0.34$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 483301 yöntem numaralı (Çizelge sırası: 20) uygulama ile enlem, boylam, eğim, 4. en yakın komşu ve nem girdileri kullanılarak  $\pm 11.99$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 43026 yöntem numaralı (Çizelge sırası: 13) uygulama ile enlem, boylam, GPM, sıcaklık ve basınç girdileri kullanılarak  $\pm 1.17$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 750712 yöntem numaralı (Çizelge sırası: 24) uygulama ile enlem, boylam,



4. en yakın komşu, GPM ve nem girdileri kullanılarak  $\pm 8.06$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 250271 yöntem numaralı (Çizelge sırası: 9) uygulama ile enlem, boylam, denize uzaklık, 3. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 1.79$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 416806 yöntem numaralı (Çizelge sırası: 22) uygulama ile enlem, boylam, bakı, GPM ve nem girdileri kullanılarak, R eğitim 0.77, R test 0.69 ve  $\pm 10.94$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri nem, basınç, GPM, sıcaklık ve 4. en yakın komşu olup, en az kullanılan değişkenler enlem ve boylam dışındaki diğer 10 değişken olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişken olmamıştır. En düşük test KOH değerine göre sıralanan çizelgede, nöron sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın 23'ü çift katmanlı sinir ağı yapısı ile gerçekleştirilirken 2'si tek katmanlı olarak gerçekleştirilmiştir. Nöron sayıları 1. ve 2. katman için genellikle 5 ila 20 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.9.'da yer alan bilgilere göre 416806 yöntem numaralı (Çizelge sırası: 22) enlem, boylam, bakı, GPM ve nem girdisi kullanılan uygulama, 5 girdili ve LM algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 416806 uygulamasının 1. katman nöron sayısı 10, 2. katman nöron sayısı ise 19'dur.

Çizelge 4.10.'da verilen uygulama bulgularına göre 5 girdi kullanılarak, ANN-SCG ile gerçekleştirilen uygulamalar arasından en düşük test KOH değerine sahip olan uygulama  $\pm 9.88$  mm hata değeri ile 1591880 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak enlem, boylam, 2. ve 4. en yakın komşu ile basınç değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 1698478 yöntem numaralı (Çizelge sırası: 24) uygulama ile enlem, boylam, 4. en yakın komşu, akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 7.61$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 1041387 yöntem numaralı (Çizelge sırası: 3) uygulama ile enlem, boylam, yükseklik, 1. en yakın komşu ve nem girdileri kullanılarak  $\pm 0.23$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 1758718 yöntem numaralı (Çizelge sırası: 19) uygulama ile enlem, boylam, akarsulara uzaklık, sıcaklık ve nem girdileri kullanılarak  $\pm 5.31$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 1261004 yöntem numaralı (Çizelge sırası: 13) uygulama ile enlem, boylam, denize uzaklık, sıcaklık ve

nem girdileri kullanılarak  $\pm 2.67$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 0.34 yöntem numaralı (Çizelge sırası: 10) uygulama ile enlem, boylam, akarsulara uzaklık, sıcaklık ve nem girdileri kullanılarak  $\pm 0.34$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 30505 yöntem numaralı (Çizelge sırası: 14) uygulama ile enlem, boylam, yükseklik, bakı ve 3. en yakın komşu girdileri kullanılarak  $\pm 3.09$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 1317098 yöntem numaralı (Çizelge sırası: 16) uygulama ile enlem, boylam, bakı, eğim ve basınç girdileri kullanılarak  $\pm 0.86$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 1282440 yöntem numaralı (Çizelge sırası: 6) uygulama ile enlem, boylam, bakı, eğim ve nem girdileri kullanılarak  $\pm 8.67$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 1329918 yöntem numaralı (Çizelge sırası:4) uygulama ile enlem, boylam, bakı, 3. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 0.43$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 14287 yöntem numaralı (Çizelge sırası: 21) uygulama ile enlem, boylam, yükseklik, denize uzaklık ve akarsulara uzaklık girdileri kullanılarak  $\pm 8.27$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 1280931 yöntem numaralı (Çizelge sırası: 22) uygulama ile enlem, boylam, bakı, eğim ve sıcaklık girdileri kullanılarak  $\pm 4.08$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 1698478 yöntem numaralı (Çizelge sırası: 24) uygulama ile enlem, boylam, 4. en yakın komşu, akarsulara uzaklık ve nem girdileri kullanılarak, R eğitim 0.55, R test 0.67 ve  $\pm 11.24$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri nem, basınç, sıcaklık, bakı ve akarsulara uzaklık olup, en az kullanılan değişkenler denize uzaklık, eğim, GPM, en yakın komşu verileri ve yükseklik olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişken, göllere uzaklık değişkeni olmuştur. En düşük test KOH değerine göre sıralanan çizelgede, nöron sayısı ve katman sayısı bakımından en düşük test hatasına sahip 25 uygulamanın 24'ü çift katmanlı sinir ağı yapısı ile gerçekleştirilirken 1'i tek katmanlı olarak gerçekleştirilmiştir. Nöron sayıları 1. ve 2. katman için genellikle 5 ila 20 nöron sayısı aralığında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.10.'da yer alan bilgilere göre 1698478 yöntem numaralı (Çizelge sırası: 24) enlem,

boylam, 4. en yakın komşu, akarsulara uzaklık ve nem girdisi kullanılan uygulama, 5 girdili ve SCG algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 1698478 uygulamasının 1. katman nöron sayısı 9, 2. katman nöron sayısı ise 20'dir.

#### **4.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS) Bulguları**

ANFIS yöntemi ile her uygulama setinde en düşük test KOH hatasına sahip ilk 25 uygulamanın sonuçları, 1 girdili ve hibrit eğitim algoritması kullanılan uygulamalar için Çizelge 4.11. ile, 1 girdili ve GY algoritması kullanılan uygulamalar için Çizelge 4.12. ile, 2 girdili ve hibrit eğitim algoritması kullanılan uygulamalar için Çizelge 4.13. ile, 2 girdili ve GY algoritması kullanılan uygulamalar için Çizelge 4.14. ile, 3 girdili ve hibrit eğitim algoritması kullanılan uygulamalar için Çizelge 4.15. ile, 3 girdili ve GY algoritması kullanılan uygulamalar için Çizelge 4.16. ile, 4 girdili ve hibrit eğitim algoritması kullanılan uygulamalar için Çizelge 4.17. ile, 4 girdili ve GY algoritması kullanılan uygulamalar için Çizelge 4.18. ile, 5 girdili ve hibrit eğitim algoritması kullanılan uygulamalar için Çizelge 4.19. ile ve 5 girdili ve GY algoritması kullanılan uygulamalar için Çizelge 4.20. ile verilmiştir.

Çizelge 4.11. Hibrit eğitim algoritması ve 1 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	11.3	8.5	0.4	0.7	5.1	33.2	7.9	4.6	4.4	20.6	0.0	18.8	9.6	7.0	Lineer	5	Hibrit	Nem	-	-	-	-	16-25H1
2	11.3	8.7	0.3	0.7	3.7	30.7	8.5	4.4	0.3	17.4	3.2	21.8	9.9	8.8	Lineer	3	Hibrit	Nem	-	-	-	-	16-23H1
3	12.2	8.6	0.3	0.6	3.0	33.0	21.0	4.0	5.2	19.1	1.5	20.1	10.2	7.8	Sabit	5	Hibrit	Nem	-	-	-	-	16-15H1
4	12.6	8.7	0.3	0.7	4.4	30.8	33.6	5.0	2.1	17.0	3.6	22.4	9.6	8.6	Lineer	4	Hibrit	Nem	-	-	-	-	16-24H1
5	14.2	8.8	0.2	0.6	4.5	30.3	49.8	6.6	1.4	17.2	3.4	22.0	9.7	8.7	Lineer	2	Hibrit	Nem	-	-	-	-	16-22H1
6	14.5	8.7	0.3	0.3	4.6	29.8	54.3	11.1	4.8	15.9	3.9	19.0	9.6	7.7	Lineer	4	Hibrit	D.U.	-	-	-	-	4-24H1
7	14.6	8.7	0.3	0.3	2.4	26.8	49.5	13.3	1.7	17.8	3.9	22.3	10.9	7.1	Sabit	3	Hibrit	Yük.	-	-	-	-	3-13H1
8	14.8	8.7	0.3	0.3	4.0	30.1	55.8	10.5	4.3	14.3	4.8	20.1	9.7	8.4	Lineer	5	Hibrit	D.U.	-	-	-	-	4-25H1
9	14.8	8.8	0.2	0.3	3.9	29.2	56.1	10.8	4.6	14.6	4.0	20.3	9.7	8.9	Sabit	5	Hibrit	D.U.	-	-	-	-	4-15H1
10	14.8	8.7	0.3	0.2	4.4	29.8	56.2	10.9	4.8	14.8	3.8	20.2	9.7	8.8	Lineer	3	Hibrit	D.U.	-	-	-	-	4-23H1
11	14.9	8.9	0.2	0.3	4.6	30.2	55.7	5.9	0.0	17.4	3.2	21.8	9.8	8.6	Sabit	3	Hibrit	Nem	-	-	-	-	16-13H1
12	14.9	8.8	0.2	0.2	5.0	29.0	56.2	11.0	5.1	14.7	4.0	20.4	9.8	8.9	Sabit	4	Hibrit	D.U.	-	-	-	-	4-14H1
13	15.0	8.8	0.2	0.1	7.7	27.8	53.2	7.1	0.6	21.0	5.4	21.4	10.5	8.5	Lineer	3	Hibrit	Bakı	-	-	-	-	5-23H1
14	15.0	8.6	0.3	0.2	12.4	28.1	54.2	9.7	1.8	14.0	2.6	17.8	10.8	8.8	Lineer	5	Hibrit	K1	-	-	-	-	7-25H1
15	15.0	8.9	0.2	0.3	7.3	28.5	55.4	7.5	3.1	18.2	3.1	20.5	10.3	8.2	Sabit	2	Hibrit	A.U.	-	-	-	-	12-12H1
16	15.0	8.9	0.2	0.2	7.4	28.6	55.3	7.7	3.2	18.1	3.1	20.4	10.4	8.2	Lineer	2	Hibrit	A.U.	-	-	-	-	12-22H1
17	15.1	8.8	0.2	0.2	8.0	28.7	54.6	7.7	0.9	18.0	4.8	21.3	10.5	8.3	Lineer	2	Hibrit	G.U.	-	-	-	-	13-22H1
18	15.1	8.5	0.3	0.2	9.1	26.1	45.4	12.4	6.1	19.9	4.2	22.1	12.1	9.9	Lineer	5	Hibrit	Sıc.	-	-	-	-	15-25H1
19	15.1	8.9	0.2	0.1	9.8	26.7	53.2	10.3	5.1	20.0	3.2	20.7	10.8	8.0	Sabit	2	Hibrit	Sıc.	-	-	-	-	15-12H1
20	15.1	8.8	0.2	0.1	7.5	27.9	54.6	8.2	0.1	18.8	4.7	20.6	10.7	8.3	Sabit	3	Hibrit	G.U.	-	-	-	-	13-13H1
21	15.1	8.8	0.2	0.1	7.8	27.9	54.2	7.8	0.3	18.8	5.0	20.8	10.8	7.9	Lineer	3	Hibrit	G.U.	-	-	-	-	13-23H1
22	15.1	8.7	0.3	0.1	5.3	30.2	56.3	5.1	6.5	14.4	3.4	17.9	10.6	8.7	Sabit	3	Hibrit	K2	-	-	-	-	8-13H1
23	15.1	8.9	0.2	0.1	7.5	28.4	54.9	8.3	0.9	18.3	3.6	20.9	10.6	9.0	Sabit	2	Hibrit	G.U.	-	-	-	-	13-12H1
24	15.1	8.9	0.2	0.1	7.2	27.8	54.7	8.5	0.6	18.8	4.9	20.4	10.7	8.6	Sabit	4	Hibrit	G.U.	-	-	-	-	13-14H1
25	15.2	9.0	0.1	0.1	8.7	29.1	54.8	6.5	0.3	18.5	2.8	22.3	10.4	9.7	Sabit	4	Hibrit	Bakı	-	-	-	-	5-14H1

Çizelge 4.12. GY eğitim algoritması ve 1 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	14.7	8.6	0.3	0.3	4.4	30.2	51.9	10.9	0.0	15.6	5.2	19.8	10.5	9.2	Lineer	5	GY	G.U.	-	-	-	-	13-25G1
2	14.8	8.8	0.2	0.3	3.9	29.3	55.8	10.8	4.6	14.7	3.8	20.2	9.7	8.7	Sabit	5	GY	D.U.	-	-	-	-	4-15G1
3	14.9	9.0	0.1	0.1	6.1	28.6	55.5	10.3	4.4	18.9	3.5	20.6	9.9	7.9	Lineer	2	GY	D.U.	-	-	-	-	4-22G1
4	14.9	8.7	0.3	0.2	5.4	29.3	54.7	4.0	4.6	13.2	2.0	19.0	10.8	8.1	Sabit	3	GY	K2	-	-	-	-	8-13G1
5	14.9	8.8	0.2	0.2	5.2	29.1	56.4	10.8	4.9	14.6	4.2	20.5	9.9	9.1	Sabit	4	GY	D.U.	-	-	-	-	4-14G1
6	15.0	8.7	0.3	0.2	6.0	27.8	54.6	9.9	3.9	15.1	9.2	20.0	10.7	7.1	Sabit	5	GY	K5	-	-	-	-	11-15G1
7	15.0	8.9	0.2	0.3	7.6	28.8	55.3	7.4	3.2	18.0	3.4	20.4	10.2	8.3	Lineer	2	GY	A.U.	-	-	-	-	12-22G1
8	15.0	8.7	0.3	0.2	5.1	30.1	55.3	4.4	4.9	13.7	2.8	18.7	10.7	8.1	Sabit	4	GY	K2	-	-	-	-	8-14G1
9	15.0	9.0	0.1	0.1	9.8	26.6	51.9	10.4	7.0	20.1	3.4	20.9	10.9	8.1	Lineer	2	GY	Sic.	-	-	-	-	15-22G1
10	15.0	8.9	0.2	0.2	7.6	28.8	56.2	8.3	2.4	17.8	2.8	21.2	10.0	8.6	Sabit	5	GY	Bas.	-	-	-	-	17-15G1
11	15.0	8.8	0.2	0.1	7.6	28.0	54.4	8.0	0.3	18.6	4.7	20.8	10.6	8.3	Lineer	3	GY	G.U.	-	-	-	-	13-23G1
12	15.1	8.7	0.3	0.1	5.0	31.6	57.3	4.1	2.4	20.2	0.4	17.8	9.8	8.0	Lineer	5	GY	Nem	-	-	-	-	16-25G1
13	15.1	8.9	0.2	0.2	7.9	28.6	54.6	7.9	0.5	18.0	4.2	21.2	10.5	8.9	Lineer	2	GY	G.U.	-	-	-	-	13-22G1
14	15.1	8.7	0.3	0.1	4.7	30.4	56.7	5.5	5.7	14.8	3.8	17.9	10.5	8.7	Sabit	2	GY	K2	-	-	-	-	8-12G1
15	15.1	8.8	0.2	0.1	7.2	27.9	54.7	8.5	1.1	18.8	5.0	20.5	10.7	8.3	Lineer	4	GY	G.U.	-	-	-	-	13-24G1
16	15.1	9.1	0.2	0.0	7.2	28.4	55.8	8.6	2.8	18.2	2.4	20.8	10.4	8.2	Sabit	5	GY	A.U.	-	-	-	-	12-15G1
17	15.1	8.8	0.3	0.1	5.6	29.8	56.6	6.2	8.7	15.5	3.5	17.3	10.5	8.6	Lineer	2	GY	K2	-	-	-	-	8-22G1
18	15.1	8.9	0.2	0.0	4.7	29.7	57.0	12.2	6.0	17.0	3.6	22.1	9.6	9.4	Sabit	2	GY	D.U.	-	-	-	-	4-12G1
19	15.2	8.5	0.3	0.1	9.5	31.4	54.7	10.5	5.4	8.9	2.6	16.2	11.1	8.7	Sabit	5	GY	K1	-	-	-	-	7-15G1
20	15.2	9.0	0.0	0.2	7.5	28.8	56.1	8.4	2.5	17.8	2.8	21.1	10.3	8.7	Sabit	2	GY	A.U.	-	-	-	-	12-12G1
21	15.2	8.7	0.3	0.2	4.7	30.6	56.5	4.9	4.4	14.2	3.7	19.3	10.5	9.4	Lineer	3	GY	K2	-	-	-	-	8-23G1
22	15.2	8.9	0.2	0.1	9.4	30.6	55.0	8.9	3.3	16.5	3.0	20.1	10.6	8.3	Lineer	3	GY	A.U.	-	-	-	-	12-23G1
23	15.2	9.0	0.2	0.0	7.5	28.7	56.1	8.4	2.5	17.9	2.7	21.1	10.4	8.5	Sabit	2	GY	K4	-	-	-	-	10-12G1
24	15.2	8.9	0.2	0.0	10.0	26.5	53.6	10.5	5.4	20.2	3.8	21.2	10.9	8.4	Lineer	4	GY	Sic.	-	-	-	-	15-24G1
25	15.2	8.8	0.2	0.1	9.4	30.7	55.0	9.1	3.2	16.5	3.3	20.2	10.6	8.5	Lineer	4	GY	A.U.	-	-	-	-	12-24G1

Çizelge 4.13. Hibrit eğitim algoritması ve 2 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	11.1	8.4	0.4	0.7	6.0	32.2	8.7	7.7	6.2	18.4	3.7	21.1	9.0	8.8	Lineer	4	Hibrit	Nem	Bas.	-	-	-	1617-24H2
2	11.4	8.3	0.4	0.7	5.9	29.6	23.8	7.2	8.0	16.0	2.3	23.0	8.9	7.2	Lineer	5	Hibrit	Nem	Bas.	-	-	-	1617-25H2
3	11.5	8.4	0.4	0.7	5.2	30.5	9.1	4.8	4.5	17.4	3.4	22.0	10.1	8.7	Lineer	3	Hibrit	G.U.	Nem	-	-	-	1316-23H2
4	11.9	8.3	0.4	0.6	8.3	30.9	2.1	2.6	1.0	16.3	2.0	21.2	11.1	7.9	Lineer	4	Hibrit	A.U.	Nem	-	-	-	1216-24H2
5	12.0	8.2	0.4	0.6	6.7	32.1	8.8	26.0	7.8	16.7	5.4	13.8	9.5	9.6	Lineer	4	Hibrit	Boy.	Bas.	-	-	-	217-24H2
6	12.3	8.2	0.4	0.6	3.9	33.2	16.6	26.3	6.2	16.0	5.6	13.2	9.5	10.4	Lineer	3	Hibrit	Boy.	Bas.	-	-	-	217-23H2
7	12.3	8.3	0.4	0.6	2.9	32.3	17.3	9.5	3.9	16.9	5.3	24.1	10.5	7.7	Lineer	4	Hibrit	K3	Nem	-	-	-	916-24H2
8	12.8	8.4	0.4	0.6	5.4	30.8	27.8	5.7	6.2	17.7	1.6	19.8	10.9	8.1	Lineer	5	Hibrit	K1	Nem	-	-	-	716-25H2
9	12.9	7.6	0.5	0.5	5.3	24.6	32.9	9.4	9.1	18.9	0.9	18.9	11.2	5.9	Lineer	5	Hibrit	Sic.	Nem	-	-	-	1516-25H2
10	12.9	8.1	0.4	0.6	6.1	24.4	35.4	7.3	6.6	22.5	5.2	21.0	10.4	6.3	Lineer	4	Hibrit	Sic.	Nem	-	-	-	1516-24H2
11	13.0	7.8	0.5	0.5	5.1	30.0	19.8	7.9	5.5	21.7	4.8	27.0	11.3	6.7	Lineer	3	Hibrit	En.	Nem	-	-	-	116-23H2
12	13.0	8.3	0.4	0.6	8.9	29.3	33.4	4.0	2.6	16.9	1.9	21.5	10.7	7.8	Lineer	5	Hibrit	A.U.	Nem	-	-	-	1216-25H2
13	13.1	7.5	0.6	0.5	5.8	27.9	21.5	9.7	12.6	24.0	5.5	28.8	10.7	5.4	Lineer	5	Hibrit	Sic.	Bas.	-	-	-	1517-25H2
14	13.1	8.5	0.4	0.5	4.6	25.4	32.2	8.9	1.4	15.2	6.2	23.2	11.3	9.0	Lineer	5	Hibrit	K3	Bas.	-	-	-	917-25H2
15	13.1	8.1	0.4	0.6	5.7	26.3	37.1	7.1	9.0	22.2	4.2	20.6	10.3	6.5	Lineer	3	Hibrit	Sic.	Nem	-	-	-	1516-23H2
16	13.3	8.1	0.4	0.5	2.1	33.6	3.2	22.7	5.3	20.5	6.9	20.6	11.8	7.7	Lineer	5	Hibrit	K4	Nem	-	-	-	1016-25H2
17	13.4	8.6	0.3	0.6	5.9	32.9	39.7	1.5	4.9	15.4	4.0	21.5	9.8	9.3	Lineer	3	Hibrit	A.U.	Nem	-	-	-	1216-23H2
18	13.4	8.1	0.4	0.5	2.6	32.5	25.0	4.0	12.4	15.8	3.8	24.4	11.5	9.5	Lineer	5	Hibrit	G.U.	Nem	-	-	-	1316-25H2
19	13.4	7.6	0.5	0.4	4.8	30.2	21.4	8.6	1.4	21.9	6.0	26.9	11.8	6.8	Lineer	4	Hibrit	En.	Nem	-	-	-	116-24H2
20	13.5	8.6	0.3	0.6	4.3	31.0	40.2	6.7	0.9	16.8	4.3	22.7	9.8	10.1	Sabit	4	Hibrit	G.U.	Nem	-	-	-	1316-14H2
21	13.5	8.3	0.4	0.6	4.2	32.4	41.5	4.9	1.4	12.0	9.0	23.9	10.0	7.0	Lineer	3	Hibrit	K5	Nem	-	-	-	1116-23H2
22	13.5	7.6	0.5	0.4	5.2	27.6	39.7	22.0	7.1	13.8	1.3	18.6	10.4	6.8	Lineer	5	Hibrit	Boy.	Nem	-	-	-	216-25H2
23	13.5	8.1	0.5	0.5	3.0	26.6	41.8	9.0	3.3	21.0	5.0	26.3	9.7	8.0	Lineer	3	Hibrit	GPM	Nem	-	-	-	1416-23H2
24	13.7	8.5	0.3	0.4	4.9	31.9	49.0	7.4	1.9	14.8	2.4	20.6	8.9	8.4	Lineer	5	Hibrit	D.U.	Nem	-	-	-	416-25H2
25	13.7	8.1	0.4	0.4	1.2	33.1	44.6	1.7	17.1	12.3	1.8	20.3	9.5	7.8	Lineer	4	Hibrit	K2	Nem	-	-	-	816-24H2

Çizelge 4.14. GY eğitim algoritması ve 2 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	14.3	8.6	0.3	0.2	8.4	28.0	47.6	17.6	4.9	18.9	3.5	14.5	10.6	7.0	Linear	3	GY	Boy.	Sic.	-	-	-	215-23G2
2	14.3	8.6	0.3	0.3	8.0	28.2	48.8	16.1	6.3	18.6	3.8	15.6	10.4	7.5	Linear	4	GY	Boy.	Sic.	-	-	-	215-24G2
3	14.6	8.6	0.3	0.3	8.0	30.4	50.0	15.7	4.3	16.5	4.8	15.4	10.4	8.4	Linear	2	GY	Boy.	Sic.	-	-	-	215-22G2
4	14.6	8.5	0.3	0.3	8.9	30.7	49.1	16.6	3.9	16.2	5.3	16.2	10.6	8.6	Linear	5	GY	Boy.	Sic.	-	-	-	215-25G2
5	14.7	8.9	0.2	0.3	6.0	28.5	54.6	9.3	5.1	19.2	4.0	19.7	9.7	7.6	Linear	2	GY	D.U.	A.U.	-	-	-	412-22G2
6	14.7	8.9	0.2	0.2	9.6	27.7	48.5	7.7	5.0	20.0	3.5	22.2	10.8	9.4	Linear	4	GY	Bakı	Sic.	-	-	-	515-24G2
7	14.7	10.9	-0.1	0.4	7.4	28.6	56.0	4.0	2.6	18.0	2.6	21.1	9.5	8.4	Sabit	5	GY	Eğim	Sic.	-	-	-	615-15G2
8	14.7	8.8	0.2	0.1	8.5	27.6	52.8	14.1	5.1	18.0	3.4	21.6	10.0	8.8	Linear	4	GY	D.U.	Sic.	-	-	-	415-24G2
9	14.8	8.7	0.3	0.2	6.4	28.4	52.3	7.2	10.9	16.6	4.0	17.5	10.8	8.1	Linear	2	GY	K2	Sic.	-	-	-	815-22G2
10	14.8	8.9	0.2	0.1	6.0	28.1	54.2	10.2	2.8	19.4	4.1	20.3	10.1	8.3	Linear	2	GY	D.U.	G.U.	-	-	-	413-22G2
11	14.8	8.7	0.3	0.2	5.4	32.4	57.0	8.9	1.3	14.7	4.7	15.9	9.5	9.0	Linear	2	GY	Boy.	A.U.	-	-	-	212-22G2
12	14.8	8.8	0.3	0.1	4.6	29.3	55.8	7.9	9.5	16.7	3.5	17.0	10.1	7.9	Linear	2	GY	D.U.	K2	-	-	-	48-22G2
13	14.8	8.5	0.3	0.2	8.2	26.2	44.9	2.9	3.4	20.0	5.7	20.6	11.7	13.1	Linear	5	GY	Bakı	Sic.	-	-	-	515-25G2
14	14.9	8.9	0.2	0.1	6.2	28.9	55.3	9.6	5.4	18.7	3.3	20.4	9.9	8.3	Linear	4	GY	D.U.	A.U.	-	-	-	412-24G2
15	14.9	8.3	0.4	0.1	6.5	26.3	56.2	7.5	4.9	20.2	4.5	18.7	10.2	6.9	Sabit	4	GY	K2	GPM	-	-	-	814-14G2
16	14.9	8.8	0.2	0.2	10.0	26.3	50.7	10.1	4.9	20.4	4.2	20.8	11.0	8.6	Linear	3	GY	G.U.	Sic.	-	-	-	1315-23G2
17	14.9	8.9	0.2	0.0	7.7	27.1	51.8	11.9	8.5	20.6	2.2	21.2	10.5	8.4	Linear	5	GY	D.U.	Sic.	-	-	-	415-25G2
18	14.9	8.7	0.3	0.1	10.9	24.8	50.3	11.2	2.3	21.9	5.3	20.7	11.0	8.4	Linear	4	GY	G.U.	Sic.	-	-	-	1315-24G2
19	14.9	8.9	0.2	0.1	8.5	29.9	51.5	7.0	2.2	18.1	4.6	21.4	10.6	9.2	Linear	3	GY	Bakı	A.U.	-	-	-	512-23G2
20	14.9	9.0	0.1	0.1	7.9	27.5	53.0	10.8	7.5	19.6	3.5	20.9	10.4	8.0	Linear	2	GY	D.U.	Sic.	-	-	-	415-22G2
21	14.9	8.8	0.2	0.2	8.4	27.4	52.7	9.2	3.9	19.2	3.6	20.8	10.6	8.5	Linear	2	GY	G.U.	Sic.	-	-	-	1315-22G2
22	14.9	8.3	0.4	0.3	3.0	33.7	54.1	1.2	0.9	15.3	4.0	20.6	10.0	9.6	Linear	5	GY	K2	Nem	-	-	-	816-25G2
23	14.9	8.9	0.2	0.0	5.8	28.8	55.3	9.6	5.4	18.9	2.6	20.5	10.0	8.4	Linear	3	GY	D.U.	A.U.	-	-	-	412-23G2
24	14.9	8.8	0.2	0.2	8.8	29.9	51.9	6.1	2.2	18.4	4.6	21.6	10.5	9.3	Linear	5	GY	Bakı	A.U.	-	-	-	512-25G2
25	14.9	8.8	0.3	0.2	8.6	31.0	54.9	6.3	6.1	16.4	5.0	20.9	9.8	9.6	Sabit	2	GY	D.U.	A.U.	-	-	-	412-12G2

Çizelge 4.15. Hibrit eğitim algoritması ve 3 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	11.5	7.6	0.5	0.7	8.8	34.7	9.3	19.1	7.2	15.5	7.4	12.6	9.0	10.0	Linear	4	Hibrit	Boy.	Nem	Bas.	-	-	21617-24H3
2	11.6	8.2	0.4	0.6	1.8	35.9	20.1	9.7	5.3	10.0	3.8	16.7	9.1	10.8	Linear	3	Hibrit	Boy.	D.U.	Nem	-	-	2416-23H3
3	12.2	6.9	0.6	0.6	4.9	31.1	13.1	11.2	5.0	11.0	5.5	24.6	11.0	6.2	Linear	4	Hibrit	En.	Sıc.	Nem	-	-	11516-24H3
4	12.3	7.9	0.5	0.6	3.3	28.6	20.0	7.3	2.3	13.0	4.7	27.3	10.7	9.3	Linear	4	Hibrit	Eğim	K3	Nem	-	-	6916-24H3
5	12.4	7.6	0.5	0.6	3.3	30.8	12.6	7.2	1.5	19.3	4.2	27.7	10.9	4.9	Linear	3	Hibrit	En.	GPM	Nem	-	-	11416-23H3
6	12.5	7.7	0.5	0.6	4.2	24.2	29.5	12.6	11.7	18.2	6.2	21.1	10.4	6.2	Linear	4	Hibrit	K3	Sıc.	Nem	-	-	91516-24H3
7	12.5	8.2	0.4	0.6	5.4	30.4	28.0	5.1	1.0	16.5	1.8	19.2	10.7	7.5	Linear	4	Hibrit	K1	A.U.	Nem	-	-	71216-24H3
8	12.5	7.0	0.6	0.6	7.3	39.9	23.1	17.0	7.2	14.3	3.4	0.9	10.1	6.7	Linear	5	Hibrit	Boy.	K2	Bas.	-	-	2817-25H3
9	12.6	7.9	0.5	0.6	6.6	29.7	40.2	8.6	6.1	12.8	2.2	20.5	8.4	10.3	Linear	5	Hibrit	D.U.	Nem	Bas.	-	-	41617-25H3
10	12.6	8.0	0.5	0.5	8.5	28.2	19.3	7.7	6.3	16.8	0.1	23.2	11.5	7.2	Linear	4	Hibrit	A.U.	G.U.	Nem	-	-	121316-24H3
11	12.7	7.0	0.6	0.5	5.1	33.8	15.0	17.3	3.3	15.2	5.9	21.1	11.0	7.3	Linear	3	Hibrit	Boy.	Sıc.	Nem	-	-	21516-23H3
12	12.7	7.9	0.5	0.6	6.3	27.7	28.1	5.6	3.6	21.2	1.1	16.5	11.0	9.5	Linear	5	Hibrit	K1	G.U.	Nem	-	-	71316-25H3
13	12.8	8.2	0.4	0.5	4.5	32.8	18.2	11.8	3.1	18.1	5.6	24.9	10.5	10.6	Linear	4	Hibrit	K3	Nem	Bas.	-	-	91617-24H3
14	12.8	8.1	0.4	0.6	2.2	27.0	34.0	10.6	2.3	18.7	5.3	21.8	10.3	6.3	Linear	3	Hibrit	K3	Sıc.	Nem	-	-	91516-23H3
15	12.8	7.9	0.5	0.6	14.8	28.2	10.0	14.3	20.2	16.6	6.4	22.4	10.9	8.2	Linear	5	Hibrit	K3	A.U.	Bas.	-	-	91217-25H3
16	12.8	7.7	0.5	0.6	8.3	26.6	36.1	11.2	14.3	18.8	4.7	16.6	9.3	10.9	Sabit	5	Hibrit	Boy.	G.U.	Sıc.	-	-	21315-15H3
17	12.9	7.9	0.5	0.5	8.8	29.2	28.5	5.5	5.6	18.3	1.5	20.4	11.3	7.0	Linear	5	Hibrit	K1	A.U.	Nem	-	-	71216-25H3
18	13.0	7.7	0.5	0.6	13.3	35.5	33.5	4.8	2.1	11.3	0.0	16.5	10.3	8.6	Linear	4	Hibrit	K2	A.U.	Nem	-	-	81216-24H3
19	13.0	8.5	0.3	0.6	10.5	32.9	35.0	3.9	6.3	17.3	2.5	21.1	9.6	9.5	Linear	4	Hibrit	A.U.	Nem	Bas.	-	-	121617-24H3
20	13.1	7.9	0.5	0.5	2.7	26.5	38.6	9.6	2.1	17.4	5.5	25.9	9.7	8.0	Linear	4	Hibrit	D.U.	GPM	Nem	-	-	41416-24H3
21	13.1	7.4	0.6	0.5	7.0	37.4	34.2	7.1	3.0	13.6	4.0	13.6	10.6	4.2	Linear	4	Hibrit	Boy.	K2	Bas.	-	-	2817-24H3
22	13.1	7.3	0.6	0.5	10.5	39.8	26.9	0.4	4.0	15.6	3.6	19.1	10.6	6.4	Linear	4	Hibrit	K2	K4	Nem	-	-	81016-24H3
23	13.1	6.9	0.6	0.5	3.7	37.0	2.5	7.4	1.3	14.5	6.1	28.2	11.8	6.5	Linear	5	Hibrit	En.	Nem	Bas.	-	-	11617-25H3
24	13.2	8.3	0.4	0.5	8.4	26.6	42.3	4.5	5.1	14.5	0.9	21.9	10.0	6.9	Linear	4	Hibrit	K1	Nem	Bas.	-	-	71617-24H3
25	13.2	8.0	0.5	0.5	5.8	34.1	27.5	15.7	0.2	14.5	6.3	23.3	10.5	9.4	Linear	5	Hibrit	K3	Nem	Bas.	-	-	91617-25H3



Çizelge 4.16. GY eğitim algoritması ve 3 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	14.0	8.6	0.4	0.3	6.0	28.2	46.7	16.9	5.3	18.8	3.9	13.7	10.4	6.7	Lineer	2	GY	Boy.	G.U.	Sic.	-	-	21315-22G3
2	14.2	8.4	0.4	0.3	7.9	31.4	48.7	14.8	5.0	15.9	6.1	14.0	10.0	8.6	Lineer	4	GY	Boy.	A.U.	Sic.	-	-	21215-24G3
3	14.3	8.4	0.4	0.3	5.4	30.4	49.9	13.4	10.9	15.3	4.6	12.2	10.2	7.3	Lineer	2	GY	Boy.	K2	Sic.	-	-	2815-22G3
4	14.3	8.4	0.4	0.3	7.1	31.0	50.0	14.0	4.2	16.1	5.3	14.4	10.0	8.2	Lineer	2	GY	Boy.	A.U.	Sic.	-	-	21215-22G3
5	14.3	8.6	0.3	0.3	8.4	30.4	45.9	14.1	5.5	16.8	5.2	16.2	10.7	9.0	Lineer	4	GY	Boy.	Bakı	Sic.	-	-	2515-24G3
6	14.3	8.4	0.4	0.3	7.0	31.1	49.8	15.7	3.5	16.1	5.2	13.1	10.1	8.1	Lineer	3	GY	Boy.	A.U.	Sic.	-	-	21215-23G3
7	14.3	8.4	0.4	0.3	8.8	29.2	46.3	16.3	2.3	17.9	6.1	15.2	10.7	8.1	Lineer	5	GY	Boy.	G.U.	Sic.	-	-	21315-25G3
8	14.3	8.4	0.4	0.3	9.0	29.5	47.2	15.9	3.9	17.5	6.1	15.6	10.5	8.1	Lineer	4	GY	Boy.	G.U.	Sic.	-	-	21315-24G3
9	14.3	8.3	0.4	0.4	5.4	35.2	51.2	10.6	2.4	14.7	5.7	16.4	9.1	10.3	Lineer	4	GY	Boy.	A.U.	Nem	-	-	21216-24G3
10	14.4	8.6	0.3	0.2	6.0	29.6	49.3	17.5	6.1	17.5	3.2	15.3	10.2	7.8	Lineer	4	GY	Boy.	D.U.	Sic.	-	-	2415-24G3
11	14.4	8.7	0.3	0.2	6.0	30.9	47.6	19.1	5.7	17.2	4.9	16.7	10.3	7.4	Lineer	2	GY	Boy.	K5	Sic.	-	-	21115-22G3
12	14.4	8.6	0.3	0.2	8.0	30.2	45.8	15.7	6.2	18.2	5.2	15.9	10.8	8.2	Lineer	3	GY	Boy.	Bakı	Sic.	-	-	2515-23G3
13	14.4	8.6	0.3	0.2	8.1	30.2	45.5	15.8	5.9	18.2	5.0	15.9	10.9	8.2	Lineer	2	GY	Boy.	Bakı	Sic.	-	-	2515-22G3
14	14.4	8.6	0.3	0.3	7.3	30.1	49.4	15.0	6.5	17.0	3.2	15.1	10.5	7.6	Lineer	3	GY	Boy.	K1	Sic.	-	-	2715-23G3
15	14.4	8.4	0.4	0.3	9.1	29.8	47.9	15.8	2.2	17.2	5.5	15.4	10.6	8.3	Lineer	3	GY	Boy.	G.U.	Sic.	-	-	21315-23G3
16	14.5	8.6	0.3	0.2	7.3	30.6	49.7	16.3	6.0	18.2	1.4	13.3	10.4	7.0	Lineer	2	GY	Boy.	K1	Sic.	-	-	2715-22G3
17	14.5	8.8	0.3	0.3	9.0	27.9	48.9	6.5	2.8	18.9	3.2	21.8	10.4	9.6	Lineer	4	GY	Bakı	A.U.	Sic.	-	-	51215-24G3
18	14.5	8.3	0.4	0.2	3.7	27.8	50.6	17.1	10.0	19.1	5.7	12.6	10.6	5.2	Lineer	4	GY	Boy.	K2	Sic.	-	-	2815-24G3
19	14.5	8.6	0.3	0.2	7.6	29.9	50.0	15.6	5.8	16.8	4.2	15.7	10.4	8.2	Lineer	2	GY	Boy.	D.U.	Sic.	-	-	2415-22G3
20	14.5	8.7	0.3	0.3	4.6	30.2	55.1	10.8	0.3	16.6	3.3	16.4	9.6	7.7	Lineer	2	GY	Boy.	Yük.	A.U.	-	-	2312-22G3
21	14.5	8.6	0.3	0.2	7.7	30.4	50.1	15.2	5.6	17.1	2.6	15.0	10.5	7.3	Lineer	5	GY	Boy.	K1	Sic.	-	-	2715-25G3
22	14.5	8.4	0.4	0.2	4.8	31.2	51.7	12.7	8.9	14.6	4.0	13.9	10.3	7.8	Lineer	3	GY	Boy.	K2	Sic.	-	-	2815-23G3
23	14.5	8.4	0.4	0.3	7.7	29.8	53.7	10.0	4.1	13.1	4.2	22.1	9.4	9.5	Lineer	4	GY	D.U.	K3	Nem	-	-	4916-24G3
24	14.6	8.7	0.3	0.2	7.3	29.7	49.6	15.9	6.1	17.1	2.8	15.9	10.5	8.2	Lineer	3	GY	Boy.	D.U.	Sic.	-	-	2415-23G3
25	14.6	8.5	0.3	0.2	7.5	30.3	51.8	13.9	4.0	17.3	1.3	15.3	10.3	6.9	Lineer	4	GY	Boy.	K1	Sic.	-	-	2715-24G3

Çizelge 4.17. Hibrit eğitim algoritması ve 4 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	12.5	7.2	0.6	0.5	0.9	33.5	24.4	6.8	2.2	16.2	5.0	16.8	10.9	8.3	Linear	3	Hibrit	En.	Boy.	D.U.	Nem	-	12416-23H4
2	12.8	6.7	0.7	0.5	2.5	32.2	19.1	7.3	3.4	18.9	4.0	20.9	11.7	4.5	Linear	3	Hibrit	En.	Boy.	GPM	Bas.	-	121417-23H4
3	13.0	7.3	0.6	0.5	5.7	32.2	30.1	13.2	14.0	18.3	6.7	18.3	10.4	5.3	Linear	2	Hibrit	En.	Boy.	Sic.	Nem	-	121516-22H4
4	13.2	6.5	0.7	0.5	6.5	33.9	26.6	14.8	2.6	16.1	7.2	19.0	11.5	4.6	Linear	3	Hibrit	En.	Boy.	Sic.	Nem	-	121516-23H4
5	13.4	7.5	0.6	0.4	3.0	29.5	33.3	15.0	1.0	19.4	5.0	19.6	11.3	4.3	Linear	3	Hibrit	En.	Boy.	GPM	Nem	-	121416-23H4
6	13.5	7.5	0.6	0.4	1.6	35.2	21.8	1.3	5.3	14.3	0.2	18.0	12.8	6.0	Linear	4	Hibrit	En.	Boy.	K2	Nem	-	12816-24H4
7	13.5	6.8	0.7	0.4	4.5	34.5	25.1	15.6	1.7	16.8	8.4	20.5	11.7	6.3	Linear	3	Hibrit	En.	Boy.	Nem	Bas.	-	121617-23H4
8	13.6	6.9	0.7	0.4	5.4	33.3	33.3	12.7	4.0	17.5	7.8	19.3	11.2	6.3	Linear	2	Hibrit	En.	Boy.	Nem	Bas.	-	121617-22H4
9	13.8	6.9	0.6	0.4	7.0	32.7	38.8	11.4	9.6	16.9	9.2	16.9	10.9	6.1	Sabit	4	Hibrit	En.	Boy.	Nem	Bas.	-	121617-14H4
10	14.0	6.9	0.6	0.4	1.6	34.0	33.0	7.7	9.3	19.0	5.8	12.9	12.5	2.4	Linear	5	Hibrit	En.	Boy.	K2	Nem	-	12816-25H4
11	14.0	7.3	0.6	0.4	8.1	34.6	17.7	9.2	13.0	18.1	5.4	26.4	12.5	6.4	Linear	5	Hibrit	En.	Boy.	K1	Nem	-	12716-25H4
12	14.1	7.6	0.5	0.4	4.9	34.0	29.1	8.4	17.9	15.0	6.5	22.2	12.1	6.1	Linear	4	Hibrit	En.	Boy.	K1	Nem	-	12716-24H4
13	14.2	7.2	0.6	0.4	5.6	38.1	33.5	9.6	1.1	15.0	10.0	21.7	11.4	8.5	Linear	2	Hibrit	En.	Boy.	A.U.	Nem	-	121216-22H4
14	14.3	7.2	0.6	0.4	4.8	38.3	40.8	0.2	6.0	15.4	11.4	18.6	10.6	9.1	Sabit	4	Hibrit	En.	Boy.	A.U.	Nem	-	121216-14H4
15	14.4	7.2	0.6	0.3	4.5	33.2	40.5	9.4	0.6	17.7	4.7	18.7	11.8	7.1	Linear	5	Hibrit	En.	Boy.	D.U.	Nem	-	12416-25H4
16	14.4	6.9	0.6	0.4	0.2	31.2	13.3	4.2	9.6	8.2	6.9	18.6	14.9	9.3	Linear	4	Hibrit	En.	Boy.	Bakı	Bas.	-	12517-24H4
17	14.4	8.6	0.3	0.3	7.9	28.9	50.1	4.5	2.3	16.6	2.3	21.3	10.1	10.3	Sabit	4	Hibrit	En.	Boy.	Bakı	Sic.	-	12515-14H4
18	14.5	6.7	0.7	0.3	8.5	33.5	38.7	13.6	6.3	14.9	7.6	25.0	11.7	5.3	Linear	4	Hibrit	En.	Boy.	Nem	Bas.	-	121617-24H4
19	14.6	6.8	0.7	0.4	3.9	38.0	45.8	8.7	10.1	13.8	13.0	16.7	10.4	7.6	Sabit	4	Hibrit	En.	Boy.	A.U.	Sic.	-	121215-14H4
20	14.6	7.7	0.5	0.3	5.8	29.3	43.6	15.5	8.2	19.3	4.1	23.4	11.3	6.4	Linear	3	Hibrit	En.	Boy.	Yük.	Nem	-	12316-23H4
21	14.7	8.8	0.3	0.2	2.8	33.8	54.1	9.2	1.4	17.1	2.5	19.6	9.4	7.6	Sabit	5	Hibrit	En.	Boy.	D.U.	Nem	-	12416-15H4
22	14.7	7.9	0.5	0.2	2.2	32.6	51.8	9.7	6.0	17.7	6.7	21.2	10.1	6.0	Sabit	2	Hibrit	En.	Boy.	A.U.	Nem	-	121216-12H4
23	14.7	7.2	0.6	0.2	5.1	30.3	50.0	23.6	9.6	18.5	5.8	16.1	10.0	5.6	Linear	4	Hibrit	En.	Boy.	D.U.	Bas.	-	12417-24H4
24	14.8	7.6	0.5	0.2	2.7	30.3	51.1	7.7	7.5	19.1	3.8	17.2	11.1	4.7	Sabit	3	Hibrit	En.	Boy.	K2	Nem	-	12816-13H4
25	14.8	8.1	0.4	0.2	5.5	28.7	49.8	3.1	7.5	20.7	1.2	22.9	10.7	9.5	Sabit	5	Hibrit	En.	Boy.	Bakı	Sic.	-	12515-15H4

Çizelge 4.18. GY eğitim algoritması ve 4 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	14.5	7.9	0.5	0.2	5.0	26.2	53.6	10.8	5.0	20.3	2.5	19.0	10.0	6.1	Sabit	4	GY	En.	Boy.	Sic.	Bas.	-	121517-14G4
2	14.8	7.7	0.5	0.1	3.7	29.7	54.0	9.1	1.6	16.7	4.5	18.2	10.5	6.7	Lineer	4	GY	En.	Boy.	D.U.	Bas.	-	12417-24G4
3	14.8	9.2	0.0	0.3	7.3	28.5	55.9	8.6	2.7	18.0	12.9	20.9	9.4	8.3	Sabit	3	GY	En.	Boy.	G.U.	GPM	-	121314-13G4
4	14.9	8.7	0.3	0.2	6.6	27.4	54.8	9.7	3.8	19.2	4.0	20.1	10.3	7.3	Sabit	3	GY	En.	Boy.	Yük.	K3	-	1239-13G4
5	14.9	7.9	0.5	0.2	4.7	30.2	51.9	6.8	8.0	18.3	5.5	15.0	11.3	5.2	Lineer	5	GY	En.	Boy.	K2	Sic.	-	12815-25G4
6	14.9	8.2	0.4	0.2	4.9	30.1	51.5	7.8	5.0	17.3	4.4	18.4	11.2	7.3	Lineer	4	GY	En.	Boy.	Bakı	Sic.	-	12515-24G4
7	14.9	8.2	0.4	0.2	4.7	31.0	54.2	9.3	3.8	17.1	4.8	17.4	10.6	6.8	Lineer	2	GY	En.	Boy.	A.U.	Sic.	-	121215-22G4
8	14.9	8.1	0.4	0.2	4.4	31.7	53.3	7.5	5.3	17.4	6.3	17.4	10.7	6.4	Lineer	4	GY	En.	Boy.	A.U.	Sic.	-	121215-24G4
9	14.9	8.2	0.4	0.1	4.4	29.7	53.4	10.0	5.9	18.4	2.7	18.1	10.9	5.3	Lineer	3	GY	En.	Boy.	K1	Sic.	-	12715-23G4
10	14.9	8.0	0.5	0.2	4.3	30.1	51.7	9.0	3.9	18.3	7.1	21.1	10.9	6.1	Lineer	2	GY	En.	Boy.	G.U.	Nem	-	121316-22G4
11	15.0	8.2	0.4	0.1	2.3	30.7	53.9	8.0	9.1	16.3	3.8	15.1	11.0	6.1	Lineer	3	GY	En.	Boy.	K2	Sic.	-	12815-23G4
12	15.0	8.0	0.5	0.1	4.2	31.7	51.6	9.4	3.2	18.1	5.4	18.8	11.0	6.8	Lineer	3	GY	En.	Boy.	G.U.	Nem	-	121316-23G4
13	15.0	8.0	0.5	0.2	5.5	33.4	54.1	5.5	5.1	16.6	7.9	17.1	10.4	7.0	Lineer	5	GY	En.	Boy.	A.U.	Sic.	-	121215-25G4
14	15.0	8.1	0.4	0.1	3.7	30.7	54.2	8.4	8.4	16.5	4.8	16.2	10.8	6.4	Lineer	2	GY	En.	Boy.	K2	Sic.	-	12815-22G4
15	15.0	8.3	0.4	0.1	3.9	30.0	53.6	10.0	5.7	18.9	2.9	17.1	10.9	5.5	Lineer	2	GY	En.	Boy.	K1	Sic.	-	12715-22G4
16	15.0	8.0	0.5	0.1	5.4	29.9	52.7	10.6	1.9	18.0	6.0	19.9	10.9	6.7	Lineer	2	GY	En.	Boy.	G.U.	Bas.	-	121317-22G4
17	15.0	8.7	0.3	0.2	7.4	27.9	55.2	9.3	3.4	18.7	4.7	20.5	10.3	7.9	Sabit	3	GY	En.	Boy.	Yük.	K4	-	12310-13G4
18	15.0	8.9	0.2	0.0	6.8	28.0	55.4	9.1	3.2	18.6	2.0	20.4	10.4	7.8	Sabit	5	GY	En.	Boy.	Eğim	Bas.	-	12617-15G4
19	15.0	8.2	0.4	0.1	4.6	30.1	51.2	9.5	5.4	18.7	4.4	18.4	11.3	6.2	Lineer	2	GY	En.	Boy.	Bakı	Sic.	-	12515-22G4
20	15.0	8.3	0.4	0.1	4.9	30.5	50.5	9.3	6.0	19.1	5.0	18.6	11.3	6.6	Lineer	3	GY	En.	Boy.	Bakı	Sic.	-	12515-23G4
21	15.0	9.3	0.0	-0.1	6.7	28.0	55.3	9.2	3.2	18.6	2.0	20.4	10.4	8.1	Sabit	4	GY	En.	Boy.	A.U.	Bas.	-	121217-14G4
22	15.0	8.1	0.4	0.1	2.8	28.6	52.6	12.3	6.7	18.4	5.7	16.5	11.3	5.1	Lineer	5	GY	En.	Boy.	Yük.	Bas.	-	12317-25G4
23	15.0	8.1	0.4	0.1	3.4	30.9	54.8	7.7	8.1	16.1	4.9	16.1	10.8	6.6	Lineer	2	GY	En.	Boy.	K2	Bas.	-	12817-22G4
24	15.0	8.2	0.4	0.1	4.4	30.1	52.5	8.3	3.8	17.3	4.5	18.3	11.3	6.9	Lineer	3	GY	En.	Boy.	Bakı	Bas.	-	12517-23G4
25	15.0	8.2	0.4	0.1	3.1	29.8	54.6	10.2	6.5	18.7	4.0	18.3	10.7	5.8	Lineer	2	GY	En.	Boy.	D.U.	Sic.	-	12415-22G4

Çizelge 4.19. Hibrit eğitim algoritması ve 5 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	11.9	6.6	0.7	0.6	8.5	34.0	15.0	9.2	5.8	15.8	10.1	12.4	10.4	6.5	Lineer	2	Hibrit	En.	Boy.	A.U.	Sic.	Nem	12121516-22H5
2	12.3	7.0	0.6	0.5	3.4	32.2	22.0	6.3	4.7	13.8	5.4	18.7	11.1	6.3	Lineer	3	Hibrit	En.	Boy.	D.U.	GPM	Nem	1241416-23H5
3	12.5	7.4	0.6	0.5	4.4	29.1	25.6	16.0	1.8	19.8	5.6	15.1	11.0	3.9	Lineer	3	Hibrit	En.	Boy.	G.U.	GPM	Nem	12131416-23H5
4	12.7	5.9	0.8	0.6	12.5	31.8	15.6	7.0	1.8	7.8	3.9	16.8	12.4	4.4	Lineer	5	Hibrit	En.	Boy.	A.U.	Nem	Bas.	12121617-25H5
5	12.7	6.6	0.7	0.5	7.5	36.3	24.1	9.6	4.0	14.4	10.5	14.7	10.6	8.2	Lineer	2	Hibrit	En.	Boy.	A.U.	Nem	Bas.	12121617-22H5
6	12.7	7.6	0.5	0.5	6.0	32.4	23.2	8.5	10.1	15.6	5.5	17.9	11.3	5.8	Lineer	3	Hibrit	En.	Boy.	A.U.	G.U.	Nem	12121316-23H5
7	12.8	7.3	0.6	0.5	3.4	36.3	19.7	6.4	3.4	17.0	7.2	19.9	11.0	7.2	Lineer	3	Hibrit	En.	Boy.	D.U.	A.U.	Nem	1241216-23H5
8	12.8	7.2	0.6	0.5	2.0	35.0	23.7	6.5	0.8	18.5	5.2	19.3	11.1	5.4	Lineer	3	Hibrit	En.	Boy.	D.U.	K2	Nem	124816-23H5
9	13.1	7.1	0.6	0.5	6.3	35.9	32.3	13.2	10.1	16.4	9.6	16.8	9.9	7.3	Lineer	3	Hibrit	En.	Boy.	A.U.	Nem	Bas.	12121617-23H5
10	13.1	7.0	0.6	0.5	2.4	34.5	24.0	18.8	5.4	17.3	8.8	17.5	11.2	4.1	Lineer	4	Hibrit	En.	Boy.	K3	A.U.	Sic.	1291215-24H5
11	13.2	7.1	0.6	0.5	6.3	32.6	31.0	5.0	3.7	17.1	5.8	14.4	11.3	8.4	Lineer	3	Hibrit	En.	Boy.	D.U.	Nem	Bas.	1241617-23H5
12	13.2	7.3	0.6	0.4	5.3	32.0	33.0	13.4	2.6	20.5	5.3	19.1	10.6	4.1	Lineer	3	Hibrit	En.	Boy.	G.U.	GPM	Bas.	12131417-23H5
13	13.2	7.2	0.6	0.4	1.1	33.5	31.0	8.5	1.6	15.9	4.9	20.3	11.1	7.8	Lineer	3	Hibrit	En.	Boy.	D.U.	K3	Nem	124916-23H5
14	13.3	6.7	0.7	0.5	13.3	30.4	15.8	13.6	1.3	15.4	1.1	22.8	12.5	3.6	Lineer	3	Hibrit	En.	Boy.	K1	GPM	Nem	1271416-23H5
15	13.3	6.8	0.7	0.6	11.4	33.5	13.4	7.3	16.4	11.9	5.9	18.4	12.3	8.5	Lineer	4	Hibrit	En.	Boy.	K1	K2	Nem	127816-24H5
16	13.4	7.3	0.6	0.4	4.5	36.0	29.2	9.5	5.3	15.3	10.5	17.6	11.3	4.6	Sabit	5	Hibrit	En.	Boy.	A.U.	GPM	Sic.	12121415-15H5
17	13.4	6.9	0.7	0.4	4.1	23.0	25.8	0.8	6.2	19.5	3.9	15.7	13.3	5.6	Lineer	4	Hibrit	En.	Boy.	Yük.	K4	Nem	1231016-24H5
18	13.4	6.8	0.7	0.5	5.1	33.8	18.9	17.5	21.4	11.3	8.6	22.6	11.3	5.0	Lineer	5	Hibrit	En.	Boy.	K1	A.U.	Sic.	1271215-25H5
19	13.5	6.9	0.6	0.4	5.5	32.2	31.2	12.1	4.9	18.9	8.6	18.7	11.4	5.1	Lineer	2	Hibrit	En.	Boy.	G.U.	Nem	Bas.	12131617-22H5
20	13.5	6.9	0.7	0.5	10.8	32.0	22.4	17.9	4.7	19.3	3.0	14.5	12.2	5.5	Lineer	5	Hibrit	En.	Boy.	GPM	Sic.	Nem	12141516-25H5
21	13.5	6.8	0.7	0.4	5.6	33.3	29.1	8.4	4.2	18.1	8.4	20.8	11.6	5.2	Lineer	2	Hibrit	En.	Boy.	Sic.	Nem	Bas.	12151617-22H5
22	13.5	7.3	0.6	0.4	5.0	31.4	44.1	12.1	2.4	21.8	7.0	10.0	9.9	5.3	Lineer	3	Hibrit	En.	Boy.	Yük.	Nem	Bas.	1231617-23H5
23	13.6	6.6	0.7	0.4	4.5	32.8	20.2	9.1	24.0	12.1	7.7	27.9	11.1	7.5	Lineer	4	Hibrit	En.	Boy.	K1	Nem	Bas.	1271617-24H5
24	13.6	5.7	0.8	0.6	9.8	44.0	2.2	8.3	3.9	10.5	10.7	15.5	12.1	9.1	Lineer	4	Hibrit	En.	Boy.	A.U.	Sic.	Nem	12121516-24H5
25	13.7	8.8	0.4	0.5	3.6	31.4	5.2	11.4	1.4	21.9	6.8	17.8	13.5	7.3	Lineer	3	Hibrit	En.	Boy.	Yük.	G.U.	Sic.	1231315-23H5

Çizelge 4.20. GY eğitim algoritması ve 5 girdi ile gerçekleştirilen en düşük test hatalarına sahip ANFIS uygulamaları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik											
1	14.2	7.6	0.5	0.3	8.0	31.6	45.1	9.3	6.2	19.0	4.8	19.7	10.5	6.8	Lineer	4	GY	En.	Boy.	D.U.	K3	Nem	124916-24G5
2	14.3	6.9	0.7	0.4	5.4	40.7	44.1	8.0	2.2	13.1	10.8	20.4	9.1	11.1	Lineer	5	GY	En.	Boy.	A.U.	Nem	Bas.	12121617-25G5
3	14.4	9.6	0.0	0.2	4.4	25.6	53.0	5.4	5.6	21.0	0.4	18.0	10.3	5.5	Sabit	2	GY	En.	Boy.	Bakı	K1	A.U.	125712-12G5
4	14.5	7.7	0.5	0.2	3.5	27.4	52.2	12.4	8.4	21.0	3.9	18.3	10.2	4.4	Lineer	4	GY	En.	Boy.	K2	GPM	Sic.	1281415-24G5
5	14.6	9.2	0.1	0.1	4.9	26.2	53.5	5.9	5.0	20.4	0.2	18.6	10.5	6.0	Sabit	2	GY	En.	Boy.	Bakı	K1	K3	12579-12G5
6	14.6	8.3	0.4	0.2	2.8	29.3	52.2	11.1	6.5	19.3	3.2	15.7	10.6	5.0	Lineer	2	GY	En.	Boy.	A.U.	Sic.	Bas.	12121517-22G5
7	14.6	7.3	0.6	0.2	1.6	32.0	51.8	13.3	1.4	20.5	5.2	17.0	10.1	4.3	Lineer	4	GY	En.	Boy.	D.U.	K2	Nem	124816-24G5
8	14.6	9.3	0.0	0.2	5.5	26.7	54.1	6.9	4.5	19.9	0.7	19.1	10.3	6.5	Sabit	2	GY	En.	Boy.	Bakı	Eğim	Bas.	125617-12G5
9	14.6	7.6	0.6	0.2	3.5	33.0	44.5	7.6	1.3	16.8	5.6	17.7	11.8	7.3	Lineer	4	GY	En.	Boy.	Bakı	K4	Nem	1251016-24G5
10	14.6	8.1	0.4	0.2	5.1	27.5	52.4	10.0	3.2	18.5	3.6	15.7	10.9	6.4	Lineer	5	GY	En.	Boy.	K5	G.U.	Sic.	12111315-25G5
11	14.6	9.2	0.1	0.1	5.0	26.2	53.6	5.7	5.0	20.3	0.2	18.7	10.6	6.1	Sabit	2	GY	En.	Boy.	Bakı	K3	Bas.	125917-12G5
12	14.7	7.2	0.6	0.2	1.3	31.9	51.4	13.5	9.2	19.3	2.7	18.7	9.8	7.9	Lineer	4	GY	En.	Boy.	D.U.	Nem	Bas.	1241617-24G5
13	14.7	7.4	0.6	0.2	6.4	34.3	47.5	7.7	3.7	14.4	2.5	15.4	11.3	8.2	Lineer	3	GY	En.	Boy.	K2	Sic.	Nem	1281516-23G5
14	14.7	9.4	0.0	0.0	5.3	26.5	53.9	10.6	4.7	20.1	0.5	18.9	10.3	6.4	Sabit	2	GY	En.	Boy.	Bakı	A.U.	Bas.	1251217-12G5
15	14.7	8.1	0.5	0.2	3.1	32.3	52.7	8.3	9.8	15.0	6.0	13.4	10.6	6.6	Lineer	5	GY	En.	Boy.	K2	A.U.	Sic.	1281215-25G5
16	14.7	8.1	0.5	0.2	4.1	30.0	53.2	9.0	3.9	15.9	4.0	16.5	10.7	7.2	Lineer	4	GY	En.	Boy.	Bakı	A.U.	Sic.	1251215-24G5
17	14.7	8.1	0.5	0.2	2.8	32.3	52.6	6.9	8.9	14.8	4.5	14.2	10.8	6.9	Lineer	4	GY	En.	Boy.	K2	A.U.	Sic.	1281215-24G5
18	14.8	8.1	0.5	0.1	1.1	31.3	53.7	9.9	9.7	18.0	4.0	14.9	10.4	5.6	Lineer	5	GY	En.	Boy.	D.U.	K2	Sic.	124815-25G5
19	14.8	8.1	0.5	0.2	4.2	30.4	51.9	7.5	8.2	15.3	4.5	16.2	11.0	7.3	Lineer	4	GY	En.	Boy.	Bakı	K2	Sic.	125815-24G5
20	14.8	8.1	0.5	0.2	3.5	31.0	53.8	8.6	7.7	16.4	4.9	15.2	10.5	6.4	Lineer	2	GY	En.	Boy.	K2	A.U.	Sic.	1281215-22G5
21	14.8	7.6	0.5	0.2	4.0	30.0	50.0	15.2	7.6	19.7	4.5	17.4	10.9	4.5	Lineer	5	GY	En.	Boy.	K2	GPM	Bas.	1281417-25G5
22	14.8	7.5	0.6	0.2	4.7	29.5	52.6	12.3	0.7	19.3	6.3	20.0	10.4	5.8	Lineer	4	GY	En.	Boy.	Eğim	GPM	Sic.	1261415-24G5
23	14.8	8.2	0.4	0.1	4.4	30.5	51.4	9.3	4.7	18.1	4.5	17.1	11.0	6.3	Lineer	2	GY	En.	Boy.	Bakı	A.U.	Sic.	1251215-22G5
24	14.8	7.9	0.5	0.2	4.5	29.9	51.7	8.4	4.8	18.9	6.5	17.7	10.9	6.2	Lineer	5	GY	En.	Boy.	A.U.	G.U.	Sic.	12121315-25G5
25	14.8	8.2	0.4	0.1	3.0	30.6	54.0	10.2	5.6	18.2	4.9	17.2	10.3	6.1	Lineer	4	GY	En.	Boy.	D.U.	A.U.	Sic.	1241215-24G5

Çizelge 4.11.'de, 1 girdili ve hibrit eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH değerine sahip olan uygulama  $\pm 11.31$  mm hata değeri ile 16-25H1 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak nem değişkeni kullanılmıştır. En düşük eğitim KOH değeri aynı uygulama ile nem girdisi kullanılarak  $\pm 8.47$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 3-13H1 yöntem numaralı (Çizelge sırası: 7) uygulama ile yükseklik girdisi kullanılarak  $\pm 2.39$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 7-25H1 yöntem numaralı (Çizelge sırası: 14) uygulama ile 1. en yakın komşu girdisi kullanılarak  $\pm 17.78$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 16-15H1 yöntem numaralı (Çizelge sırası: 3) uygulama ile nem girdisi kullanılarak  $\pm 3.97$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 16-13H1 yöntem numaralı (Çizelge sırası: 11) uygulama ile nem girdisi kullanılarak  $\pm 0.01$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 7-25H1 yöntem numaralı (Çizelge sırası: 14) uygulama ile 1. en yakın komşu girdisi kullanılarak  $\pm 13.99$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 16-25H1 yöntem numaralı (Çizelge sırası: 1) uygulama ile nem girdisi kullanılarak  $\pm 0.02$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 15-25H1 yöntem numaralı (Çizelge sırası: 18) uygulama ile sıcaklık girdisi kullanılarak  $\pm 26.10$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 16-25H1 yöntem numaralı (Çizelge sırası: 1) uygulama ile nem girdisi kullanılarak  $\pm 7.91$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 4-24H1 yöntem numaralı (Çizelge sırası: 6) uygulama ile denize uzaklık girdisi kullanılarak  $\pm 9.60$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 16-25H1 yöntem numaralı (Çizelge sırası: 1) uygulama ile nem girdisi kullanılarak  $\pm 6.99$  mm hata değeri ile elde edilmiştir. Nem girdisi kullanılan uygulama olan 16-25H1 yöntem numaralı (Çizelge sırası: 1) uygulama eğitim ve test R değerlerine göre en uygun uygulama olarak belirlenmiştir. Uygulama, R eğitim değeri 0.35, R test değeri 0.65 ve  $\pm 11.31$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi

değişkenleri nem, denize uzaklık ve göllere uzaklık olup, en az kullanılan değişkenler akarsulara uzaklık, bakı, 1. ve 2. en yakın komşu, sıcaklık ve yükseklik olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler enlem, boylam, eğim, 3., 4., 5. en yakın komşu, GPM ve basınç girdileri olmuştur. En düşük test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının 13'ü lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulurken 12'si sabit çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 2 ve 5 üyelik fonksiyonu arasında değişirken, en düşük test hatasına sahip uygulamalar 3 ve 5 üyelik fonksiyonu ile gerçekleştirilmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.11.'de yer alan bilgilere göre 16-25H1 yöntem numaralı (Çizelge sırası: 1) nem girdisi kullanılan uygulama, 1 girdili ve hibrit eğitim algoritması kullanılan ANFIS uygulamalarına göre en iyi uygulama olarak belirlenmiştir. 16-25H1 uygulamasının bulanık çıkarım sistemi lineer yapıda iken, her girdi için kullanılan üyelik fonksiyonu sayısı ise 5'tir.

Çizelge 4.12.'de, 1 girdili ve GY eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH değerine sahip olan uygulama  $\pm 14.75$  mm hata değeri ile 13-25G1 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak göllere uzaklık değişkeni kullanılmıştır. En düşük eğitim KOH değeri 7-15G1 yöntem numaralı (Çizelge sırası: 19) uygulama ile 1. en yakın komşu girdisi kullanılarak  $\pm 8.50$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 4-15G1 yöntem numaralı (Çizelge sırası: 2) uygulama ile denize uzaklık girdisi kullanılarak  $\pm 3.93$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 7-15G1 yöntem numaralı (Çizelge sırası: 19) uygulama ile 1. en yakın komşu girdisi kullanılarak  $\pm 16.20$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 8-13G1 yöntem numaralı (Çizelge sırası: 4) uygulama ile 2. en yakın komşu girdisi kullanılarak  $\pm 3.99$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 13-25G1 yöntem numaralı (Çizelge sırası: 1) uygulama ile göllere uzaklık girdisi kullanılarak  $\pm 0.04$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 7-15G1 yöntem numaralı (Çizelge sırası: 19) uygulama ile 1.

en yakın komşu girdisi kullanılarak  $\pm 8.95$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 16-25G1 yöntem numaralı (Çizelge sırası: 12) uygulama ile nem girdisi kullanılarak  $\pm 0.37$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 15-24G1 yöntem numaralı (Çizelge sırası: 24) uygulama ile sıcaklık girdisi kullanılarak  $\pm 26.48$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 13-25G1 yöntem numaralı (Çizelge sırası: 1) uygulama ile göllere uzaklık girdisi kullanılarak  $\pm 0.04$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 4-12G1 yöntem numaralı (Çizelge sırası: 18) uygulama ile denize uzaklık girdisi kullanılarak  $\pm 9.63$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 11-15G1 yöntem numaralı (Çizelge sırası: 6) uygulama ile 5. en yakın komşu girdisi kullanılarak  $\pm 7.09$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 13-25G1 numaralı uygulama ile (Çizelge sırası: 1), göllere uzaklık girdisi kullanılarak R eğitim 0.33, R test 0.26 ve  $\pm 14.75$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri akarsulara uzaklık, göllere uzaklık, denize uzaklık ve 2. en yakın komşu olup, en az kullanılan değişkenler basınç, nem, sıcaklık ve 1., 4. ve 5. en yakın komşu olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler enlem, boylam, yükseklik, bakı, eğim, GPM ve 3. en yakın komşu değeri olmuştur. En düşük test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının 13'ü lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulurken 12'si sabit çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 2 ile 5 arasında değişirken, en düşük test KOH değerine sahip uygulamalar 5 üyelik fonksiyonu kullanılarak gerçekleştirilmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.12.'de yer alan bilgilere göre 13-25G1 yöntem numaralı (Çizelge sırası: 1) göllere uzaklık girdisi kullanılan uygulama, 1 girdili ve GY algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir 13-25G1 uygulamasının bulanık çıkarım sistemi lineer yapıda iken, Her girdi için kullanılan üyelik fonksiyonu sayısı ise 5'tir.

Çizelge 4.13.'te, 2 girdili ve hibrit eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH değerine



sahip olan uygulama  $\pm 11.13$  mm hata değeri ile 1617-24H2 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak nem ve basınç değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 1517-25H2 yöntem numaralı (Çizelge sırası: 13) uygulama ile sıcaklık ve basınç girdileri kullanılarak  $\pm 7.45$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 816-24H2 yöntem numaralı (Çizelge sırası: 25 2. en yakın komşu ve nem girdileri kullanılarak  $\pm 1.18$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 217-23H2 yöntem numaralı (Çizelge sırası: 6) uygulama ile boylam ve basınç girdileri kullanılarak  $\pm 13.22$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 1216-23H2 yöntem numaralı (Çizelge sırası: 17) uygulama ile akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 1.47$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 1316-14H2 yöntem numaralı (Çizelge sırası: 20) uygulama ile göllere uzaklık ve nem girdileri kullanılarak  $\pm 0.94$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 1116-23H2 yöntem numaralı (Çizelge sırası: 21) uygulama ile 5. en yakın komşu ve nem girdileri kullanılarak  $\pm 12.03$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 1516-25H2 yöntem numaralı (Çizelge sırası: 9) uygulama ile sıcaklık ve nem girdileri kullanılarak  $\pm 0.93$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 1516-24H2 yöntem numaralı (Çizelge sırası: 10) uygulama ile sıcaklık ve nem girdileri kullanılarak  $\pm 24.41$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 1216-24H2 yöntem numaralı (Çizelge sırası: 4) uygulama ile akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 2.14$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 416-25H2 yöntem numaralı (Çizelge sırası: 24) uygulama ile denizlere uzaklık ve nem girdileri kullanılarak  $\pm 8.86$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 1517-25H2 yöntem numaralı (Çizelge sırası: 13) uygulama ile sıcaklık ve basınç girdileri kullanılarak  $\pm 5.36$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 13-25G1 yöntem numaralı uygulama ile (Çizelge sırası: 2), nem ve basınç girdileri kullanılarak R eğitim 0.40, R test 0.67 ve  $\pm 11.13$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri nem, basınç ve sıcaklık olup, en az kullanılan

değişkenler akarsulara uzaklık, boylam, denizlere uzaklık, enlem, göllere uzaklık, GPM ve en yakın komşu verileri olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler yükseklik, bakı ve eğim değişkenleri olmuştur. En düşük test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının 24'ü lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulurken 1'i sabit çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 3 ile 5 arasında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.13.'te yer alan bilgilere göre 1617-24H2 yöntem numaralı (Çizelge sırası: 1) nem ve basınç girdisi kullanılan uygulama, 2 girdili ve hibrit eğitim algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir 1617-24H2 uygulamasının bulanık çıkarım sistemi lineer yapıda iken, Her girdi için kullanılan üyelik fonksiyonu sayısı ise 4'tür.

Çizelge 4.14.'te, 2 girdili ve GY eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH değerine sahip olan uygulama  $\pm 14.32$  mm hata değeri ile 215-23G2 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak boylam ve sıcaklık değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 814-14G2 yöntem numaralı (Çizelge sırası: 15) uygulama ile 2. en yakın komşu ve GPM girdileri kullanılarak  $\pm 8.31$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 816-25G2 yöntem numaralı (Çizelge sırası: 22) uygulama ile 2. en yakın komşu ve nem girdileri kullanılarak  $\pm 2.96$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 215-23G2 yöntem numaralı (Çizelge sırası: 1) uygulama ile boylam ve sıcaklık girdileri kullanılarak  $\pm 14.54$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 816-25G2 yöntem numaralı (Çizelge sırası: 22) uygulama ile 2. en yakın komşu ve nem girdileri kullanılarak  $\pm 1.16$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 816-25G2 yöntem numaralı (Çizelge sırası: 22) uygulama ile 2. en yakın komşu ve nem girdileri kullanılarak  $\pm 0.91$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 212-22G2 yöntem numaralı (Çizelge sırası: 11) uygulama ile boylam ve akarsulara uzaklık girdileri kullanılarak  $\pm 14.67$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası

için en düşük tahmin hatası 415-25G2 yöntem numaralı (Çizelge sırası: 17) uygulama ile denize uzaklık ve sıcaklık girdileri kullanılarak  $\pm 2.21$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 1315-24G2 yöntem numaralı (Çizelge sırası: 18) uygulama ile göllere uzaklık ve sıcaklık girdileri kullanılarak  $\pm 24.81$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 515-25G2 yöntem numaralı (Çizelge sırası: 13) uygulama ile bakı ve sıcaklık girdileri kullanılarak  $\pm 44.93$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 212-22G2 yöntem numaralı (Çizelge sırası: 11) uygulama ile boylam ve akarsulara uzaklık girdileri kullanılarak  $\pm 6.95$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 814-14G2 yöntem numaralı (Çizelge sırası: 15) uygulama ile 2. en yakın komşu ve GPM girdileri kullanılarak  $\pm$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 816-25G2 yöntem numaralı (Çizelge sırası: 22) uygulama ile, en yakın komşu ve nem girdileri kullanılarak R eğitim 0.40, R test 0.29 ve  $\pm 14.91$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri sıcaklık, akarsulara uzaklık, denize uzaklık ve boylam olup, en az kullanılan değişkenler bakı, eğim, göllere uzaklık, GPM, 2. en yakın komşu ve nem girdileri olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler enlem, yükseklik, 1., 3., 4. ve 5. en yakın komşu noktaları ve basınç olmuştur. En düşük test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının 22'si lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulurken 3'ü sabit çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 2 ile 5 arasında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.14.'te yer alan bilgilere göre 215-23G2 yöntem numaralı (Çizelge sırası: 1) boylam ve sıcaklık girdisi kullanılan uygulama, 2 girdili ve GY algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir 215-23G2 uygulamasının bulanık çıkarım sistemi lineer yapıda iken, Her girdi için kullanılan üyelik fonksiyonu sayısı ise 3 tür.

Çizelge 4.15.'te, 3 girdili ve hibrit eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH değerine sahip olan uygulama  $\pm 11.52$  mm hata değeri ile 21617-24H3 yöntem numaralı (Çizelge

sırası:1) uygulama olmuştur. Uygulamada eğitim için girdi olarak boylam, nem ve basınç değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 11617-25H3 yöntem numaralı (Çizelge sırası: 23) uygulama ile enlem, nem ve basınç girdileri kullanılarak  $\pm 6.89$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 2416-23H3 yöntem numaralı (Çizelge sırası: 2) uygulama ile boylam, denize uzaklık ve nem girdileri kullanılarak  $\pm 1.84$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 2817-25H3 yöntem numaralı (Çizelge sırası: 8) uygulama ile boylam, 2. en yakın komşu ve basınç girdileri kullanılarak  $\pm 0.89$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 81016-24H3 yöntem numaralı (Çizelge sırası: 22) uygulama ile 2. en yakın komşu, 4. en yakın komşu ve nem girdileri kullanılarak  $\pm 0.36$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 91617-25H3 yöntem numaralı (Çizelge sırası: 25) uygulama ile 3. en yakın komşu, nem ve basınç girdileri kullanılarak  $\pm 0.18$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 2416-23H3 yöntem numaralı (Çizelge sırası: 2) uygulama ile boylam, denize uzaklık ve nem girdileri kullanılarak  $\pm 10.01$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 81216-24H3 yöntem numaralı (Çizelge sırası: 18) uygulama ile 2. en yakın komşu, akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 0.04$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 91516-24H3 yöntem numaralı (Çizelge sırası: 6) uygulama ile 3. en yakın komşu, sıcaklık ve nem girdileri kullanılarak  $\pm 24.19$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 11617-25H3 yöntem numaralı (Çizelge sırası: 23) uygulama ile enlem, nem ve basınç girdileri kullanılarak  $\pm 2.53$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 41617-25H3 yöntem numaralı (Çizelge sırası: 9) uygulama ile denize uzaklık, nem ve basınç girdileri kullanılarak  $\pm 8.44$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 2817-24H3 yöntem numaralı (Çizelge sırası: 21) uygulama ile boylam, 2. en yakın komşu ve basınç girdileri kullanılarak  $\pm 4.23$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, 21617-24H3 yöntem numaralı (Çizelge sırası:1) olan uygulama ile boylam, nem ve basınç girdileri kullanılarak R eğitim 0.55, R test 0.67 ve  $\pm 11.52$  test KOH değeri ile gerçekleştirilmiştir. En çok

kullanılan girdi değişkenleri basınç, akarsulara uzaklık, boylam, nem ve sıcaklık olup, en az kullanılan değişkenler denize uzaklık, enlem, göllere uzaklık, GPM, 1., 2., 3., ve 4. en yakın komşu ile eğim değişkenleri olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler yükseklik, bakı ve 5. en yakın komşu değişkenleri olmuştur. En düşük test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının 24'ü lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulurken 1'i sabit çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 3 ile 5 arasında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.15.'te yer alan bilgilere göre 21617-24H3 yöntem numaralı (Çizelge sırası: 1) boylam, nem ve basınç girdisi kullanılan uygulama, 3 girdili ve hibrit eğitim algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 21617-24H3 uygulamasının bulanık çıkarım sistemi lineer yapıda iken, Her girdi için kullanılan üyelik fonksiyonu sayısı ise 4 tür.

Çizelge 4.16.'da 3 girdili ve GY eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH değerine sahip olan uygulama  $\pm 14.02$  mm hata değeri ile 21315-22G3 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak boylam, göllere uzaklık, sıcaklık değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 21216-24G3 yöntem numaralı (Çizelge sırası: 9) uygulama ile boylam, akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 8.30$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 2815-24G3 yöntem numaralı (Çizelge sırası: 18) uygulama ile boylam, 2. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 3.71$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 2815-22G3 yöntem numaralı (Çizelge sırası: 3) uygulama ile boylam, 2. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 12.21$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 51215-24G3 yöntem numaralı (Çizelge sırası: 17) uygulama ile bakı, akarsulara uzaklık ve sıcaklık girdileri kullanılarak  $\pm 6.47$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 2312-22G3 yöntem numaralı (Çizelge sırası: 20) uygulama ile boylam, yükseklik ve akarsulara uzaklık girdileri kullanılarak  $\pm 0.30$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin

hatası 4916-24G3 yöntem numaralı (Çizelge sırası: 23) uygulama ile denize uzaklık, 3. en yakın komşu ve nem girdileri kullanılarak  $\pm 13.08$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 2715-24G3 yöntem numaralı (Çizelge sırası: 25) uygulama ile boylam, 1. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 1.29$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 2815-24G3 yöntem numaralı (Çizelge sırası: 18) uygulama ile boylam, 2. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 27.85$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 2515-22G3 yöntem numaralı (Çizelge sırası: 13) uygulama ile boylam, bakı ve sıcaklık girdileri kullanılarak  $\pm 45.52$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 21216-24G3 yöntem numaralı (Çizelge sırası: 9) uygulama ile boylam, akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 9.10$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 2815-24G3 yöntem numaralı (Çizelge sırası: 18) uygulama ile boylam, 2. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 5.20$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, boylam, akarsulara uzaklık ve nem girdisi kullanılan, 21216-24G3 numaralı (Çizelge sırası: 9) olan uygulama ile R eğitim 0.40, R test 0.39 ve  $\pm 14.34$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri boylam, akarsulara uzaklık ve sıcaklık olup, en az kullanılan değişkenler yükseklik, ne bakı, denize uzaklık, göllere uzaklık, 1., 2., 3. ve 5. en yakın komşu değişkeni olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler enlem, eğim, GPM, 4. en yakın komşu ve basınç olmuştur. En düşük test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının tamamı lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 2 ile 5 arasında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.16.'da yer alan bilgilere göre 21216-24G3 yöntem numaralı (Çizelge sırası: 9) boylam, akarsulara uzaklık ve nem girdisi kullanılan uygulama, 3 girdili ve GY eğitim algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 21216-24G3 uygulamasının bulanık çıkarım sistemi lineer yapıda iken, her girdi için kullanılan üyelik fonksiyonu sayısı ise 4'tür.

Çizelge 4.17.'de, 4 girdili ve hibrit eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir.

4 girdili uygulamaların tamamında ilk iki girdi enlem ve boylam deęişkenleri olarak belirlenmiştir. Bu deęişkenlere ilave olarak dięer girdi deęişkenleri kullanılmıştır. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH deęerine sahip olan uygulama  $\pm 12.54$  mm hata deęeri ile 12416-23H4 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak enlem, boylam, denize uzaklık ve nem deęişkenleri kullanılmıştır. En düşük eğitim KOH deęeri 121516-23H4 yöntem numaralı (Çizelge sırası: 4) uygulama ile enlem, boylam, sıcaklık ve nem girdileri kullanılarak  $\pm 6.55$  mm hata deęeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 12517-24H4 yöntem numaralı (Çizelge sırası: 16) uygulama ile enlem, boylam, bakı ve basınç girdileri kullanılarak  $\pm 0.16$  mm hata deęeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 12816-25H4 yöntem numaralı (Çizelge sırası: 10) uygulama ile enlem, boylam, 2. en yakın komşu ve nem girdileri kullanılarak  $\pm 12.90$  mm hata deęeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 121216-14H4 yöntem numaralı (Çizelge sırası: 14) uygulama ile enlem, boylam, akarsulara uzaklık ve nem girdileri kullanılarak  $\pm 0.20$  mm hata deęeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 12416-25H4 yöntem numaralı (Çizelge sırası: 15) uygulama ile enlem, boylam, denize uzaklık ve nem girdileri kullanılarak  $\pm 0.63$  mm hata deęeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 12517-24H4 yöntem numaralı (Çizelge sırası: 16) uygulama ile enlem, boylam, bakı ve basınç girdileri kullanılarak  $\pm 8.17$  mm hata deęeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 12816-24H4 yöntem numaralı (Çizelge sırası: 6) uygulama ile enlem, boylam, 2. en yakın komşu ve nem girdileri kullanılarak  $\pm 0.15$  mm hata deęeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 12515-15H4 yöntem numaralı (Çizelge sırası: 25) uygulama ile enlem, boylam, bakı ve sıcaklık girdileri kullanılarak  $\pm 28.72$  mm hata deęeri ile elde edilmiştir. Eğitim setinin maksimum yağış deęerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 12517-24H4 yöntem numaralı (Çizelge sırası: 16) uygulama ile enlem, boylam, bakı ve basınç girdileri kullanılarak  $\pm 13.3$  mm hata deęeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH deęeri 12416-15H4 yöntem numaralı (Çizelge sırası: 21) uygulama ile enlem, boylam, denize uzaklık ve nem girdileri kullanılarak  $\pm 9.44$  mm hata deęeri ile elde edilmiştir. İstasyonların seyrek olduęu noktalarda yer alan test noktaları için en düşük KOH deęeri 12816-25H4 yöntem

numaralı (Çizelge sırası: 10) uygulama ile enlem, boylam, 2. en yakın komşu ve nem girdileri kullanılarak  $\pm 2.40$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, enlem, boylam, denize uzaklık ve nem girdisi kullanılan, 12416-23H4 numaralı (Çizelge sırası: 1) uygulama ile R eğitim 0.61, R test 0.52 ve  $\pm 12.54$  test KOH değeri ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri nem, basınç ve sıcaklık olup, en az kullanılan değişkenler akarsulara uzaklık, bakı, denize uzaklık, GPM, 1. en yakın komşu, 2. en yakın komşu ve yükseklik olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler göllere uzaklık, 3. en yakın komşu, 4. en yakın komşu, 5. en yakın komşu ve eğim değişkenleri olmuştur. En düşük test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının 17'si lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulurken 8'i sabit çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 2 ile 5 arasında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.17.'de yer alan bilgilere göre 12517-24H4 yöntem numaralı (Çizelge sırası: 16) enlem, boylam, bakı ve basınç girdisi kullanılan uygulama, 4 girdili ve hibrit eğitim algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. Test KOH değeri diğer yöntemlere göre yüksek olan bu uygulamanın rasgele test noktaları üzerindeki hatalarının fazla olması nedeniyle test KOH değeri yüksek bir değer almaktadır. Oysaki karakteristik test noktaları üzerinde daha uygun hata değerlerine sahiptir. 12517-24H4 uygulamasının bulanık çıkarım sistemi lineer yapıda iken, her girdi için kullanılan üyelik fonksiyonu sayısı ise 4'tür.

Çizelge 4.18.'de, 4 girdili ve GY eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir. 4 girdili uygulamaların tamamında ilk iki girdi enlem ve boylam değişkenleri olarak belirlenmiştir. Bu değişkenlere ilave olarak diğer girdi değişkenleri kullanılmıştır. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH değerine sahip olan uygulama  $\pm 14.50$  mm hata değeri ile 121517-14G4 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak enlem, boylam, sıcaklık ve basınç değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 12417-24G4 yöntem numaralı (Çizelge sırası: 2) uygulama ile enlem, boylam, denize uzaklık ve basınç girdileri kullanılarak  $\pm 7.74$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 12815-23G4 yöntem numaralı (Çizelge sırası: 11) uygulama ile enlem, boylam, 2. en yakın komşu ve sıcaklık



girdileri kullanılarak  $\pm 2.32$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 12815-25G4 yöntem numaralı (Çizelge sırası: 5) uygulama ile enlem, boylam, 2. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 14.96$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 121215-25G4 yöntem numaralı (Çizelge sırası: 13) uygulama ile enlem, boylam, akarsulara uzaklık ve sıcaklık girdileri kullanılarak  $\pm 5.51$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 12417-24G4 yöntem numaralı (Çizelge sırası: 2) uygulama ile enlem, boylam, denize uzaklık ve basınç girdileri kullanılarak  $\pm 1.58$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 12817-22G4 yöntem numaralı (Çizelge sırası: 23) uygulama ile enlem, boylam, 2. en yakın komşu ve basınç girdileri kullanılarak  $\pm 16.13$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 121217-14G4 yöntem numaralı (Çizelge sırası: 21) uygulama ile enlem, boylam, akarsulara uzaklık ve basınç girdileri kullanılarak  $\pm 1.96$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 121517-14G4 yöntem numaralı (Çizelge sırası: 1) uygulama ile enlem, boylam, sıcaklık ve basınç girdileri kullanılarak  $\pm 26.24$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 12515-23G4 yöntem numaralı (Çizelge sırası: 20) uygulama ile enlem, boylam, bakı ve sıcaklık girdileri kullanılarak  $\pm 50.54$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 121314-13G4 yöntem numaralı (Çizelge sırası: 3) uygulama ile enlem, boylam, göllere uzaklık ve GPM girdileri kullanılarak  $\pm 9.36$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 12317-25G4 yöntem numaralı (Çizelge sırası: 22) uygulama ile enlem, boylam, yükseklik ve basınç girdileri kullanılarak  $\pm 5.10$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, enlem, boylam, sıcaklık ve basınç girdileri kullanılarak R eğitim 0.49, R test 0.23 ve  $\pm 14.50$  test KOH değeri bulunan, 121517-14G4 numaralı uygulama (Çizelge sırası:1) ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri basınç ve sıcaklık olup, en az kullanılan değişkenler akarsulara uzaklık, bakı, denize uzaklık, göllere uzaklık, GPM, 1. en yakın komşu, 2. en yakın komşu, 3. en yakın komşu, 4. en yakın komşu, nem, yükseklik ve eğim olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişken 5. en yakın komşu olmuştur. En düşük

test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının 19'u lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulurken 6'sı sabit çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 2 ile 5 arasında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.18.'de yer alan bilgilere göre 121517-14G4 yöntem numaralı (Çizelge sırası: 1) enlem, boylam, sıcaklık ve basınç girdisi kullanılan uygulama, 4 girdili ve GY algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir 121517-14G4 uygulamasının bulanık çıkarım sistemi sabit yapıda iken, Her girdi için kullanılan üyelik fonksiyonu sayısı ise 4 tür.

Çizelge 4.19.'da 5 girdili ve hibrit eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir. 5 girdili uygulamaların tamamında ilk iki girdi enlem ve boylam değişkenleri olarak belirlenmiştir. Bu değişkenlere ilave olarak diğer girdi değişkenleri kullanılmıştır. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH değerine sahip olan uygulama  $\pm 11.86$  mm hata değeri ile 12121516-22H5 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak enlem, boylam, akarsulara uzaklık, sıcaklık ve nem değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 12121516-24H5 yöntem numaralı (Çizelge sırası: 24) uygulama ile enlem, boylam, akarsulara uzaklık, sıcaklık ve nem girdileri kullanılarak  $\pm 5.70$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 124916-23H5 yöntem numaralı (Çizelge sırası: 13) uygulama ile enlem, boylam, denize uzaklık, 3. en yakın komşu ve nem girdileri kullanılarak  $\pm 1.13$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 1231617-23H5 yöntem numaralı (Çizelge sırası: 22) uygulama ile enlem, boylam, yükseklik nem ve basınç girdileri kullanılarak  $\pm 10.03$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 1231016-24H5 yöntem numaralı (Çizelge sırası: 17) uygulama ile enlem, boylam, yükseklik, 4. en yakın komşu ve nem girdileri kullanılarak  $\pm 0.80$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 124816-23H5 yöntem numaralı (Çizelge sırası: 8) uygulama ile enlem, boylam, denize uzaklık, 2. en yakın komşu ve nem girdileri kullanılarak  $\pm 0.79$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 12121617-25H5 yöntem numaralı (Çizelge sırası: 4)

uygulama ile enlem, boylam, akarsulara uzaklık, nem ve basınç girdileri kullanılarak  $\pm 7.83$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 1271416-23H5 yöntem numaralı (Çizelge sırası: 14) uygulama ile enlem, boylam, 1. en yakın komşu, GPM ve nem girdileri kullanılarak  $\pm 1.14$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 1231016-24H5 yöntem numaralı (Çizelge sırası: 17) uygulama ile enlem, boylam, yükseklik, 4. en yakın komşu ve nem girdileri kullanılarak  $\pm 4.12$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 12121516-24H5 yöntem numaralı (Çizelge sırası: 24) uygulama ile enlem, boylam, akarsulara uzaklık, sıcaklık ve nem girdileri kullanılarak  $\pm 2.21$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 1231617-23H5 yöntem numaralı (Çizelge sırası: 22) uygulama ile enlem, boylam, yükseklik nem ve basınç girdileri kullanılarak  $\pm 9.88$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 1271416-23H5 yöntem numaralı (Çizelge sırası: 14) uygulama ile enlem, boylam, 1. en yakın komşu, GPM ve nem girdileri kullanılarak  $\pm 3.58$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, enlem, boylam, akarsulara uzaklık, nem ve basınç girdileri kullanılan, 12121617-25H5 yöntem numaralı (Çizelge sırası: 4) olan uygulama ile R eğitim 0.76, R test 0.63 ve  $\pm 12.67$  test KOH bulguları ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri nem, sıcaklık, basınç ve akarsulara uzaklık olup, en az kullanılan değişkenler GPM, göllere uzaklık, denize uzaklık, 1. en yakın komşu, 2. en yakın komşu, 3. en yakın komşu, 4. en yakın komşu, yükseklik, değişkenleri olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında hiç kullanılmayan değişkenler, eğim, bakı ve 5. en yakın komşu girdileridir. En düşük test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının 24'ü lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulurken 1'i sabit çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 5'tir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.19.'da yer alan bilgilere göre 12121617-25H5 yöntem numaralı (Çizelge sırası: 4) enlem, boylam, akarsulara uzaklık, nem ve basınç girdisi kullanılan uygulama, 5 girdili ve hibrit eğitim algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir. 12121617-25H5 uygulamasının bulanık çıkarım sistemi lineer yapıda iken, Her girdi için kullanılan üyelik fonksiyonu sayısı ise 5'tir.

Çizelge 4.20.'de, 5 girdili ve GY eğitim algoritması kullanılan ANFIS uygulamalarının en düşük test hatasına sahip ilk 25 uygulamasına ait bulgular verilmiştir. 5 girdili uygulamaların tamamında ilk iki girdi enlem ve boylam değişkenleri olarak belirlenmiştir. Bu değişkenlere ilave olarak diğer girdi değişkenleri kullanılmıştır. Çizelgede bulguları verilen ANFIS uygulamaları arasından en düşük test KOH değerine sahip olan uygulama  $\pm 14.22$  mm hata değeri ile 124916-24G5 yöntem numaralı (Çizelge sırası: 1) uygulama olmuştur. Uygulamada eğitim için girdi olarak enlem, boylam, 3. en yakın komşu, denize uzaklık ve nem değişkenleri kullanılmıştır. En düşük eğitim KOH değeri 12121617-25G5 yöntem numaralı (Çizelge sırası: 2) uygulama ile enlem, boylam, akarsulara uzaklık, nem ve basınç girdileri kullanılarak  $\pm 6.86$  mm hata değeri ile elde edilmiştir. Karakteristik noktalardan düşük yükseklikte yer alan test noktası için en düşük tahmin hatası 124815-25G5 yöntem numaralı (Çizelge sırası: 18) uygulama ile enlem, boylam, denize uzaklık, 2. en yakın komşu ve sıcaklık girdileri kullanılarak  $\pm 1.12$  mm hata değeri ile elde edilmiştir. Ortalama yükseklikte yer alan test noktası için en düşük tahmin hatası 1281215-25G5 yöntem numaralı (Çizelge sırası: 15) uygulama ile enlem, boylam, 2. en yakın komşu, akarsulara uzaklık ve sıcaklık girdileri kullanılarak  $\pm 13.41$  mm hata değeri ile elde edilmiştir. Maksimum yükseklikte yer alan test noktası için en düşük tahmin hatası 125712-12G5 yöntem numaralı (Çizelge sırası: 3) uygulama ile enlem, boylam, bakı, 1. en yakın komşu ve akarsulara uzaklık girdileri kullanılarak  $\pm 5.41$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yüksekliğinin üzerinde yer alan ekstrapolasyon test noktası için en düşük tahmin hatası 1261415-24G5 yöntem numaralı (Çizelge sırası: 22) uygulama ile enlem, boylam, eğim, sıcaklık ve GPM girdileri kullanılarak  $\pm 0.75$  mm hata değeri ile elde edilmiştir. Minimum yağış alan test noktası için en düşük tahmin hatası 12121617-25G5 yöntem numaralı (Çizelge sırası: 2) uygulama ile enlem, boylam, akarsulara uzaklık, nem ve basınç girdileri kullanılarak  $\pm 13.11$  mm hata değeri ile elde edilmiştir. Ortalama yağış alan test noktası için en düşük tahmin hatası 12579-12G5 yöntem numaralı (Çizelge sırası: 5) uygulama ile enlem, boylam, bakı, 1. en yakın komşu ve 3. en yakın komşu girdileri kullanılarak  $\pm 0.15$  mm hata değeri ile elde edilmiştir. Maksimum yağış alan test noktası için en düşük tahmin hatası 125712-12G5 yöntem numaralı (Çizelge sırası: 3) uygulama ile enlem, boylam, bakı, 1. en yakın komşu ve akarsulara uzaklık girdileri kullanılarak  $\pm 25.62$  mm hata değeri ile elde edilmiştir. Eğitim setinin maksimum yağış değerinin üzerinde yağış alan, maksimum yağış ekstrapolasyon test noktası için en düşük tahmin hatası 12121617-25G5 yöntem numaralı (Çizelge sırası: 2) uygulama ile enlem, boylam, akarsulara uzaklık, nem

ve basınç girdileri kullanılarak  $\pm 44.07$  mm hata değeri ile elde edilmiştir. Rasgele test noktaları için en düşük KOH değeri 12121617-25G5 yöntem numaralı (Çizelge sırası: 2) uygulama ile enlem, boylam, akarsulara uzaklık, nem ve basınç girdileri kullanılarak  $\pm 9.13$  mm hata değeri ile elde edilmiştir. İstasyonların seyrek olduğu noktalarda yer alan test noktaları için en düşük KOH değeri 124816-24G5 yöntem numaralı (Çizelge sırası: 7) uygulama ile enlem, boylam, denize uzaklık, 2. en yakın komşu ve nem girdileri kullanılarak  $\pm 4.35$  mm hata değeri ile elde edilmiştir. Eğitim ve test R değerlerine göre en uygun uygulama, enlem, boylam, akarsulara uzaklık, nem ve basınç girdileri kullanılan, 12121617-25G5 yöntem numaralı (Çizelge sırası:2) uygulama ile R eğitim 0.65, R test 0.38 ve  $\pm 14.27$  mm test KOH bulguları ile gerçekleştirilmiştir. En çok kullanılan girdi değişkenleri akarsulara uzaklık, basınç, nem ve sıcaklık değişkenleri olup, en az kullanılan değişkenler denize uzaklık, eğim, göllere uzaklık, GPM, 1. en yakın komşu, 2. en yakın komşu, 3. en yakın komşu, 4. en yakın komşu, 5. en yakın komşu değişkenleri olmuştur. En düşük test hatasına sahip ilk 25 uygulama arasında yükseklik değişkeni hiç kullanılmamıştır. En düşük test KOH değerine sahip ilk 25 uygulamaya göre sıralanan çizelgede, ANFIS uygulamalarının 20'si lineer çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulurken 5'i sabit çıktı yapısına sahip bulanık çıkarım sistemi ile oluşturulmuştur. Her girdi için kullanılan üyelik fonksiyonu sayısı ise 2 ile 5 arasında değişmiştir. Hem test KOH değeri hem de karakteristik noktalarda ortaya çıkan hata değerleri incelendiğinde, Çizelge 4.20.'de yer alan bilgilere göre 12121617-25G5 yöntem numaralı (Çizelge sırası: 2) enlem, boylam, akarsulara uzaklık, nem ve basınç girdisi kullanılan uygulama, 5 girdili ve GY algoritması kullanılan uygulamalara göre en iyi uygulama olarak belirlenmiştir 12121617-25G5 uygulamasının bulanık çıkarım sistemi lineer yapıda iken, Her girdi için kullanılan üyelik fonksiyonu sayısı ise 5'tir.

#### **4.3. En uygun Yapay Sinir Ağları (ANN) Bulgularının Değerlendirilmesi**


Her girdi sayısı ve kullanılan yöntem için gerçekleştirilen uygulama setlerinden en düşük test KOH değerine sahip ilk 25 uygulama bulgularının verildiği, ANN yöntemi için Çizelge 4.1.'den Çizelge 4.10.'a kadar, ANFIS yöntemi için Çizelge 4.11.'den Çizelge 4.20.'ye kadar verilen çizelgeler, KOH değerleri, karakteristik noktalarda görülen hata değerleri, kullanılan girdiler ve yöntem parametreleri bakımından değerlendirilmiştir. Bu şekilde 250 ANN uygulaması ve 250 ANFIS uygulaması incelenmiştir.

ANN yöntemi uygulamalarına ait LM ve SCG eğitim algoritması ve farklı girdi sayılarına göre incelenen her bulgu setinden en uygun uygulamalar Çizelge 4.23. ile verilmiştir. Hibrit ve GY eğitim algoritması ve farklı girdi sayılarına göre ANFIS yöntemi için değerlendirilen her çizelge için belirlenen en uygun uygulamalar ise Çizelge 4.26. ile verilmiştir.


ANN yöntemi kullanılarak her eğitim algoritması ve farklı girdi sayısı için belirlenen en iyi 25 uygulamaya ait bulguların ortalama test KOH hatalarına göre, en düşük ortalama test KOH değerleri 2 girdili ve LM algoritması kullanan uygulamalarda, 3 girdili ve LM algoritması kullanılan uygulamalarda ve 3 girdili SCG algoritması kullanılan uygulamalarda elde edilmiştir. ANN uygulamalarının test hata değerlerinin eğitim algoritması ve girdi sayısı bakımından genel olarak değerlendirilmesi için ortalama hata büyüklükleri Şekil 4.1. ile görselleştirilmiştir. Şekil 4.1.'e göre  $\pm 10.2$  mm ile en düşük ortalama test KOH değerine sahip olan uygulama bulgu seti, 3 girdili ve LM algoritması kullanılan uygulamalara aittir. Şekil 4.1. üzerinde görülebileceği gibi ortalama hata değerlerine göre aynı girdi sayısına ait uygulamalarda LM yöntemi SCG yöntemine göre daima daha düşük tahmin hataları ortaya koymuştur.

Benzer şekilde ANN uygulama setlerinin maksimum yağış ekstrapolasyon test noktası üzerindeki ortalama hatalarını temsil eden grafik ise Şekil 4.2. ile verilmiştir. Şekil 4.2'ye göre en düşük ortalama hata değerleri 1 girdili ve LM algoritması kullanılan uygulama setinde ve 3 girdili ve LM algoritması kullanılan uygulama setine ait bulgularda elde edilmiştir. Şekil 4.2. üzerinde görülebileceği gibi, ortalama hata değerlerine göre aynı girdi sayısına ait uygulamalarda LM yöntemi en yüksek yağış ekstrapolasyon test noktası için de SCG yöntemine göre daima daha düşük tahmin hataları ortaya koymuştur.

Sonuç olarak en düşük test KOH değerine sahip uygulamalara göre, LM algoritması SCG algoritmasına göre daima daha düşük ortalama hata değerleri elde etmiştir. Ayrıca girdi sayısına göre 3 girdili uygulamalar düşük ortalama tahmin hata değerlerine sahiptir.



**Şekil 4.1.** Her uygulama setinin en düşük test KOH değerine sahip ilk 25 uygulamasının ortalama test KOH değerleri.



**Şekil 4.2.** Her uygulama setinin en düşük test KOH değerine sahip ilk 25 uygulamasının ortalama maksimum yağış ekstrapolasyon test noktası hata değerleri.

ANN yöntemi için her girdi sayısı ve kullanılan algoritmaya göre, en düşük test KOH hatasına sahip 25 uygulamadan oluşan uygulama bulguları setlerinin karakteristik test noktaları üzerindeki ortalama hataları Çizelge 4.21. ile verilmiştir. Çizelge 4.21.' de verilen ortalama hata değerlerine göre 3 girdili ve LM algoritması kullanılan ANN uygulamaları, ortalama hatalar bakımından en uygun tahmin performansına sahiptir.

**Çizelge 4.21.** ANN yöntemi ile her girdi sayısı ve farklı algoritma için belirlenen en düşük test hatasına sahip 25 uygulamanın ortalama hatası

En düşük test hatasına sahip 25 uygulamanın ortalamaları	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Karakteristik Test Hataları ± mm							Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	
					Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış			Ortalama Yükseklik
1 Girdili-LM	11.0	8.5	0.3	0.7	5.5	30.1	5.3	5.8	1.7	18.7	2.1	20.2	9.5	7.3
1 Girdili-SCG	11.0	9.0	0.2	0.7	5.4	28.1	6.3	6.0	4.0	18.3	2.6	21.0	9.6	7.3
2 Girdili-LM	10.3	8.3	0.4	0.7	3.6	26.3	8.1	6.9	5.9	16.2	3.7	19.4	8.9	6.9
2 Girdili-SCG	10.7	9.1	0.3	0.7	4.3	25.9	9.6	5.6	6.0	17.5	4.7	21.2	9.1	7.9
3 Girdili-LM	10.2	8.5	0.5	0.7	4.0	22.9	6.2	6.7	4.2	17.9	4.8	19.1	8.9	7.1
3 Girdili-SCG	10.4	10.0	0.2	0.7	5.6	20.5	9.1	5.3	5.3	18.3	4.7	19.9	9.0	7.9
4 Girdili-LM	11.4	8.4	0.5	0.6	4.1	27.0	7.1	10.7	5.1	17.7	3.7	18.6	10.4	6.1
4 Girdili-SCG	11.4	9.8	0.2	0.6	5.7	24.2	12.3	9.6	5.9	19.1	6.5	17.1	9.9	8.7
5 Girdili-LM	10.8	8.4	0.5	0.7	4.8	25.8	10.3	9.1	4.6	15.3	5.2	13.3	9.8	6.6
5 Girdili-SCG	11.0	9.5	0.2	0.7	4.8	23.8	12.6	8.2	6.2	16.8	6.2	16.6	9.7	8.2

1 girdiden 5 girdiye kadar ANN yöntemi ile gerçekleştirilen hem LM hem de SCG uygulamasına ait en düşük test hatası görülen en iyi 25 uygulamanın bulgularının yer aldığı bulgu setlerine göre Şekil 4.3. ve Şekil 4.4. ile değişkenlerin kullanımının oranları verilmiştir. Şekil 4.3 ile 1, 2 ve 3 girdili uygulamaların en düşük test hatasına sahip uygulamalarında kullanılan 17 farklı girdinin kullanım oranı dağılımları verilmiştir. Şekil 4.4. ile 4 ve 5 girdili uygulamaların en düşük test hatasına sahip uygulamalarında kullanılan enlem ve boylam değişkeni dışındaki 15 farklı girdinin kullanım oranı dağılımları verilmiştir.

Şekil 4.3.'e göre 1, 2 ve 3 girdili, en iyi test hatası bulgularına sahip ANN uygulamalarında sırasıyla en çok nem, basınç, denize uzaklık, bakı, yükseklik ve sıcaklık değişkenleri kullanılmıştır. 3 girdili en düşük test hatasına sahip uygulamalara ait değişken dağılımına göre enlem, boylam ve en yakın komşu değeri değişkenlerinin en az kullanılan değişkenler arasında bulunduğu görülmektedir. Bu durum örnek noktalarının konumları arasındaki ilişkinin, yağışların tahmini için en önemli parametreler olmadığını göstermektedir. Yani yağış tahmini yapılan konumun diğer örnek istasyon noktalarına göre enlem ve boylamı, nerede olduğu, komşu örnek nokta değerleri bilgisi, nem, basınç,



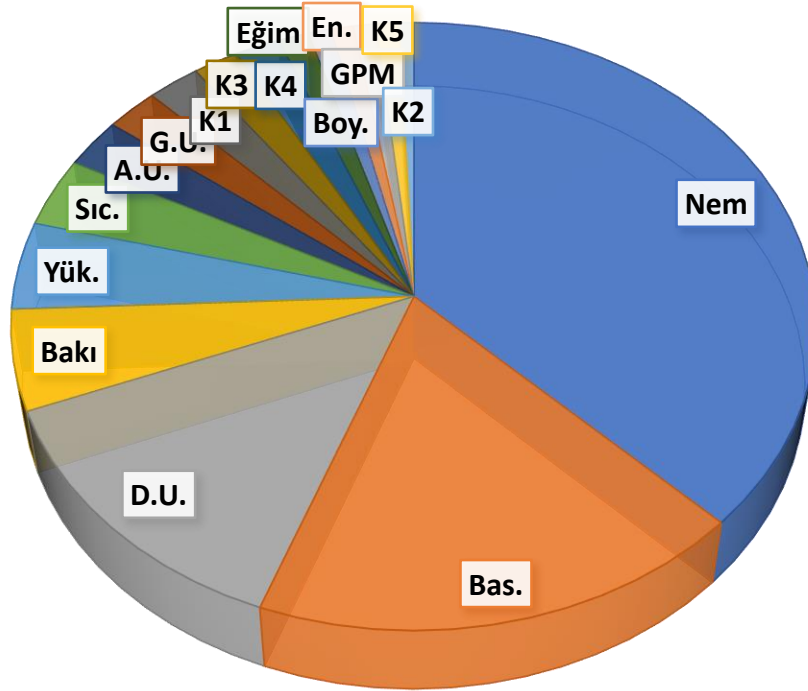
denize uzaklık, bakı ve yükseklik gibi değişkenlere göre daha önemli bir tahmin girdisi olmamıştır.

Şekil 4.4.'e göre, 4 ve 5 girdili, ilk iki girdisi daima enlem ve boylam olan uygulamaların en iyi test hatasına sahip uygulamalarında en çok sırasıyla nem, basınç, sıcaklık, bakı, 4. en yakın komşu değeri, GPM, denize uzaklık ve akarsulara uzaklık değişkenleri kullanılmıştır. En az ise 1., 2., 3. ve 5. en yakın komşu değeri değişkenleri, göllere uzaklık, eğim ve yükseklik değişkenleri kullanılmıştır. Bu uygulamalarda yakınlık-benzerlik ilişkisi bakımından birinci ve ikinci girdilerde daima enlem ve boylam değişkenleri kullanılmıştır. Şekilden görüleceği üzere en yakın 1. komşu değeri değişkeni en çok kullanılan girdi olmadığı gibi daha uzakta yer alan 4. en yakın komşu değeri değişkeni diğer komşulara göre daha çok kullanılmıştır. 4 ve 5 girdili ANN uygulamalarında da görüldüğü üzere yakın olan benzerdir yaklaşımı tahmin bulgularında gözlemlenmemiştir. En yakın komşu veya en yakın 2., 3. komşu nokta değeri en önemli girdiler olmamıştır.

Burada Tobler'in (1970) yakın objelerin uzak objelere daha benzer olduğunu belirttiği coğrafyanın ilk kanunu düşünüldüğünde aslında bu kanunu temel alan klasik yöntemlerin, bu çalışmada en önemli değişkenler yerine en az kullanılan nitelikleri daha çok ön plana çıkardığı söylenebilir. Bu durum böyle bir çalışmada kriging gibi klasik yöntemlerinin mekânsal otokorelasyon, yakınlık ve komşuluğa dayanan metodolojisinin aslında daima en iyi yaklaşım yolu olmadığını göstermektedir. Bu çalışmada gerçekleştirilen, uygun ANN uygulamalarında tahmini yapılan konuma ait nem gibi değişkenler tahminlerin performansında daha etkili olmuştur.


Çizelge 4.22. ile değişkenlerin en düşük test KOH hatasına sahip ANN uygulamaları arasında hangi oranda kullanıldığı listelenmiştir.

### 3 Girdili En İyi ANN Uygulamalarında - Girdi Değişkeni Dağılımı



Şekil 4.3. 3 girdili en iyi ANN uygulamalarında kullanılan girdilerin kullanım miktarının dağılımı

### 4 ve 5 Girdili En İyi ANN Uygulamalarında Enlem Ve Boylam Dışındaki Girdilerin Dağılımı



Şekil 4.4. 4 ve 5 girdili en iyi ANN uygulamalarında enlem ve boylam dışında kullanılan girdilerin kullanım miktarının dağılımı

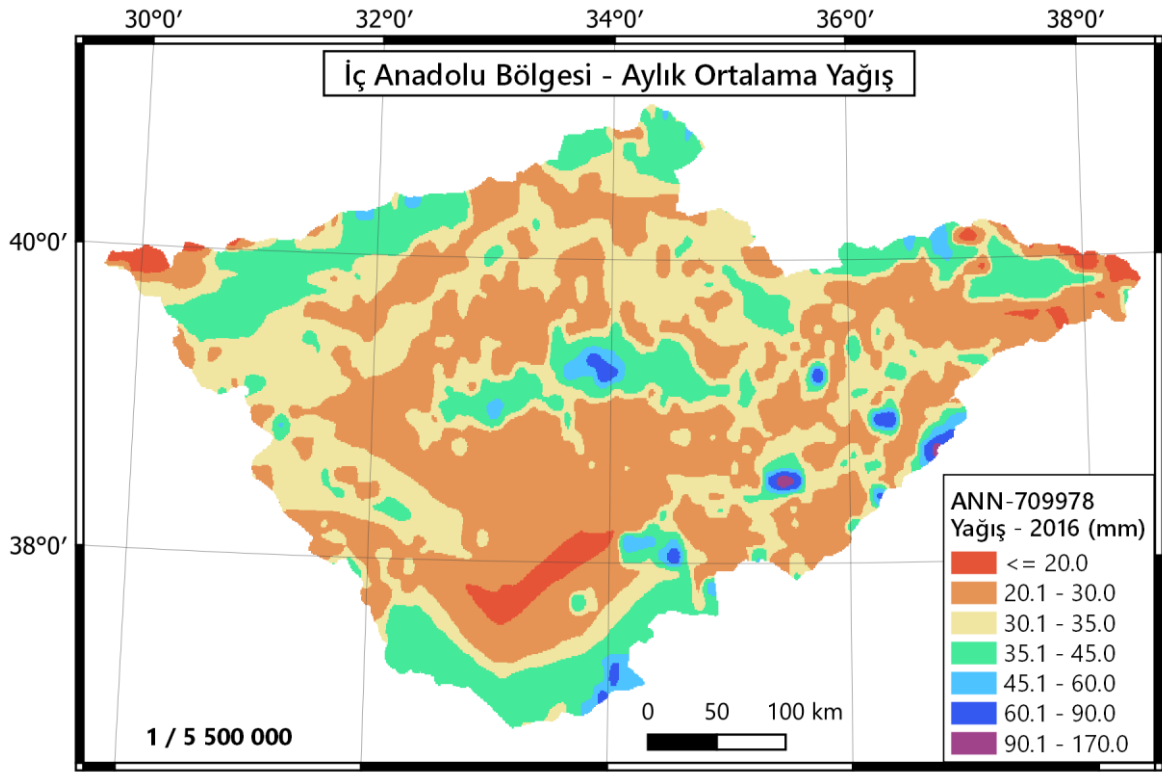
**Çizelge 4.22.** ANN yöntemi ile belirlenen en düşük test KOH değerine sahip uygulamalarda kullanılan girdiler

ANN					
1-2-3 Girdili Uygulamalar			4-5 Girdili Uygulamalarda Kullanılan Enlem ve Boylam Dışındaki Girdiler		
Girdi	Sayı	Yüzde	Girdi	Sayı	Yüzde
Nem	112	%37.33	Nem	55	%18.33
Bas.	55	%18.33	Bas.	30	%10.00
D.U.	40	%13.33	Sıc.	26	%8.67
Bakı	16	%5.33	Bakı	24	%8.00
Yük.	14	%4.67	K4	21	%7.00
Sıc.	11	%3.67	GPM	18	%6.00
A.U.	8	%2.67	D.U.	13	%4.33
G.U.	7	%2.33	A.U.	12	%4.00
K1	7	%2.33	Yük.	10	%3.33
K3	6	%2.00	K3	8	%2.67
K4	6	%2.00	Eğim	7	%2.33
Eğim	4	%1.33	G.U.	7	%2.33
Boy.	3	%1.00	K2	7	%2.33
En.	3	%1.00	K1	6	%2.00
GPM	3	%1.00	K5	6	%2.00
K5	3	%1.00	Boy.	-	-
K2	2	%0.67	En.	-	-

ANN için her çizelgeye ait en iyi uygulamalar Çizelge 4.23. ile verilmiştir. Çizelge 4.23.'te verilen bilgilere göre farklı uygulama setlerinde genellikle en iyi uygulama olarak seçilen bulgularda 2 gizli katmandan oluşan ANN yapılarının kullanıldığı görülmektedir. 3693 numaralı uygulama dışında 10 uygulama seti içinden seçilen en iyi diğer tüm uygulamalar iki gizli katmandan oluşmaktadır. Nöron sayıları bakımından her iki katman için de 2'den 20 nörona kadar uygulamalar gerçekleştirilmesine rağmen seçilen en iyi uygulamaların birinci ve ikinci katmanının 20 nörondan oluşmaması nöron sayısı aralığının yeterli olabileceğini göstermektedir.

Çizelge 4.23. te verilen her uygulama seti için belirlenen en iyi uygulamalar arasında 709978 numaralı, 3 girdili ve LM algoritması kullanılan uygulama, bu tez çalışmasında ANN yöntemi ile gerçekleştirilen tüm uygulamalar arasındaki en iyi tahmin performansına sahip uygulama olarak belirlenmiştir. Uygulama en düşük test KOH değerine sahip olup uygun R değerlerine sahiptir. Ayrıca karakteristik test noktalarında görülen hatalar bakımından da diğer uygulamalara göre daha başarılı bulunmuştur. Bu

uygulamada denize uzaklık, nem ve basınç deęişkenleri girdi olarak kullanılmıştır. Uygulamaya ait yağış haritası Şekil 4.5. ile verilmiştir.



Şekil 4.5. En iyi ANN uygulaması ile elde edilen aylık ortalama yağış haritası

Çizelge 4.23. LM ve SCG eğitim algoritmaları ile gerçekleştirilen 1, 2, 3, 4 ve 5 girdili uygulamalar arasından seçilen en uygun ANN sonuçları



Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik	Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem
Çizelge 4.1.-1	11	3	27216	10.5	8.5	0.3	0.7	7.2	31.2	0.1	6.6	0.7	16.3	4.2	15.8	9.1	7.7	Nem	-	-	-	-	LM
Çizelge 4.2.-1	15	14	4817	10.5	8.8	0.3	0.7	3.4	17.2	6.8	10.1	8.1	18.6	0.1	18.6	10.2	5.4	Yük.	-	-	-	-	SCG
Çizelge 4.3.-2	4	8	61952	10.0	7.1	0.63	0.73	6.6	10.6	12.6	18.6	8.5	13.3	0.6	18.1	9.1	9.2	Yük.	K1	-	-	-	LM
Çizelge 4.4.-11	16	19	102766	10.8	8.1	0.45	0.70	4.1	31.9	4.7	6.2	8.4	16.5	6.3	20.3	8.6	9.5	D.U.	Nem	-	-	-	SCG
<b>Çizelge 4.5.-1</b>	<b>10</b>	<b>8</b>	<b>709978</b>	<b>9.6</b>	<b>7.3</b>	<b>0.61</b>	<b>0.76</b>	<b>0.1</b>	<b>21.9</b>	<b>9.5</b>	<b>2.6</b>	<b>9.2</b>	<b>9.6</b>	<b>0.1</b>	<b>22.0</b>	<b>8.9</b>	<b>4.1</b>	<b>D.U.</b>	<b>Nem</b>	<b>Bas.</b>	-	-	<b>LM</b>
Çizelge 4.6.-22	18	15	1006704	10.6	8.1	0.46	0.72	8.5	21.4	9.2	5.3	15.1	17.9	0.7	17.8	9.6	6.1	K1	Sic.	Nem	-	-	SCG
Çizelge 4.7.-15	17	19	182195	11.5	5.4	0.81	0.64	0.1	30.5	6.0	10.0	8.1	13.9	4.7	21.9	10.6	1.4	En.	Boy.	GPM	Nem	-	LM
Çizelge 4.8.-1	18	0	3693	10.5	8.2	0.44	0.71	4.9	27.7	7.1	6.0	1.1	17.7	4.9	14.8	9.6	7.1	En.	Boy.	Bakı	Bas.	-	SCG
Çizelge 4.9.-22	10	19	416806	10.9	5.8	0.77	0.69	1.6	32.5	7.4	10.8	3.7	7.0	5.3	15.4	10.2	4.8	En.	Boy.	Bakı	GPM	Nem	LM
Çizelge 4.10.-24	9	20	1698478	11.2	7.6	0.55	0.67	9.2	30.7	5.0	6.5	0.8	16.3	8.9	15.7	10.2	7.6	En.	Boy.	K4	A.U.	Nem	SCG

#### 4.4. En uygun Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS) Bulgularının Değerlendirilmesi

ANFIS yöntemi kullanılarak her eğitim algoritması ve farklı girdi sayısı için belirlenen en iyi 25 uygulamaya ait bulgulara göre en düşük ortalama test KOH değerleri 2 girdili ve hibrit eğitim algoritması kullanan uygulamalarda, 3 girdili ve hibrit eğitim algoritması kullanan uygulamalarda ve 5 girdili hibrit eğitim algoritması kullanan uygulamalarda elde edilmiştir. Bunlardan  $\pm 12.68$  mm ile en düşük ortalama test KOH değerine sahip olan uygulama bulgu seti, 3 girdili ve hibrit eğitim algoritması kullanan uygulamalara aittir. ANFIS uygulamalarının test hata değerlerinin, eğitim algoritması ve girdi sayısı bakımından genel olarak değerlendirilmesi için ortalama hata büyüklükleri Şekil 4.6. ile görselleştirilmiştir. Şekil 4.6. üzerinde görülebileceği gibi ortalama hata değerlerine göre aynı girdi sayısına ait uygulamalarda hibrit eğitim algoritması, GY algoritmasına göre daima daha düşük tahmin hataları ortaya koymuştur.

Benzer şekilde ANFIS uygulama setlerinin maksimum yağış ekstrapolasyon test noktası üzerindeki ortalama hatalarını temsil eden grafik ise Şekil 4.7. ile verilmiştir. Şekil 4.7.'ye göre maksimum yağış ekstrapolasyon test noktası için en düşük ortalama hata değerleri 2, 3 ve 5 girdili, hibrit eğitim algoritması kullanılan uygulama setlerine ait bulgularda elde edilmiştir. Şekil 4.7. üzerinde görülebileceği gibi, hata değerlerine göre aynı girdi sayısına ait uygulamalarda hibrit eğitim algoritması, GY algoritmasına göre daima daha düşük tahmin hataları ortaya koymuştur.  $\pm 23.11$  mm değerinde en yüksek yağış ekstrapolasyon hatası ile 5 girdili, hibrit eğitim algoritması kullanılan uygulama seti en iyi tahmin performansını göstermiştir.

ANFIS yöntemi hakkında Şekil 4.6. ve Şekil 4.7. ile verilen, her uygulama veri setinin en iyi 25 uygulamasının ortalama hata değerlerine göre, hibrit eğitim algoritması GY algoritmasına göre daima daha iyi tahmin performansı sergilemiştir. Ayrıca girdi sayısına göre 3 girdili uygulamalar düşük ortalama tahmin hata değerlerine sahiptir.

**ANFIS Ortalama Test KOH  $\pm$  mm****Şekil 4.6.** ANFIS yöntemi ile her uygulama setinin en düşük test KOH değerine sahip ilk 25 uygulamasının ortalama test KOH değerleri**Maksimum Yağış Ekstrapolasyon Test Noktası Ortalama Hata  $\pm$  mm****Şekil 4.7.** ANFIS yöntemi ile her uygulama setinin en düşük test KOH değerine sahip ilk 25 uygulamasının ortalama maksimum yağış ekstrapolasyon test noktası hata değerleri

ANFIS yöntemi için her girdi sayısı ve kullanılan algoritmaya göre, en düşük test KOH hatasına sahip 25 uygulamadan oluşan uygulama bulguları setlerinin karakteristik test noktaları üzerindeki ortalama hataları Çizelge 4.24. ile verilmiştir. Çizelge 4.24.' de

verilen ortalama hata deęerlerine gre, 3 girdili ve hibrit eęitim algoritması kullanılan ANFIS uygulamaları ortalama hatalar bakımından en uygun tahmin performansına sahiptir.

**Çizelge 4.24.** ANFIS yöntemi ile her girdi sayısı ve farklı algoritma için belirlenen en düşük test hatasına sahip 25 uygulamanın ortalama hatası

En düşük test Hatasına sahip 25 Uygulama Ortalamaları	Test KOH ± mm	Eęitim KOH ± mm	Eęitim R	Test R	Karakteristik Test Hataları ± mm								Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm
					Düşük Yükseklik	Maksimum Yaęış	Maksimum Yaęış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yaęış	Ortalama Yaęış	Ortalama Yükseklik		
1 Girdili-Hibrit	14.4	8.8	0.2	0.3	6.2	29.1	48.2	8.2	2.7	17.5	3.6	20.7	10.3	8.5
1 Girdili-GY	15.1	8.8	0.2	0.1	6.8	29.2	55.3	8.4	3.8	16.6	3.6	20.0	10.4	8.5
2 Girdili-Hibrit	12.9	8.2	0.4	0.5	5.0	30.1	26.9	9.3	5.9	17.6	4.1	21.8	10.3	7.9
2 Girdili-GY	14.8	8.8	0.3	0.2	7.5	28.6	52.4	9.5	4.8	18.4	4.0	19.4	10.4	8.6
3 Girdili-Hibrit	12.7	7.8	0.5	0.6	6.6	31.6	25.0	9.4	5.2	15.7	4.0	20.3	10.4	7.9
3 Girdili-GY	14.4	8.5	0.4	0.3	7.1	30.2	49.3	14.6	5.2	16.9	4.3	15.5	10.3	8.0
4 Girdili-Hibrit	14.0	7.3	0.6	0.4	4.5	33.0	35.8	9.7	6.4	16.8	6.0	19.7	11.3	6.6
4 Girdili-GY	14.9	8.3	0.4	0.1	4.8	29.8	53.5	9.0	5.0	18.0	4.9	18.3	10.8	6.6
5 Girdili-Hibrit	13.1	7.0	0.6	0.5	6.1	33.2	23.1	10.3	6.1	16.2	6.8	17.8	11.4	6.1
5 Girdili-GY	14.6	8.1	0.4	0.2	4.1	30.3	51.5	9.3	5.5	18.1	4.0	17.3	10.5	6.4

1 girdiden 5 girdiye kadar, ANFIS yöntemi ile gerçekleştirilen hem hibrit eęitim algoritması hem de GY eęitim algoritması uygulamalarına ait en düşük test hatası görlen en iyi 25 uygulama bulgularının yer aldığı veri setlerine gre, Şekil 4.8. ve Şekil 4.9. ile deęişkenlerin en iyi uygulama setlerinde kullanımının oranları verilmiştir. Şekil 4.8. üzerinde ile 1, 2 ve 3 girdili uygulamaların en düşük test hatasına sahip uygulamalarında kullanılan 17 farklı girdinin kullanım oranı dağılımları verilmiştir. Şekil 4.9. üzerinde ise 4 ve 5 girdili uygulamaların en düşük test hatasına sahip uygulamalarında kullanılan enlem ve boylam deęişkeni dışındaki 15 farklı girdinin kullanım oranı dağılımları verilmiştir.




Şekil 4.8.'e göre 1, 2 ve 3 girdili uygulamalarda en iyi test hatası bulgularına sahip uygulamalarda en çok sırasıyla nem, sıcaklık, boylam, akarsulara uzaklık, denize uzaklık ve göllere uzaklık değişkenleri kullanılmıştır. 3 girdili ve en düşük test hatasına sahip uygulamalara ait değişken dağılımına göre, enlem ve en yakın komşu değeri değişkenlerinin en az kullanılan değişkenler arasında bulunduğu görülmektedir. Bu durum gerçekleştirilen ANFIS uygulamasında örnek noktalarının konumları arasındaki enlem ve komşu noktalarının yağış değerleri değişkenlerinin, yağışların tahmini için en önemli parametreler olmadığını göstermektedir. Yağış tahmini yapılan konumun diğer örnek istasyon noktalarına göre enlemi, nerede olduğu bilgisi ve komşu örnek noktaların yağış değerleri; nem, sıcaklık, boylam, akarsulara uzaklık, denize uzaklık ve göllere uzaklık değişkenleri gibi değişkenlere göre daha önemli bir tahmin girdisi olmamıştır. Buna karşın 3 girdi ile gerçekleştirilen ANFIS uygulamalarında boylam değişkeni, en iyi uygulamalarda en sık kullanılan 3. değişken olmuştur. Boylam bilgisinin düşük test hatalarına sahip uygulamalarda kullanımı, tahmin yapılan noktanın konumunu temsil eden bir değişkenin ANFIS tahminlerinde etkili olabileceğini göstermiştir. Ancak enlem ve komşu örnek nokta yağış değerlerinin en az kullanılan değişkenler olması, ANN yöntemi bulgularında da olduğu gibi, yakınlık benzerlik ilişkisinin en uygun tahmin stratejisi olmayabileceğini göstermiştir.

Şekil 4.9.'a göre, 4 ve 5 girdili, ilk iki girdisi daima enlem ve boylam olan ANFIS uygulamalarının en iyi test hatasına sahip uygulamalarında en çok sırasıyla nem, sıcaklık, basınç, akarsulara uzaklık, 2. en yakın komşu değeri ve bakı değişkenleri kullanılmıştır. En az ise 1., 3., 4. ve 5. en yakın komşu değeri değişkenleri, göllere uzaklık, eğim ve yükseklik değişkenleri kullanılmıştır. Bu uygulamalarda yakınlık-benzerlik ilişkisi bakımından birinci ve ikinci girdilerde daima enlem ve boylam değişkenleri sabit tutulmuştur. Şekil 4.9.'dan görüleceği üzere ANN uygulamalarında olduğu gibi ANFIS uygulamalarında da en yakın 1. komşu değeri değişkeni en çok kullanılan girdi olmadığı gibi daha uzakta yer alan 2. en yakın komşu değeri değişkeni diğer komşulara göre daha çok kullanılmıştır. 4 ve 5 girdili ANFIS uygulamalarında da görüldüğü üzere yakın olan benzerdir yaklaşımı, yakınlığın temsil edildiği değişkenlerin en az kullanılan değişkenler olması nedeniyle tahmin bulgularında gözlemlenememiştir. En yakın komşu veya en yakın 1., 3. komşu nokta değeri en önemli girdiler olmamıştır. Bu durum klasik yöntemlerinin mekânsal otokorelasyon, yakınlık ve komşuluğa dayanan metodolojisinin aslında daima en iyi yaklaşım yolu olmadığını ANFIS uygulamaları bulgularında da göstermektedir. Tahmini yapılan konuma ait nem ve sıcaklık gibi değişkenler tahminlerin


performansında daha etkili olmuştur. Çizelge 4.25. ile en düşük test KOH hatasına sahip ANFIS uygulamaları arasında değişkenlerin hangi oranda kullanıldığı listelenmiştir.

**3 Girdili En İyi ANFIS Uygulamalarında - Girdi Değişkeni Dağılımı**



**Şekil 4.8.** 3 girdili en iyi ANFIS uygulamalarında kullanılan girdilerin kullanım miktarının dağılımı

**4 ve 5 Girdili En İyi ANFIS Uygulamalarında Enlem Ve Boylam Dışındaki Girdilerin Dağılımı**



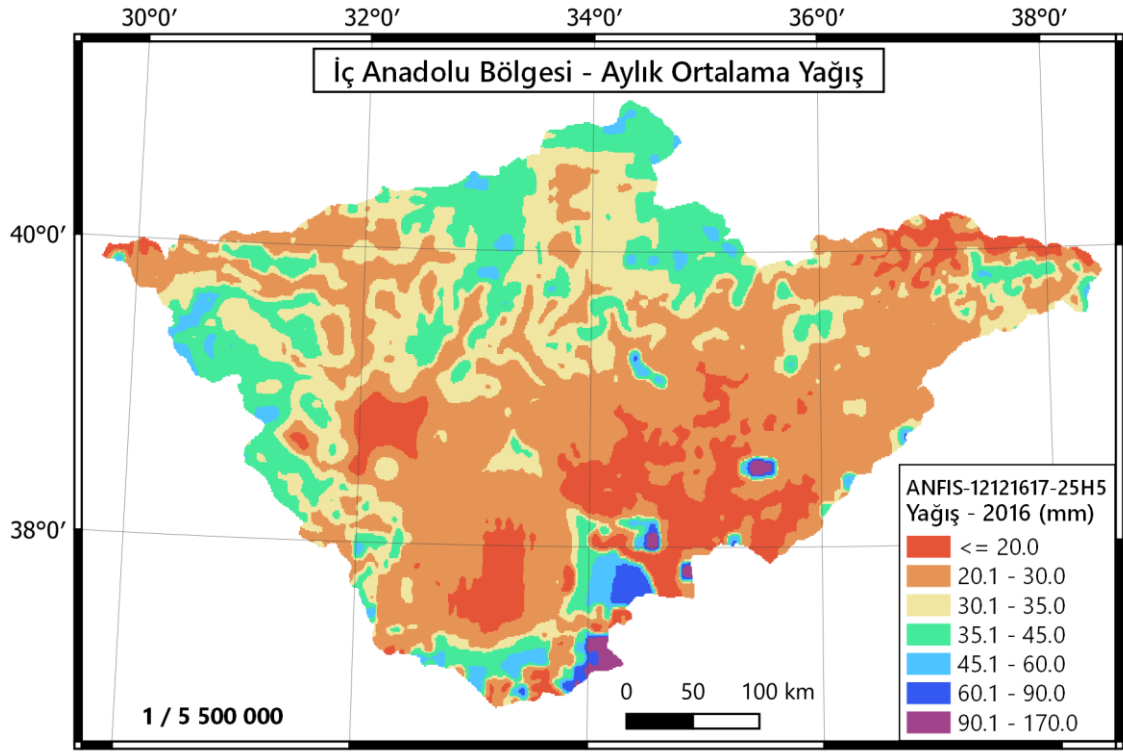
**Şekil 4.9.** 4 ve 5 girdili en iyi ANFIS uygulamalarında enlem ve boylam dışında kullanılan girdilerin kullanım miktarının dağılımı

**Çizelge 4.25.** ANFIS yöntemi ile belirlenen en düşük test KOH değerine sahip uygulamalarda kullanılan girdiler

ANFIS					
1-2-3 Girdili Uygulamalar			4-5 Girdili Uygulamalarda Kullanılan Enlem ve Boylam Dışındaki Girdiler		
Girdi	Sayı	Yüzde	Girdi	Sayı	Yüzde
Nem	52	% 17.33	Nem	47	% 15.67
Sıc.	49	% 16.33	Sıc.	40	% 13.33
Boy.	37	% 12.33	Bas.	31	% 10.33
A.U.	29	% 9.67	A.U.	29	% 9.67
D.U.	26	% 8.67	K2	18	% 6.00
G.U.	23	% 7.67	Bakı	16	% 5.33
K2	18	% 6.00	D.U.	16	% 5.33
Bas.	17	% 5.67	GPM	12	% 4.00
K1	11	% 3.67	G.U.	11	% 3.67
Bakı	10	% 3.33	K1	10	% 3.33
K3	9	% 3.00	Yük.	7	% 2.33
En.	5	% 1.67	K3	6	% 2.00
GPM	4	% 1.33	Eğim	3	% 1.00
K4	3	% 1.00	K4	3	% 1.00
K5	3	% 1.00	K5	1	% 0.33
Eğim	2	% 0.67	Boy.	-	-
Yük.	2	% 0.67	En.	-	-

ANFIS için her çizelgeye ait en iyi uygulamalar Çizelge 4.26. ile verilmiştir. Çizelge 4.26.'da verilen bilgilere göre farklı uygulama setlerinde genellikle en iyi uygulama olarak seçilen bulgularda lineer çıktı yapısından oluşan ANFIS yapılarının kullanıldığı görülmektedir. 121517-14G4 numaralı uygulama dışında, 10 uygulama seti içinden seçilen en iyi tüm uygulamalar lineer çıktı yapısından oluşmaktadır. Ayrıca en iyi uygulamalar genellikle 3, 4 ve 5 üyelik fonksiyonu kullanımı ile gerçekleştirilmiştir.

Çizelge 4.26.'da verilen her uygulama seti için belirlenen en iyi uygulamalar arasında 12121617-25H5 numaralı, 5 girdili ve hibrit eğitim algoritması kullanılan uygulama, bu tez çalışmasında ANFIS yöntemi ile gerçekleştirilen tüm uygulamalar arasındaki en iyi tahmin performansına sahip uygulama olarak belirlenmiştir. Uygulama en yüksek eğitim R değerine sahiptir. Ayrıca karakteristik test noktalarında görülen hatalar bakımından da diğer uygulamalara göre başarılı bulunmuştur. Bu uygulamada girdi değişkenleri olarak enlem, boylam, akarsulara uzaklık, nem ve basınç değişkenleri kullanılmıştır. Uygulamaya ait yağış haritası Şekil 4.10. ile verilmiştir.



Şekil 4.10. En iyi ANFIS uygulaması ile elde edilen yağış tahmin haritası

**Çizelge 4.26.** Hibrit ve GY eğitim algoritmaları ile gerçekleştirilen 1, 2, 3, 4 ve 5 girdili uygulamalar arasından seçilen en uygun ANFIS sonuçları

Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Düşük Yükseklilik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklilik	Maksimum Yükseklilik	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklilik	Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
Çizelge 4.11.-1	11.3	8.5	0.35	0.65	5.1	33.2	7.9	4.6	4.4	20.6	0.0	18.8	9.6	7.0	Lineer	5	Hibrit	Nem	-	-	-	-	16-25H1
Çizelge 4.12.-1	14.7	8.6	0.33	0.26	4.4	30.2	51.9	10.9	0.0	15.6	5.2	19.8	10.5	9.2	Lineer	5	GY	G.U.	-	-	-	-	13-25G1
Çizelge 4.13.-1	11.1	8.4	0.38	0.68	6.0	32.2	8.7	7.7	6.2	18.4	3.7	21.1	9.0	8.8	Lineer	4	Hibrit	Nem	Bas.	-	-	-	1617-24H2
Çizelge 4.14.-1	14.3	8.6	0.33	0.24	8.4	28.0	47.6	17.6	4.9	18.9	3.5	14.5	10.6	7.0	Lineer	3	GY	Boy.	Sıc.	-	-	-	215-23G2
Çizelge 4.15.-1	11.5	7.6	0.55	0.67	8.8	34.7	9.3	19.1	7.2	15.5	7.4	12.6	9.0	10.0	Lineer	4	Hibrit	Boy.	Nem	Bas.	-	-	21617-24H3
Çizelge 4.16.-9	14.3	8.3	0.40	0.39	5.4	35.2	51.2	10.6	2.4	14.7	5.7	16.4	9.1	10.3	Lineer	4	GY	Boy.	A.U.	Nem	-	-	21216-24G3
Çizelge 4.17.-16	14.4	6.9	0.65	0.41	0.2	31.2	13.3	4.2	9.6	8.2	6.9	18.6	14.9	9.3	Lineer	4	Hibrit	En.	Boy.	Bakı	Bas.	-	12517-24H4
Çizelge 4.18.-1	14.5	7.9	0.49	0.23	5.0	26.2	53.6	10.8	5.0	20.3	2.5	19.0	10.0	6.1	Sabit	4	GY	En.	Boy.	Sıc.	Bas.	-	121517-14G4
<b>Çizelge 4.19.-4</b>	<b>12.7</b>	<b>5.9</b>	<b>0.76</b>	<b>0.63</b>	<b>12.5</b>	<b>31.8</b>	<b>15.6</b>	<b>7.0</b>	<b>1.8</b>	<b>7.8</b>	<b>3.9</b>	<b>16.8</b>	<b>12.4</b>	<b>4.4</b>	<b>Lineer</b>	<b>5</b>	<b>Hibrit</b>	<b>En.</b>	<b>Boy.</b>	<b>A.U.</b>	<b>Nem</b>	<b>Bas.</b>	<b>12121617-25H5</b>
Çizelge 4.20.-2	14.3	6.9	0.65	0.38	5.4	40.7	44.1	8.0	2.2	13.1	10.8	20.4	9.1	11.1	Lineer	5	GY	En.	Boy.	A.U.	Nem	Bas.	12121617-25G5

#### 4.5. ANN-PSO, ANN-GA, ANFIS-PSO ve ANFIS-GA Bulguları

Tez çalışmasında klasik LM, SCG, GY ve hibrit eğitim algoritmaları ile eğitim süreci gerçekleştirilen ANN ve ANFIS yöntemlerinin sezgisel optimizasyon yöntemleri ile eğitilmesi sonucunda yöntemlerin tahmin performanslarının nasıl etkileneceği araştırılmıştır. Bunun için ANN ve ANFIS için belirlenen en iyi uygulamalar PSO ve GA algoritması ile yeniden eğitilmiştir.

En iyi bulgulara sahip 709978 numaralı ANN uygulamasının, LM algoritması yerine PSO ya da GA ile eğitilmesi sonucunda tahmin performanslarının nasıl değiştiği incelenmiştir. Aynı şekilde, 12121617-25H5 numaralı ANFIS uygulamasının da hibrit eğitim algoritması yerine PSO ve GA yöntemleri ile yeniden eğitilmesi ile uygulamanın tahmin performansının nasıl değiştiği incelenmiştir. Sezgisel optimizasyon algoritmaları ile farklı popülasyon sayıları kullanılarak 1000 iterasyon ile eğitilen ANN-PSO ve ANN-GA bulguları Çizelge 4.27., ANFIS-PSO ve ANFIS-GA bulguları ise Çizelge 4.28. ile verilmiştir.

Çizelge 4.27.'de verilen uygulama bulgularına göre, PSO yöntemi ile eğitilen ANN uygulamalarından en iyi tahmin performansına popülasyon sayısı 50 olarak belirlenen, ANN-PSO-50-2 yöntem numaralı uygulama sahiptir. GA yöntemi ile eğitilen ANN uygulaması için ise en iyi bulgulara popülasyon sayısı 25 olan, ANN-GA-25-4 numaralı uygulama sahiptir.

Çizelge 4.28.'de verilen uygulama bulgularına göre, PSO yöntemi ile eğitilen ANFIS uygulamalarından en iyi tahmin performansına popülasyon sayısı 25 olarak belirlenen, ANFIS-PSO-25 yöntem numaralı uygulama sahiptir. GA yöntemi ile eğitilen ANFIS uygulaması için ise en iyi bulgulara popülasyon sayısı 25 olan, ANFIS-GA-25 numaralı uygulama sahiptir.

Çizelge 4.29. üzerinde ANN, ANN-PSO, ANN-GA ve ANFIS, ANFIS-PSO, ANFIS-GA uygulamalarının en iyi bulguları karşılaştırılmıştır. Çizelgede verilen hem test KOH değeri hem de maksimum yağış ekstrapolasyon noktası test hatası değerlerine göre GA ve PSO yöntemleri en uygun ANN ve ANFIS uygulamalarının tahmin performansını geliştirmemiştir. Tahmin hataları Şekil 4.11. üzerinde karşılaştırılmıştır.

ANN-PSO-50-2 ve ANN-GA-25-4 uygulaması ile elde edilen yağış dağılımı tahmin haritaları sırasıyla Şekil 4.12. ve Şekil 4.13. ile verilmiştir.

ANFIS-PSO-25 ve ANFIS-GA-25 uygulaması ile elde edilen yağış dağılımı tahmin haritaları sırasıyla Şekil 4.14. ve Şekil 4.15. ile verilmiştir.

Çizelge 4.27. Çizelge 4.28.'de yer alan bulgulara göre popülasyon sayısının artırılması bu çalışmada tahminler üzerinde etkili olmamıştır.

Sezgisel optimizasyon algoritmaları ile gerçekleştirilecek hibrit ANN ve ANFIS uygulamalarında daha uygun tahmin sonuçları elde edebilmek için farklı optimizasyon parametrelerinin denenmesi faydalı olabilir.




**Çizelge 4.27.** PSO ve GA yöntemlerini eğitim algoritması olarak kullanarak gerçekleştirilen ANN-709978 numaralı uygulama bulguları

Çizelge Sıra	1. Katman Nöron S.	2. Katman Nöron S.	Yöntem NO	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik	Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem	Popülasyon Sayısı
1	10	8	ANN-PSO-25-5	14.4	8.7	0.3	0.4	4.8	26.9	53.7	10.3	3.4	20.7	8.3	19.3	9.3	7.4	D.U.	Nem	Bas.	-	-	PSO	25
2	10	8	ANN-GA-25-4	12.3	9.6	0.1	0.6	8.8	22.8	37.0	1.5	5.4	23.5	6.2	16.6	8.9	9.9	D.U.	Nem	Bas.	-	-	GA	25
3	10	8	ANN-PSO-50-2	12.9	8.6	0.3	0.5	6.3	31.1	28.5	14.7	15.4	23.4	6.0	22.2	8.9	9.3	D.U.	Nem	Bas.	-	-	PSO	50
4	10	8	ANN-GA-50-2	14.4	9.0	0.1	0.3	3.0	29.5	50.3	10.8	8.6	17.1	3.5	21.9	9.9	8.7	D.U.	Nem	Bas.	-	-	GA	50
5	10	8	ANN-PSO-100-3	15.4	8.7	0.3	0.2	5.8	26.4	54.6	10.5	23.9	20.3	6.2	19.2	10.0	8.7	D.U.	Nem	Bas.	-	-	PSO	100
6	10	8	ANN-GA-100-3	15.0	8.9	0.2	0.2	4.5	31.2	55.8	10.7	1.9	17.5	5.1	23.5	9.4	8.6	D.U.	Nem	Bas.	-	-	GA	100
7	10	8	ANN-PSO-200-4	15.7	8.4	0.4	0.2	4.5	31.5	53.5	10.3	24.9	19.9	5.5	22.5	9.9	9.4	D.U.	Nem	Bas.	-	-	PSO	200
8	10	8	ANN-GA-200-3	14.2	8.8	0.2	0.4	3.3	28.3	52.5	10.6	0.6	20.6	7.6	22.1	8.6	8.6	D.U.	Nem	Bas.	-	-	GA	200



**Çizelge 4.28.** PSO ve GA yöntemlerini eğitim algoritması olarak kullanarak gerçekleştirilen ANFIS-12121617-25H5 numaralı uygulama bulguları.

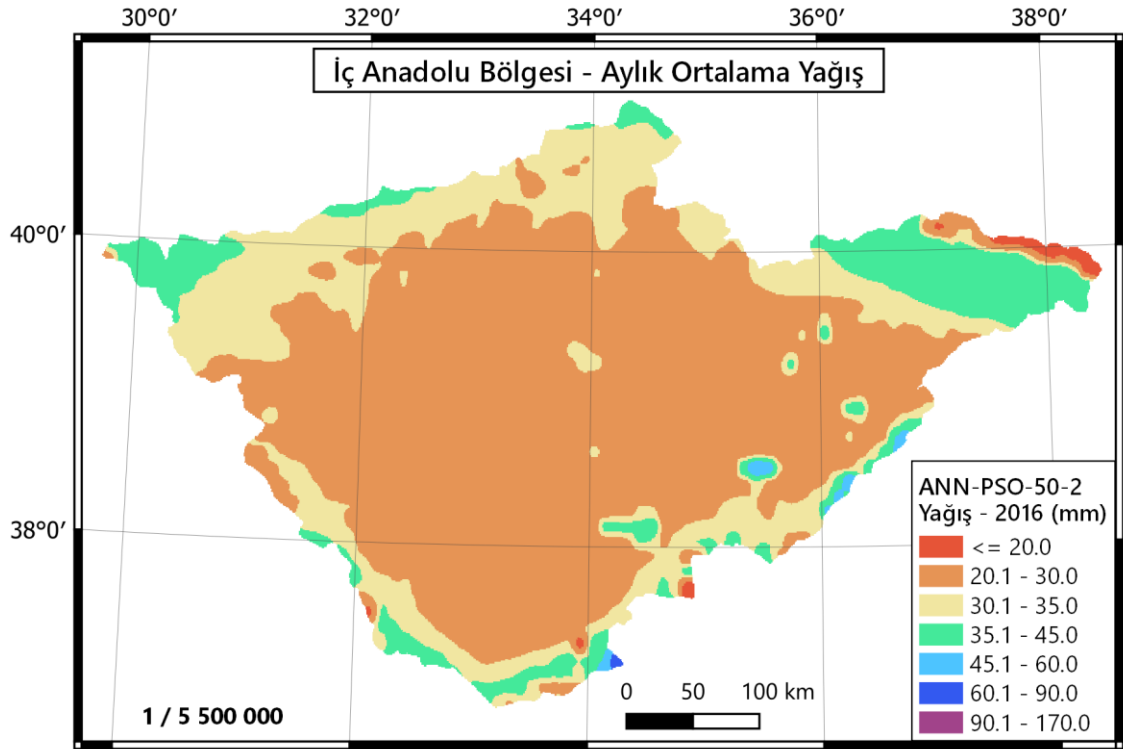
Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik	Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Üyelik Fonksiyonu Çıktı Tipi	Üyelik Fonksiyonu Sayısı	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Popülasyon Sayısı	Yöntem NO
1	14.3	7.9	0.5	0.3	5.1	29.6	48.1	8.4	12.2	18.1	4.4	18.3	10.5	6.6	Linear	5	PSO	En.	Boy.	A.U.	Nem	Bas.	25	ANFIS-PSO-25
2	14.5	8.1	0.5	0.2	4.1	30.8	50.9	8.8	3.8	17.1	4.8	17.3	10.6	6.6	Lineer	5	PSO	En.	Boy.	A.U.	Nem	Bas.	50	ANFIS-PSO-50
3	15.0	7.8	0.5	0.2	4.0	28.8	52.3	10.3	4.1	19.2	5.8	18.2	11.3	5.6	Linear	5	PSO	En.	Boy.	A.U.	Nem	Bas.	100	ANFIS-PSO-100
4	17.5	8.0	0.5	-0.2	4.7	30.2	73.6	8.6	16.4	17.7	4.7	17.7	10.6	6.6	Linear	5	PSO	En.	Boy.	A.U.	Nem	Bas.	200	ANFIS-PSO-200
5	14.8	8.0	0.5	0.2	4.6	31.3	54.6	8.6	3.5	16.7	5.4	17.6	10.1	7.0	Linear	5	GA	En.	Boy.	A.U.	Nem	Bas.	25	ANFIS-GA-25
6	15.6	7.5	0.6	0.1	4.6	31.3	54.7	8.1	3.5	16.9	5.4	17.7	11.8	6.9	Linear	5	GA	En.	Boy.	A.U.	Nem	Bas.	50	ANFIS-GA-50
7	15.0	7.9	0.5	0.1	4.2	31.0	54.4	8.6	2.7	17.0	5.0	20.9	10.4	6.7	Linear	5	GA	En.	Boy.	A.U.	Nem	Bas.	100	ANFIS-GA-100
8	15.0	8.1	0.5	0.1	4.3	28.5	55.9	8.4	2.7	18.1	5.0	17.3	10.7	6.8	Linear	5	GA	En.	Boy.	A.U.	Nem	Bas.	200	ANFIS-GA-200



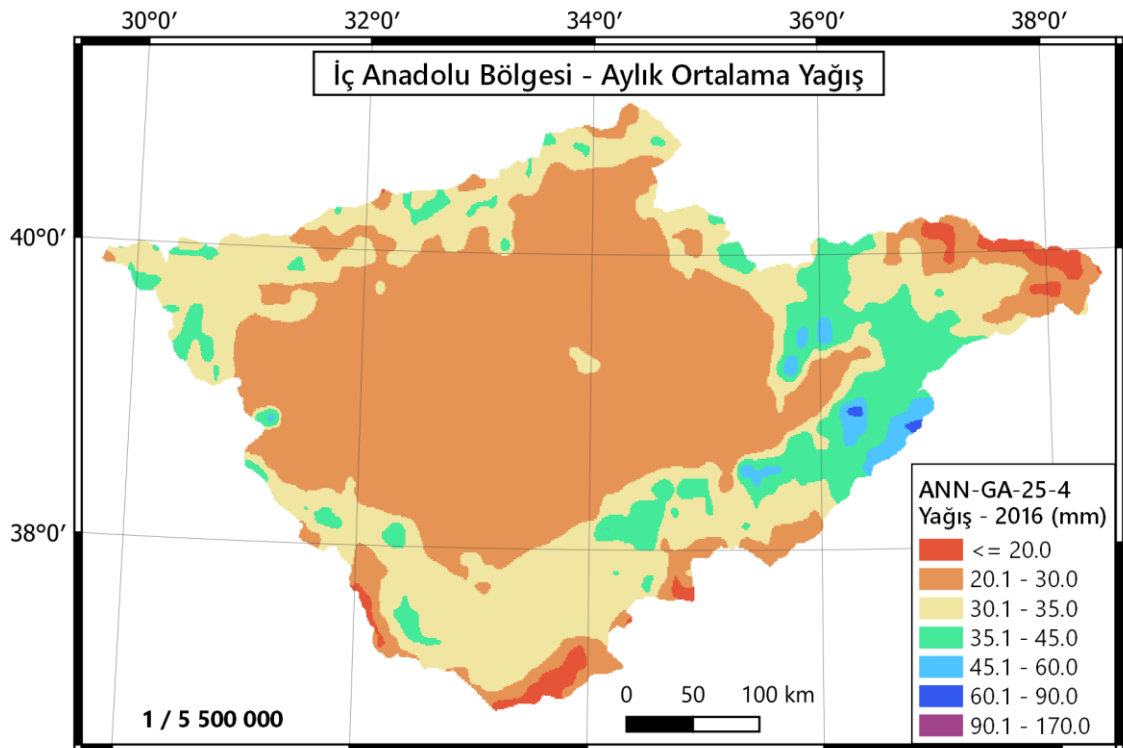
**Şekil 4.11.** En iyi ANN ve ANFIS uygulamasının PSO ve GA ile eğitilmesi bulgularının karşılaştırılması

**Çizelge 4.29.** ANN, ANN-PSO, ANN-GA, ANFIS, ANFIS-PSO, ANFIS-GA uygulamalarının hata büyüklüklerinin karşılaştırılması

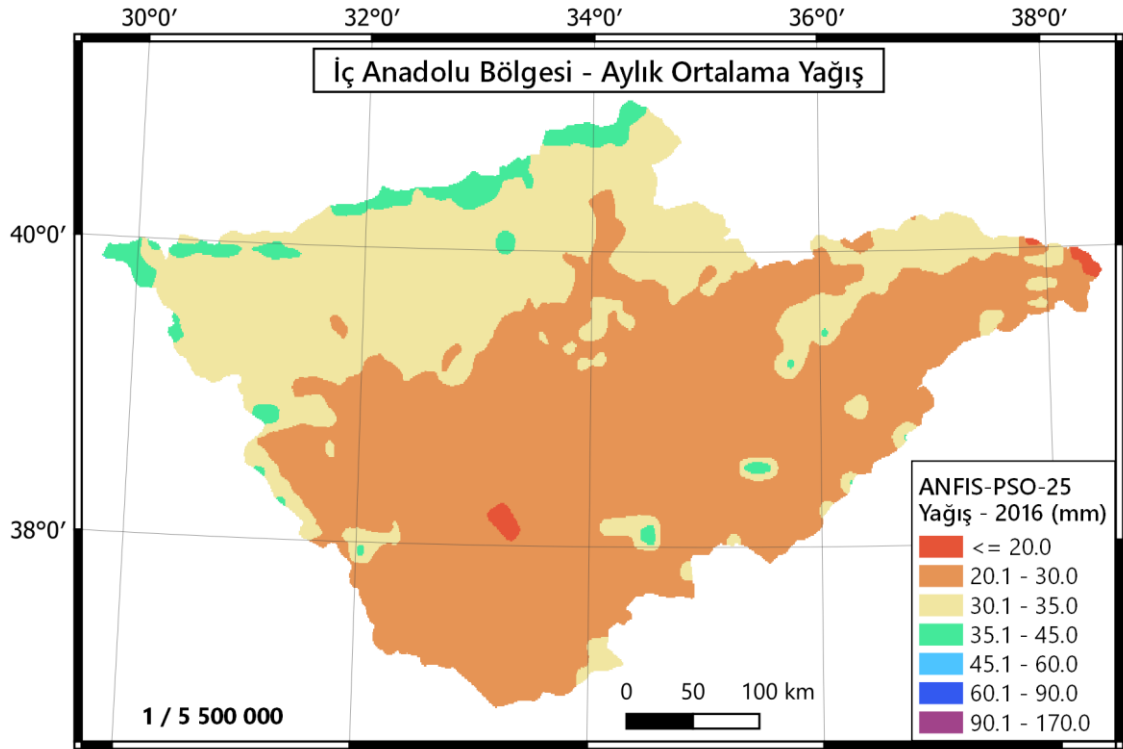
Yöntem	Test KOH ± mm	Maksimum Yağış Ekstrapolasyon Noktası Test Hatası ± mm
ANN (709978)	9.6	9.5
ANN-PSO (PSO-50-2)	12.9	28.5
ANN-GA (GA-25-4)	12.3	37.0
ANFIS (12121617-25H5)	12.7	15.6
ANFIS-PSO (ANFIS-PSO-25)	14.3	48.1
ANFIS-GA (ANFIS-GA-25)	14.8	54.6



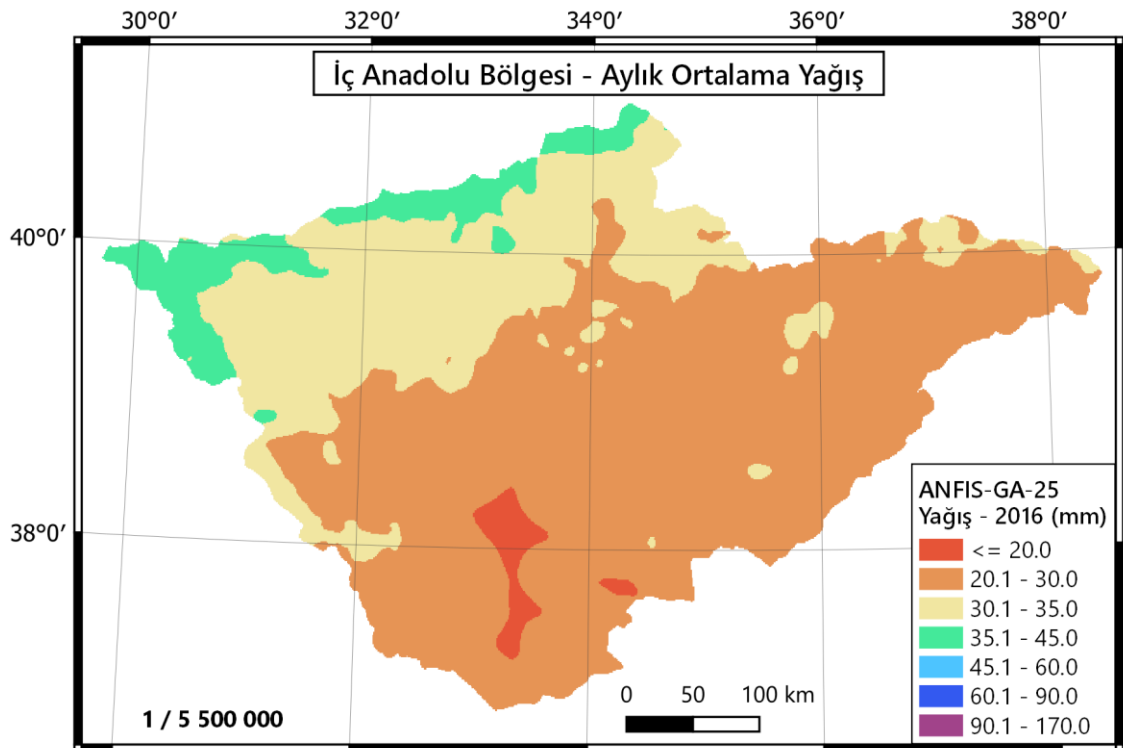
Şekil 4.12. ANN-PSO-50-2 uygulaması ile elde edilen yağış dağılımı tahmini haritası



Şekil 4.13. ANN-GA-25-4 uygulaması ile elde edilen yağış dağılımı tahmini haritası



Şekil 4.14. ANFIS-PSO-25 uygulaması ile elde edilen yağış dağılımı tahmini haritası



Şekil 4.15. ANFIS-GA-25 uygulaması ile elde edilen yağış dağılımı tahmini haritası

#### 4.6. Kriging, CoKriging (COK), Regresyon Kriging (RK) ve Geo-HUSREV

##### Bulguları

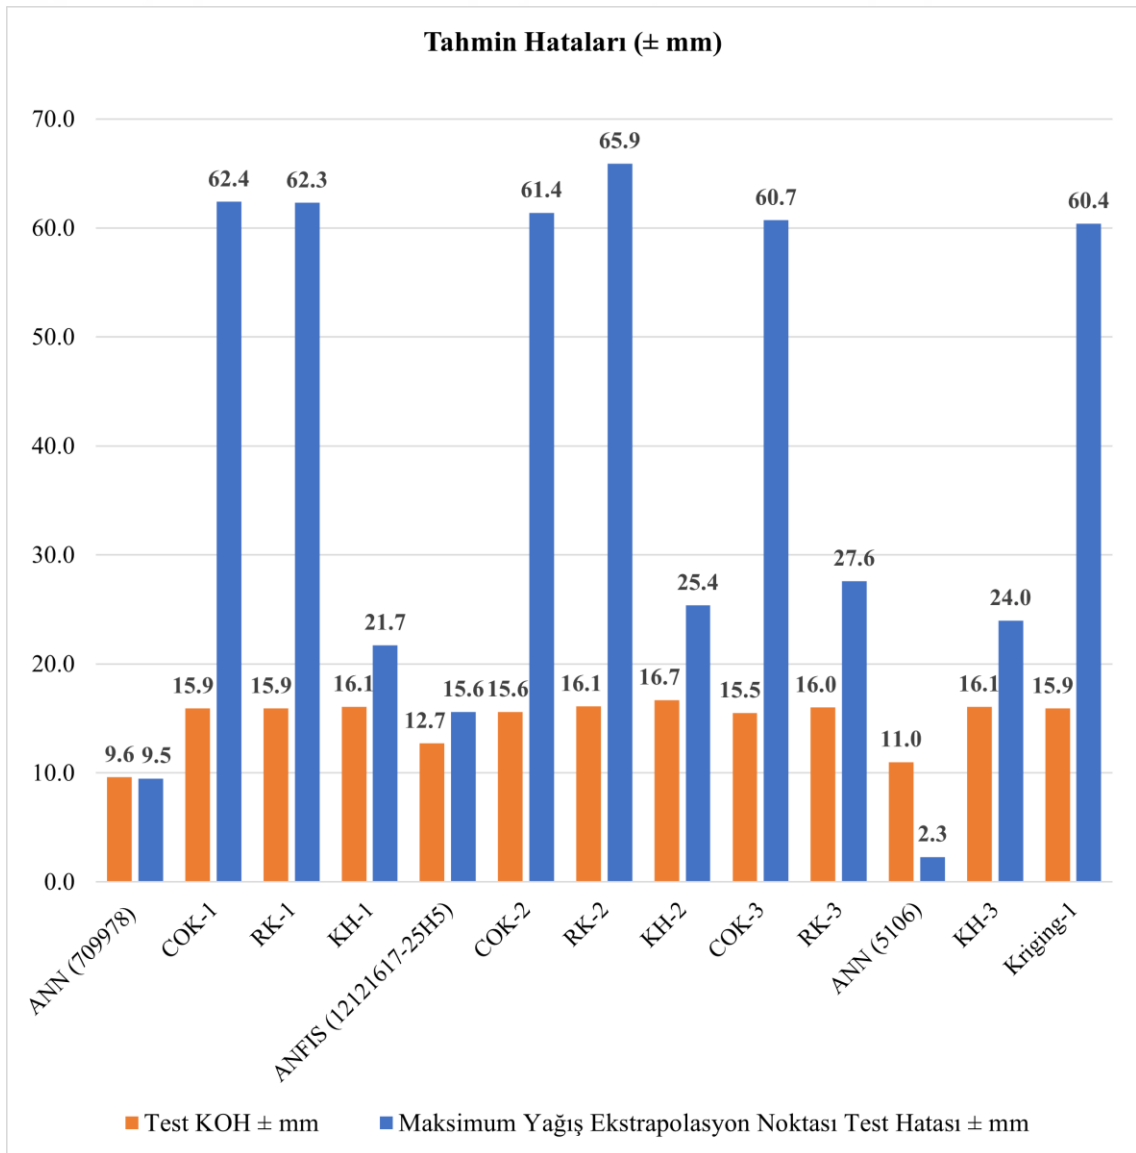
Kriging, COK, RK ve Geo-HUSREV yöntemlerini kullanarak mekânsal tahmin uygulamaları gerçekleştirilmiştir. Kriging yöntemi ile 1 uygulama gerçekleştirilmiş olup COK, RK ve Geo-HUSREV yöntemleri ile 3'er uygulama gerçekleştirilmiştir. İkincil değişkenler kullanarak mekânsal tahminler gerçekleştiren COK, RK ve Geo-HUSREV yöntemleri ile en iyi ANN ve ANFIS uygulamasında kullanılan değişkenler kullanılmıştır. Böylece aynı girdiler kullanılarak yapay zekâ yöntemleri ile diğer yöntemler karşılaştırılmıştır. Ayrıca ANN, COK, RK ve Geo-HUSREV yöntemleri arasında, tek bir ikincil değer kullanarak kıyaslama yapmak için sadece yükseklik değişkeni kullanılarak, COK, RK ve Geo-HUSREV uygulaması gerçekleştirilmiştir. ANN yöntemi için ise Çizelge 4.2.'de uygulama performansları yer alan SCG algoritması ve yükseklik girdisi ile gerçekleştirilen ANN-5106 numaralı uygulama karşılaştırma yapmak için ele alınmıştır. Maksimum yağış alan ekstrapolasyon test noktasının yüksek bir konumda olması nedeniyle yükseklik verisinin COK, RK ve Geo-HUSREV için etkili olabileceği düşünülmüştür. Mekânsal tahminlerin bulguları Çizelge 4.30. ile verilerek incelenmiştir. Bu çalışmada Geo-HUSREV yöntemi ile yapılan uygulamalarda kriging yöntemi ile elde edilen tahminler girdi olarak kullanıldığı için uygulamalara ve kullanılan yaklaşıma Kriging-HUSREV (KH) denilmiştir.

Çizelge 4.31. üzerinde en uygun ANN, ANFIS uygulamaları bulguları ile kriging, COK, RK ve KH uygulamalarının bulguları, karşılaştırılmak üzere verilmiştir. Çizelgede yer alan bilgilere göre en iyi ANN uygulaması ve en iyi ANFIS uygulamasında elde edilen tahmin performansları, COK, RK ve KH yöntemlerinin kullanılması ile elde edilememiştir.

KH yöntemi, kriging, COK ve RK yöntemine göre özellikle maksimum yağış ekstrapolasyon noktasında görülen hatalar bakımından oldukça iyi tahmin bulguları ortaya koymuştur. Kriging-1, COK-1, COK-2, COK-3, RK-1 ve RK-2 uygulamaları maksimum yağış ekstrapolasyon test noktası üzerinde gerçek değer olan yaklaşık 85 mm yağış değerinin çok altında tahmin sonucu üretmesi nedeniyle gerçekliğin temsil edilmesinden çok uzakta tahmin bulguları ortaya koymuştur. RK-3 uygulamasında yükseklik verisinin ikincil girdi olarak kullanımı ile maksimum yağış ekstrapolasyon noktası için biraz daha yüksek yağış değeri elde edilebilmiştir. KH-1, KH-2 ve KH-3

uygulamalarının tamamında maksimum yağış ekstrapolasyon test noktası için diğer tüm kriging uygulamalarına göre daha iyi tahmin performansı elde edilmiştir.

Çizelge 4.31.'de yer alan bulgulara göre KH yöntemi ya da Geo-HUSREV yönteminin sezgisel optimizasyon algoritmalarını kullanarak yapay zekâ yöntemlerinin esası olan öğrenme yapısını etkin bir şekilde kullanması, tahmin bulgularını iyileştirmiştir. Tahmin bulgularında test KOH değerinin KH yöntemlerinde diğer yöntemlere göre biraz daha fazla olması bütüncül bir değerlendirmede dezavantajlı olarak görülebilir ancak gerçekliğin tahminlerde temsil edilmesi adına KH yöntemi diğer kriging yöntemlerine göre oldukça başarılı olmuştur. Şekil 4.16. ile tahmin hataları karşılaştırılmıştır.



**Şekil 4.16.** Belirlenen en iyi yapay zekâ mekânsal tahmin uygulamaları ile kriging, COK, RK ve KH yöntemlerinin tahmin performanslarının karşılaştırılması.

Sadece yükseklik değişkeninin kullanıldığı COK-3, RK-3 ve KH-3 uygulamalarının tahmin performanslarına ait değerler Çizelge 4.30. üzerinde incelendiğinde COK-3 yönteminin sadece komşu noktalara ait yükseklik ve yağış değerlerine göre tahminini gerçekleştirmesinin son derece dezavantajlı olduğu ortaya konmuştur. Maksimum yağış ekstrapolasyon noktası etrafında yüksek yağışlı bir komşu bulunmadığından ve COK-3 yöntemi tahmini yapılan konumun özelliklerini dikkate almadığından bu noktada COK yöntemi de böyle bir çalışmada uygun bir tahmin üretmek için yetersiz kalmıştır.

KH-3 ve RK-3 yöntemi özellikle maksimum yağış ekstrapolasyon test noktasında COK-3 yöntemine göre çok daha iyi bir tahmin performansı ortaya koymuştur. Bunun nedeni RK ve KH yöntemi ile yapılan tahminde, tahmin konumuna ait öznelik verisi tahmin hesabında kullanılmaktadır. Yine de KH-3 ve RK-3 yöntemi ile sadece yükseklik verisi kullanılsa bile maksimum yağış ekstrapolasyon test noktası için ANN ve ANFIS yöntemlerine göre daha başarılı tahmin sonuçları elde edilememiştir.

Denize uzaklık, nem ve basınç girdileri kullanılan RK-1 ve akarsulara uzaklık, nem ve basınç girdileri kullanan RK-2 uygulamaları maksimum yağış ekstrapolasyon noktasında kriging ve COK uygulamalarına benzer şekilde son derece başarısız tahmin performansı ortaya koymuştur. Buna karşı aynı değişkenlerin kullanıldığı KH-1 ve KH-2 uygulaması yine de maksimum yağış ekstrapolasyon noktasında çok daha yüksek bir yağış tahmini gerçekleştirebilmiştir.

Sadece yükseklik değişkeninin kullanıldığı uygulamalar ile karşılaştırma yapmak için ele alınan ANN-5106 numaralı uygulama, yükseklik değişkeni kullanılan KH-3 ve RK-3 uygulamalarına göre daha uygun tahmin performansı bulgularına sahiptir.

Çizelge 4.30.'da bulguları verilen uygulamalar, ANN ve ANFIS yöntemleri ile üretilen yağışların mekânsal tahmin haritalarından daha iyi bir tahmin performansı ortaya koyamamıştır. Kriging, COK ve RK yöntemlerinin uygulamaları eğitim KOH hataları oldukça düşük olsa da test KOH hata değerleri ve karakteristik noktalarda görülen hata değerleri bakımından yapay zekâ yöntemlerine göre yüksek hata değerlerine sahiptir. Diğer kriging uygulamalarından daha iyi tahmin bulgularına sahip olan KH yani Geo-HUSREV uygulamaları ANN ve ANFIS bulgularına daha benzer tahmin sonuçları sağlamıştır.

Şekil 4.17.'de Kriging-1 uygulamasına ait mekânsal tahmin haritası, Şekil 4.18.'de COK-1, Şekil 4.19.'da COK-2, Şekil 4.20.'de COK-3, Şekil 4.21.'de RK-1,

Şekil 4.22.'de RK-2, Şekil 4.23.'de RK-3, Şekil 4.24.'de KH-1, Şekil 4.25.'de KH-2, ve Şekil 4.26.'da KH-3 haritası verilmiştir.



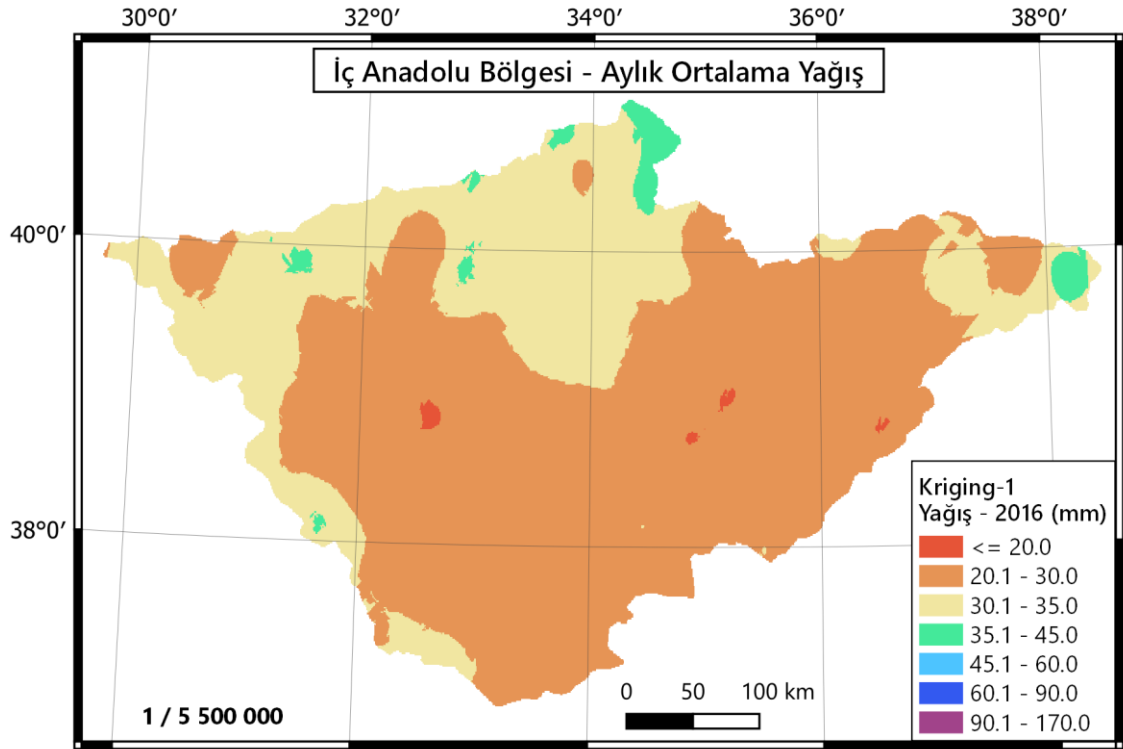


Çizelge 4.30. Kriging, COK, RK ve KH uygulamalarına ait tahmin performansı bulguları

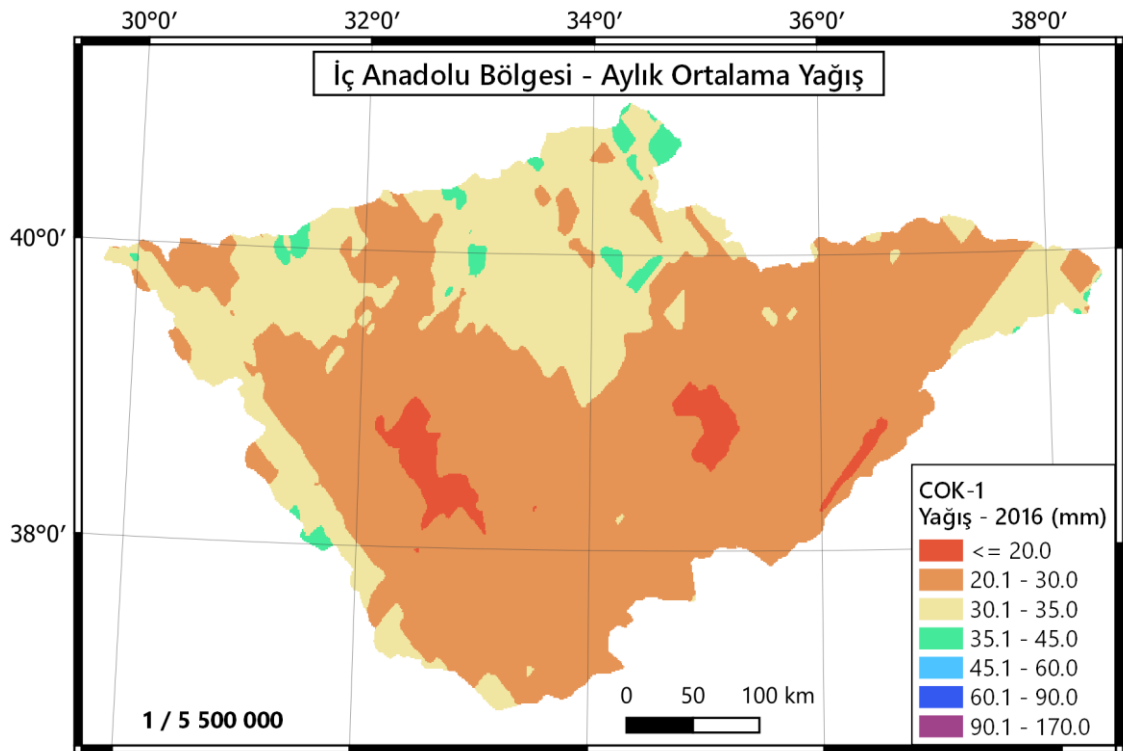
Çizelge Sıra	Test KOH ± mm	Eğitim KOH ± mm	Eğitim R	Test R	Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik	Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	Yöntem	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi	Yöntem NO
1	15.9	6.2	0.8	0.1	7.0	35.1	60.4	8.3	8.8	14.7	4.4	18.1	10.4	8.1	Kriging	-	-	-	-	-	Kriging-1
2	15.9	8.1	0.6	0.1	8.7	33.1	62.4	8.6	2.0	14.9	4.9	21.0	10.1	7.7	COK	D.U.	Nem	Bas.	-	-	COK-1
3	15.6	4.7	0.9	0.0	7.8	32.8	61.4	8.8	2.7	15.6	4.1	18.8	9.9	7.2	COK	A.U.	Nem	Bas.	-	-	COK-2
4	15.5	0.5	1.0	0.0	6.6	32.2	60.7	9.8	3.5	16.5	3.3	17.2	10.0	6.4	COK	Yük.	-	-	-	-	COK-3
5	15.9	9.9	0.4	0.3	1.6	27.2	62.3	12.7	11.3	22.4	0.9	18.0	10.4	3.8	RK	D.U.	Nem	Bas.	-	-	RK-1
6	16.1	7.8	0.6	0.2	2.9	32.9	65.9	8.0	6.3	17.3	4.2	19.0	9.7	7.6	RK	A.U.	Nem	Bas.	-	-	RK-2
7	16.0	12.5	0.1	0.2	9.4	15.5	27.6	27.0	38.2	29.9	1.9	13.0	13.4	4.8	RK	Yük.	-	-	-	-	RK-3
8	16.1	15.6	0.4	0.2	14.0	12.5	21.7	28.9	28.5	28.2	0.5	14.6	14.5	11.5	KH	D.U.	Nem	Bas.	-	-	KH-1
9	16.7	7.9	0.7	0.1	20.8	26.5	25.4	24.8	35.8	25.1	1.3	10.8	14.3	8.4	KH	A.U.	Nem	Bas.	-	-	KH-2
10	16.1	10.2	0.4	0.2	20.9	22.2	24.0	22.6	31.4	25.2	0.3	18.9	13.8	13.8	KH	Yük.	-	-	-	-	KH-3

Çizelge 4.31. Kriging, COK, RK, KH, ANN ve ANFIS bulgularının karşılaştırılması

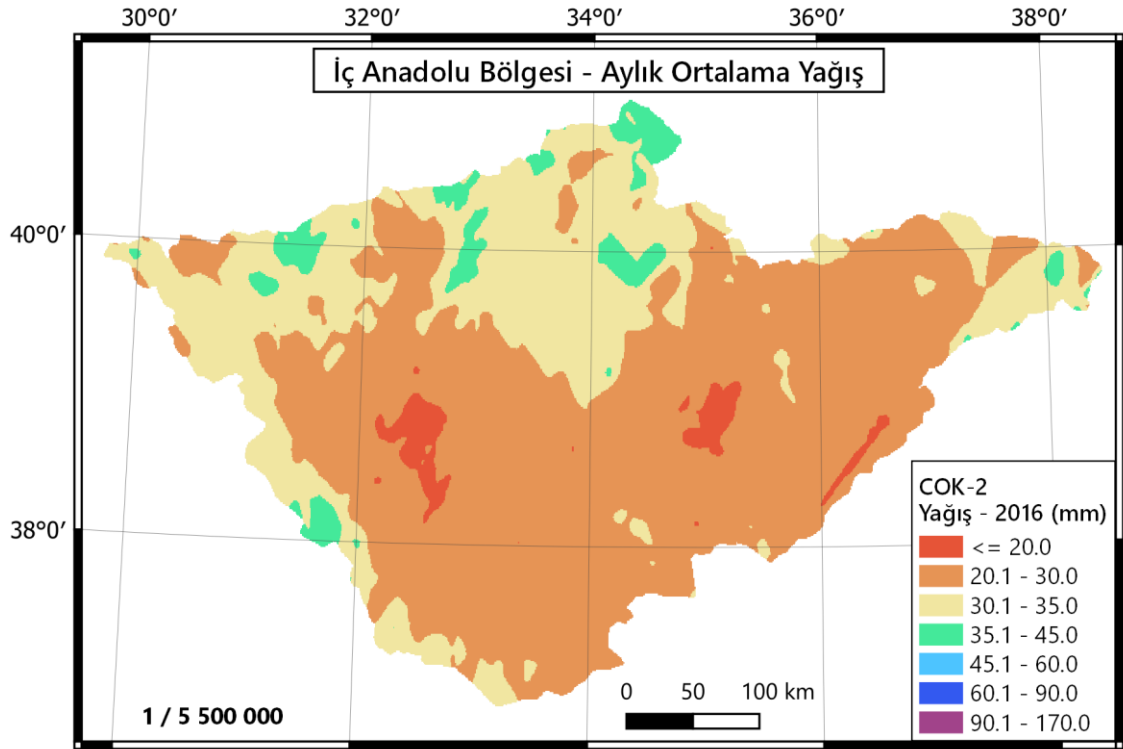
Çizelge Sıra No	Yöntem No	Test KOH ± mm	Eğitim KOH ± mm	Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik	Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm	1. Girdi	2. Girdi	3. Girdi	4. Girdi	5. Girdi
Çizelge 4.5.-1	ANN (709978)	9.6	7.3	0.1	21.9	9.5	2.6	9.2	9.6	0.1	22	8.9	4.1	D.U.	Nem	Bas.	-	-
Çizelge 4.30.-2	COK-1	15.9	8.1	8.7	33.1	62.4	8.6	2	14.9	4.9	21	10.1	7.7	D.U.	Nem	Bas.	-	-
Çizelge 4.30.-5	RK-1	15.9	9.9	1.6	27.2	62.3	12.7	11.3	22.4	0.9	18	10.4	3.8	D.U.	Nem	Bas.	-	-
Çizelge 4.30.-8	KH-1	16.1	15.6	14.0	12.5	21.7	28.9	28.5	28.2	0.5	14.6	14.5	11.5	D.U.	Nem	Bas.	-	-
Çizelge 4.19.-4	ANFIS (12121617-25H5)	12.7	5.9	12.5	31.8	15.6	7	1.8	7.8	3.9	16.8	12.4	4.4	En.	Boy.	A.U.	Nem	Bas.
Çizelge 4.30.-2	COK-2	15.6	4.7	7.8	32.8	61.4	8.8	2.7	15.6	4.1	18.8	9.9	7.2	A.U.	Nem	Bas.	-	-
Çizelge 4.30.-6	RK-2	16.1	7.8	2.9	32.9	65.9	8	6.3	17.3	4.2	19	9.7	7.6	A.U.	Nem	Bas.	-	-
Çizelge 4.30.-9	KH-2	16.7	7.9	20.8	26.5	25.4	24.8	35.8	25.1	1.3	10.8	14.3	8.4	A.U.	Nem	Bas.	-	-
Çizelge 4.2.-14	ANN (5106)	11.0	8.9	2.4	25.4	2.3	5.5	4.6	19.6	0.4	19	10.5	6.2	Yük.	-	-	-	-
Çizelge 4.30.-4	COK-3	15.5	0.5	6.6	32.2	60.7	9.8	3.5	16.5	3.3	17.2	10	6.4	Yük.	-	-	-	-
Çizelge 4.30.-7	RK-3	16.0	12.5	9.4	15.5	27.6	27	38.2	29.9	1.9	13	13.4	4.8	Yük.	-	-	-	-
Çizelge 4.30.-10	KH-3	16.1	10.2	20.9	22.2	24.0	22.6	31.4	25.2	0.3	18.9	13.8	13.8	Yük.	-	-	-	-
Çizelge 4.30.-1	Kriging-1	15.9	6.2	7	35.1	60.4	8.3	8.8	14.7	4.4	18.1	10.4	8.1	-	-	-	-	-



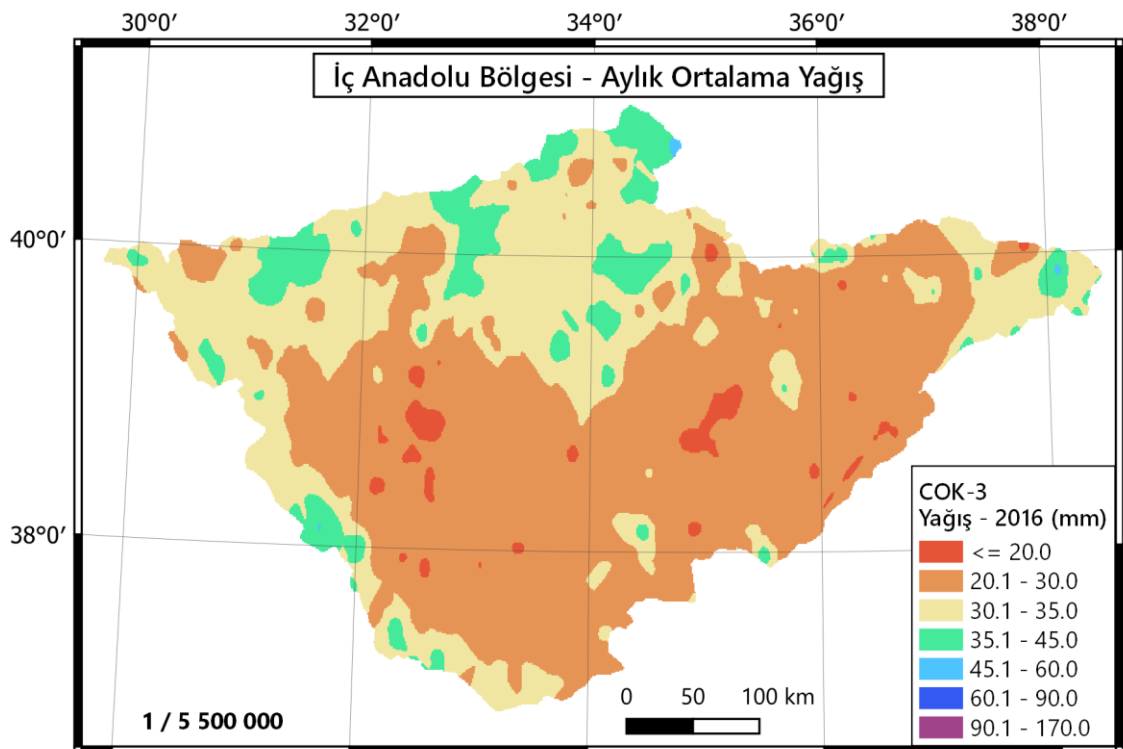
Şekil 4.17. Kriging-1 uygulaması ile elde edilen yağış dağılımı tahmini haritası



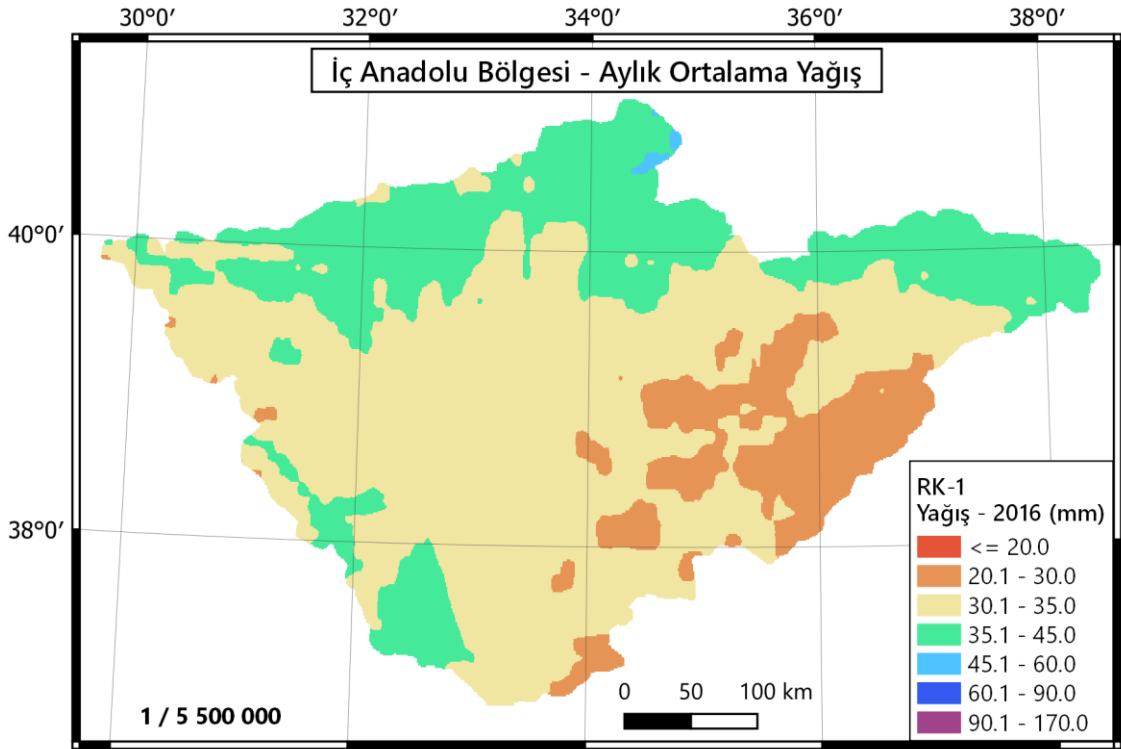
Şekil 4.18. COK-1 uygulaması ile elde edilen yağış dağılımı tahmini haritası



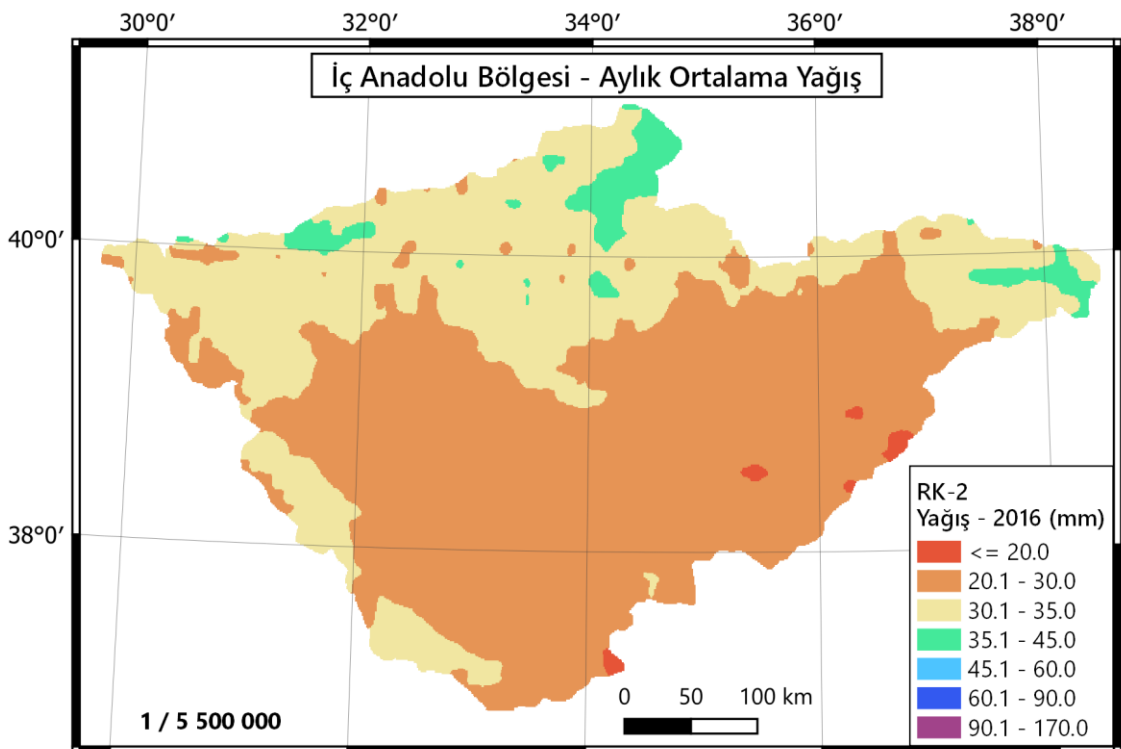
Şekil 4.19. COK-2 uygulaması ile elde edilen yağış dağılımı tahmini haritası



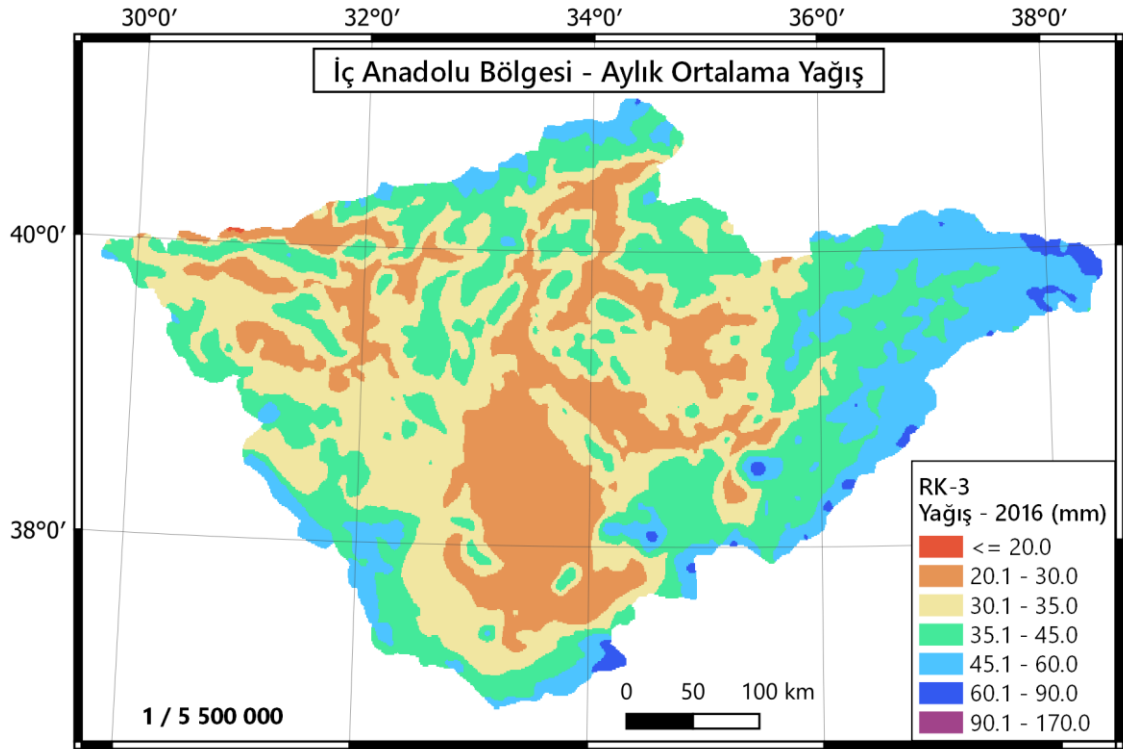
Şekil 4.20. COK-3 uygulaması ile elde edilen yağış dağılımı tahmini haritası



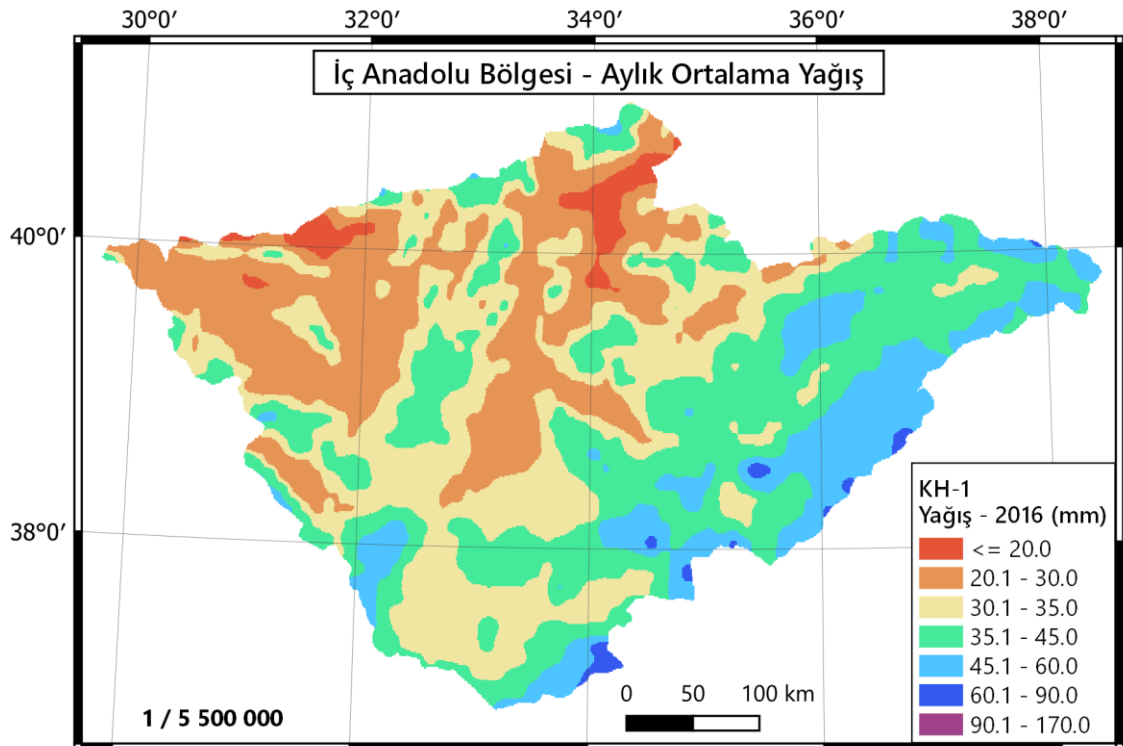
Şekil 4.21. RK-1 uygulaması ile elde edilen yağış dağılımı tahmini haritası



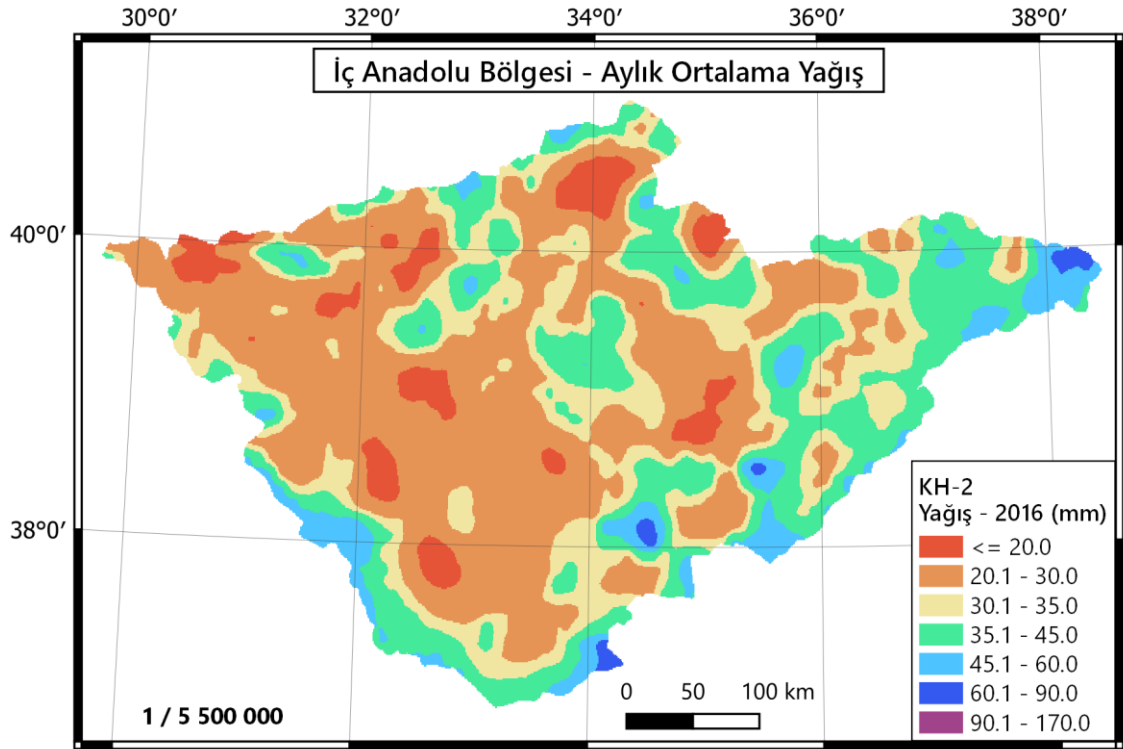
Şekil 4.22. RK-2 uygulaması ile elde edilen yağış dağılımı tahmini haritası



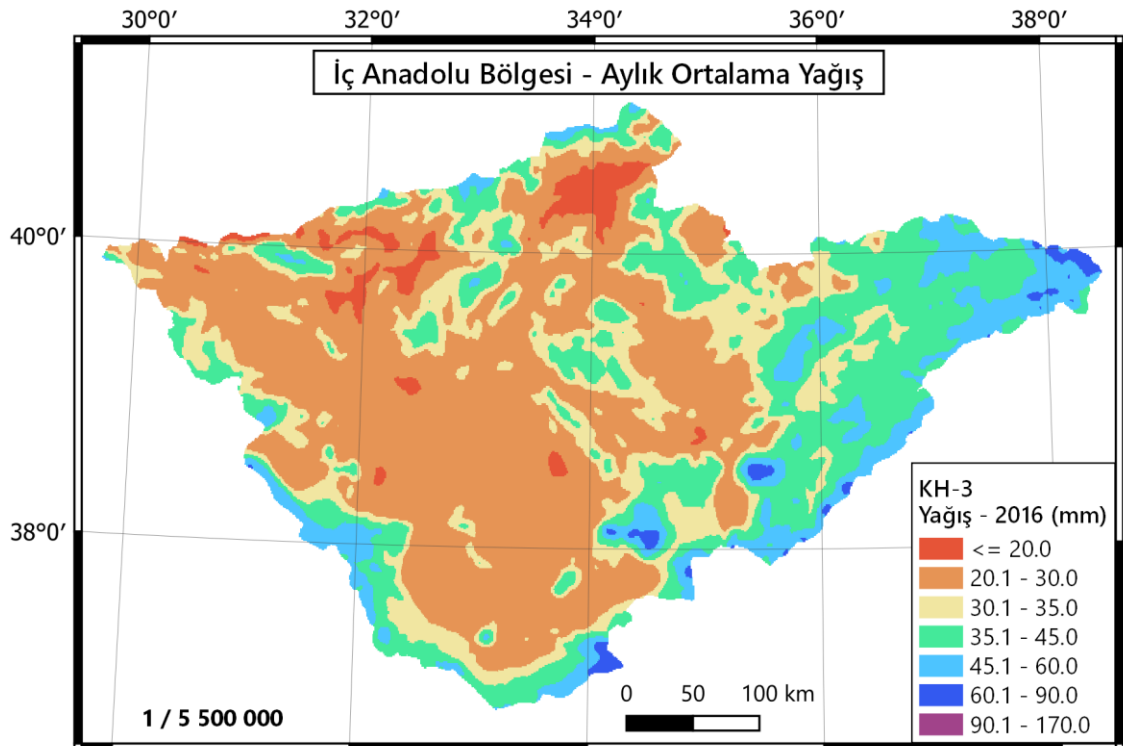
Şekil 4.23. RK-3 uygulaması ile elde edilen yağış dağılımı tahmini haritası



Şekil 4.24. KH-1 uygulaması ile elde edilen yağış dağılımı tahmini haritası



Şekil 4.25. KH-2 uygulaması ile elde edilen yağış dağılımı tahmini haritası



Şekil 4.26. KH-3 uygulaması ile elde edilen yağış dağılımı tahmini haritası

#### 4.7. Tartışma

Tez çalışması kapsamında test hataları ve diğer performans değerlendirmelerine göre yapay zekâ yöntemlerinin yağış haritaları için mekânsal tahmin başarıları incelenmiştir. Kriging yöntemleri veya benzer yakınlık-benzerlik temelli yöntemlere göre bu yöntemlerin avantajları ortaya konmuştur. Test KOH değerlerinin yanında, karakteristik noktalardan maksimum yağış ekstrapolasyon noktası, değerlendirmelerde en belirleyici nokta olmuştur. Bunun nedeni tahmin haritalarının taşkın, sel gibi konularda duyarlılık ve risk haritalarında kullanılmasıdır. Yüksek yağış alan ve istasyon noktası bulunmayan bir konum için yağışların temsil edilemediği bir tahmin haritası sonraki analizler için yanıltıcı bir altlık olarak kullanılabilir. Böyle bir durum çeşitli konularda yanlış kararların alınmasına neden olacaktır. Oldukça düşük test ve eğitim KOH değerlerine sahip uygulamalar bu çalışmada en uygun tahmin uygulamaları olarak değerlendirilmemiştir. KOH değerlerinin yanında karakteristik test noktalarında görülen tahmin değerleri ile gerçek değerler de karşılaştırılmıştır. Tahmin performanslarının değerlendirilmesinde sadece KOH değerlerinin kullanılması, çeşitli noktalarda görülen önemli hata değerlerinin, ortalama bir hata göstergesi üzerinde fark edilmemesine neden olabilir. KOH gibi hata büyüklükleri ile performans değerlendirmesi yapmanın diğer bir dezavantajı ise değerlendirmenin mekândan bağımsız olarak yapılmasıdır. Bu tez çalışmasında görüldüğü gibi, çeşitli karakteristik noktalar, buldukları konuma bağlı özelliklere göre değişen tahmin hatalarına sahiptir. Örneğin kriging yöntemleri, Erciyes Dağı üzerinde yer alan maksimum yağış ekstrapolasyon test noktası için gerçeğin çok altında yağış tahmin değerleri hesaplamıştır. Buna karşın bu uygulamalarda test ve eğitim KOH değerleri yüksek değildir. Çünkü o noktada görülen yüksek hata, diğer önemli olmayan noktaların hata değerleri ile ortalama bir göstergede belirsiz bir hale gelmiştir. Bu çalışmada hata değerlerinin mekânsal özelliği de dikkate alınacak şekilde karakteristik test noktalarından faydalanılmıştır. Böylece kullanılan yöntemlerin aslında ne kadar farklı sonuçlara sahip olduğu ortaya konmuştur. Bu durum, maksimum yağış alan ekstrapolasyon noktasının üzerinde Kriging-1, COK-1, COK-2, COK-3, RK-1, RK-2 yöntemleri ile üretilen sırasıyla Şekil 4.17., Şekil 4.18., Şekil 4.19. Şekil 4.20., Şekil 4.21. ve Şekil 4.22. ile verilen tahmin haritalarında açıkça görülmektedir. Bu haritalarda ilgili nokta için gerçek yağış değeri olan yaklaşık 85 mm yağış değeri karşısında 20-25 mm yağış değeri temsil edilmiştir. Bu haritalar için kullanılan yöntemlerin KOH değerleri düşük ve iyi olarak yorumlanabilse de bu haritalar afetler ile ilgili risk, duyarlılık gibi



çalışmalarda altlık olarak kullanılmaya uygun değildir. En yüksek yağışın beklendiği bir konumda meydana gelen bu derece düşük tahmin değerleri, bu haritaların ve yöntemlerin çalışma bölgesi için başarısız olarak değerlendirilmesi için yeterli olmuştur. Bu yöntemler diğer karakteristik noktalarda iyi tahmin bulgularına sahip olabilseler de yanıtıcı analizlere neden olabilecek önemli farklılıklar kabul edilemez boyuttadır.

Çalışmada incelenen uygulamalardan kriging, COK ve RK yöntemlerinin Matheron'un (1963) bölgeselleştirilmiş değişkenler teorisi ve Tobler'in (1970) yakın olan objelerin uzak olan objelere daha benzer olduğunu belirttiği coğrafya kanununa göre mekânsal tahmin metodolojisi izlemesi, bu çalışmada avantajlı bir yol olmamıştır. En iyi lineer ve yansız tahminci olarak bilinen kriging yöntemleri birçok çalışmada en uygun yöntem olarak değerlendirilir ve kullanımı oldukça yaygındır. Kriging yöntemleri ile uygun tahminlerin gerçekleştirilebilmesi için mekânsal otokorelasyon, durağanlık ve normal dağılım varsayımlarının sağlanması ön şarttır. Ancak gerçek yeryüzü çoğunlukla karmaşık ve lineer olmayan bir doğaya sahiptir. Çalışma alanında ele alınan meteoroloji istasyon değerleri ve bu noktaların konumlarına ait özellikler de bunu göstermektedir.

İncelenen yöntemler bakımından elde edilen bulgular ile de desteklendiği gibi, ANN, ANFIS, RK ve Geo-HUSREV yöntemlerinin tahmini yapılan konuma ait öznelikleri, tahminler için kullanması bu yöntemlerin kriging ve COK yöntemine göre çalışma alanında daha avantajlı olduğunu göstermektedir. Buna karşın RK yönteminin birden fazla ikincil değer ile uygulandığı çalışmalarda uygun tahmin performansı gözlemlenmemiştir. RK yöntemi de kriging yöntemi temeline dayanır ve komşu nokta ve yakınlık-benzerlik ilişkisinden faydalanır. Geo-HUSREV yöntemi kapsamında gerçekleştirilen KH uygulamaları diğer kriging uygulamalarına göre daha başarılı tahmin performansına sahiptir.

Geo-HUSREV yöntemi ile gerçekleştirilen KH uygulamalarında, yöntemin metodolojisi sayesinde ikincil değişkenler ve yağış değerleri arasında ABC algoritması kullanılarak bir öğrenme modeli ortaya konmuştur. Bu sayede tahmini yapılan konumun öznelikleri dikkate alınırken girdi olarak kriging tahmin değerlerinin avantajlarından da faydalanılmaktadır. Yapay zekâ yöntemleri ile öğrenme süreci ve model oluşturmak için genellikle çok sayıda parametrenin hesaplanması gerekir. Bu durum yapay zekâ çalışmalarında çok sayıda örneğe ihtiyaç duyulmasına neden olur. Daha az sayıda veriye sahip olunan uygulamalarda hem jeostatistik yöntemlerinin tahmin becerisinin hem de yapay zekâ optimizasyon algoritmalarının öğrenme becerisinin kullanılması ile Geo-HUSREV yöntemi daha az sayıda parametrenin hesaplanmasını sağlayabilir. Böylece

çeşitli uygulamalarda Geo-HUSREV yöntemi yapay zekâ uygulamalarına göre daha avantajlı bir yaklaşım olabilir. Geo-HUSREV yöntemi kullanıcı tanımlı bir fonksiyona bağlı olarak, ele alınan konu için çapraz değerlendirme, doğrulama yaklaşımları ile mekânsal tahmin gerçekleştirmektedir. Kullanıcı konuya uygun bir tahmin fonksiyonu geliştirerek karmaşık ya da basit bir tahmin modeli için parametrelerin hesaplanmasını sağlar. Bu çalışmada Geo-HUSREV yöntemi yapay zekâ uygulamalarına benzer bulgular göstermiş olup, ANN ve ANFIS yöntemleri ile gerçekleştirilen en iyi uygulama bulgularından sonra en iyi bulgulara sahiptir. Yöntemin çalışmada kullanılan diğer kriging yöntemlerine göre tahmin başarısının daha iyi olduğu gözlemlenmiştir. KH yöntemi maksimum yağış ekstrapolasyon noktasında ANN ve ANFIS yöntemleri kadar yüksek yağış değerleri tahmin edemese de RK, COK ve kriging yöntemlerine göre gerçek değere daha çok yaklaşmıştır. RK yöntemine göre farklı girdilerin kullanımı ile de benzer bulguları üretmiştir. RK-1 ve RK-2 uygulamaları COK uygulamalarına benzer tahmin haritalarına sahiptir. KH yöntemi ile özellikle maksimum yağış ekstrapolasyon noktası için daha uygun tahmin bulguları sağlanmıştır. KH-1, KH-2 ve KH-3 uygulamaları ile sırasıyla Şekil 4.24., Şekil 4.25., Şekil 4.26. ile verilen tahmin haritalarının yağış dağılımı doku, ANN ve ANFIS yöntemleri ile elde edilen sırasıyla Şekil 4.5. ve Şekil 4.10. ile verilen mekânsal tahmin haritaları dokularına benzerdir.

Çalışmada yapay zekâ yöntemlerinden ANN ve ANFIS yöntemi en uygun mekânsal tahmin performansı göstergelerine sahiptir. Çalışmanın en iyi uygulaması olarak bilinen ANN-709978 uygulaması, LM algoritması ve iki gizli katmandan oluşan bir sinir ağı yapısı kullanılarak gerçekleştirilmiştir. Uygulamanın girdileri olarak denize uzaklık, nem ve basınç değişkenleri kullanılmıştır.  $\pm 9.6$  mm test KOH değeri ve  $\pm 7.3$  mm eğitim KOH değeri ile en düşük KOH değerlerine sahip uygulama olmuştur. Diğer karakteristik noktalar için de diğer yöntemlere göre iyi bulgulara sahip olan uygulama maksimum yağış ekstrapolasyonu için de başarılı bir tahmin ortaya koymuştur. Bu noktada tahmin hatası  $\pm 9.5$  mm olarak gözlemlenmiştir. ANFIS-2121617-25H5 uygulaması ile de ANN-709978 uygulamasından sonra en uygun tahmin performansı bulguları elde edilmiştir. Enlem, boylam, akarsulara uzaklık, nem ve basınç girdileri kullanılmıştır. Eğitim için hibrit eğitim algoritması kullanılan uygulama lineer çıktı yapısına sahip bulanık çıkarım sisteminden oluşmaktadır. Bu uygulamada minimum yağış test noktası, maksimum yağış ekstrapolasyon noktası, maksimum yükseklik ekstrapolasyon noktası için uygun yağış tahmini gerçekleştirilirken maksimum yağış test noktası için yüksek tahmin hatası gözlemlenmiştir. Bu uygulama, ANN-709978

uygulamasından sonra en uygun ANFIS uygulaması olarak belirlenmiştir. Test ve eğitim KOH değerleri ile maksimum yağış ekstrapolasyon hatası sırasıyla  $\pm 12.7$  mm,  $\pm 5.9$  mm ve  $\pm 15.6$  mm'dir.

ANN yöntemi ile farklı girdi sayıları, LM algoritması ve SCG algoritması ile gerçekleştirilen uygulamalardan seçilen en iyi uygulamalar bir arada değerlendirildiğinde genellikle LM algoritmasının daha uygun tahmin bulgularına sahip olduğu gözlemlenmiştir. Şekil 4.1. ile eğitim algoritmaları arasındaki ortalama hata farkları temsil edilmiştir. Ayrıca ANN yöntemi için incelenen katman sayısı ve nöron sayısı bakımından en iyi uygulamaların büyük çoğunluğunun çift gizli katmandan oluşan ağ yapıları ile gerçekleştirildiği gözlemlenmiştir. Her bulgu setinden seçilen en iyi uygulamalar incelendiğinde sayılarının her katman için maksimum nöron sayısı olarak belirlenen 20 nöron sayısına ulaşmadığı görülmektedir. İki gizli katman ve her katmanda 20 nörona kadar olan sinir ağı yapılarının bu çalışmada uygun ve yeterli olabileceği görülmektedir. COK, RK ve KH yöntemleri ile bulgularını karşılaştırmak üzere ele alınan, sadece yükseklik girdisi kullanılan ANN-5106 yöntemi ile de uygun tahmin bulguları elde edilmiştir. ANN-5106 yöntemi, SCG yöntemi ile eğitilmiştir.

ANFIS yöntemi ile gerçekleştirilen uygulamalardan her girdi seti ve kullanılan eğitim algoritmasına göre seçilen en iyi uygulamaların değerlendirilmesi ile, kullanılan eğitim algoritmalarından hibrit eğitim algoritmasının GY algoritmasına göre daha başarılı tahmin sonuçlarına sahip olduğu gözlemlenmiştir. Girdi sayısı bakımından en iyi uygulama 5 girdili ANFIS uygulaması ile gerçekleştirilmiştir. Şekil 4.6. ile de gösterildiği gibi, girdi sayıları ve öğrenme algoritmalarına göre 2, 3 ve 5 girdili, hibrit eğitim algoritması kullanılan ANFIS uygulamaları daha başarılı tahmin bulgularına sahiptir. Bulanık çıkarım sistemi çıktı yapısı lineer ve sabit yapıli çıkarım sistemleri için uygulamalar yapılmıştır. Hangi çıktı yapısının daha uygun bulgulara sahip olduğu incelenmiştir. Elde edilen bulgulara göre bu çalışmada lineer çıktı yapıli bulanık çıkarım sistemleri ile daha başarılı tahmin bulguları elde edilmiştir. En iyi ANFIS uygulamaları genellikle 3, 4 ve 5 üyelik fonksiyonu kullanımı ile gerçekleştirilmiştir. ANFIS uygulamaları için FCM kümeleme yönteminin kullanılması ile hesaplanması gereken parametre sayısının azaltılması sağlanmıştır. Bu yaklaşım tahmin performansının artmasını sağlamıştır.

ANN ve ANFIS uygulamalarında en iyi uygulamalara ait parametre sayıları ve girdi sayıları, gerçekleştirilen uygulamalara göre fazla sayıda hesap gerektiren uygulamalardandır. Yağışların mekânsal dağılımının haritalanmasında bir girdi veya iki

girdili uygulamalar yerine 3, ve 5 girdili uygulamaların, tek gizli katman yerine iki gizli katman kullanılması, sabit çıktılı bulanık çıkarım sistemi yerine lineer bulanık çıkarım sistemi kullanılması gibi özellikler, hesaplanacak daha fazla parametreye işaret etse de iyi tahminler için tek girdili, tek katmanlı uygulamalar gibi daha basit uygulamalar yerine daha gelişmiş tahmin süreçlerinin daha etkili olduğu görülmüştür.

ANN ve ANFIS yöntemleri ile gerçekleştirilen uygulamalardan her girdi sayısı ve eğitim algoritmasına göre belirlenen en iyi tahmin performansına sahip uygulamalar incelendiğinde tahmin performanslarına en çok katkı sağlayan değişkenlerin ilk olarak nem, basınç, denize uzaklık ve sıcaklık girdileri olduğu görülmüştür. Daha sonra ise akarsulara uzaklık, bakı ve yükseklik değişkenleri kullanılmıştır. GPM, eğim ve göllere uzaklık değişkenleri en iyi uygulamalar için sıklıkla kullanılan değişkenler olmamıştır. Yakınlık-benzerlik ilişkisini temsil edebilecek nitelikte olan enlem, boylam ve en yakın komşu değerleri tahmin performansları üzerinde önemli bir etkiye sahip olmayıp en iyi uygulamalar arasında en az kullanılan değişkenler olmuştur. Oysaki bu değişkenler kriging tahminleri için temel olarak kullanılan unsurlardır. Özellikle en iyi tahminlerde en yakın komşu nokta girdilerinin yer almaması, mekânsal tahmin çalışmalarında sadece Tobler'in (1970) yakın objelerin uzak olan objelere göre daha benzer olduğu kanunu temelinde metodoloji izlemenin uygun olmayabileceğini göstermiştir. En yakın komşu değerlerinin sadece ortalama yağış test noktası üzerinde ayırt edici olumlu bir etkisi olduğu gözlemlenmiştir. Komşu değerler kriging yöntemlerinde olduğu gibi tahminlerin başarısızlığına neden olmuş olabilir. Komşuluk mekânsal tahminlerde önemli bir rol oynamaktadır çünkü yakınlık benzerlik temelini uygulanması için komşu değerlere ihtiyaç duyulur. Bu çalışmada yakınlık-benzerlik temeline dayalı tahminler için gerekli olan en yakın komşu değerleri ile en uygun yağış haritaları elde edilmemiştir. Bu çalışmaya benzer şekilde, Sekulić ve ark. (2020) ve Mariano ve Monica (2021) çalışmalarında komşu sayısının artması durumunda tahmin performanslarının düştüğünü belirtmiştir.

ANN-PSO, ANN-GA, ANFIS-PSO ve ANFIS-GA uygulamaları ile en uygun ANN ve ANFIS uygulamaları ile aynı girdiler kullanılarak yapay zekâ tahminlerinin klasik eğitim algoritmaları yerine sezgisel optimizasyon algoritmaları yardımıyla eğitilmesi araştırılmıştır. Bu algoritmaların lokal minimuma takılmama başarısı gibi avantajları nedeni ile daha başarılı tahmin bulguları sağlaması beklenmiştir. Ancak elde edilen bulgulara göre her iki optimizasyon algoritması ile de tahmin bulgularının iyileştirilmesi sağlanamamıştır. Chen ve ark. (2019) ve Taghizadeh-Mehrjardi ve ark.

(2021) çalışmalarında ANN ve ANFIS uygulamaları için sezgisel algoritmaların kullanımının tahminleri geliştirdiği sonucuna varılmıştır. Bu nedenle bu çalışma ve sonraki çalışmalar için böyle bir yaklaşımın uygulanmasında optimizasyon parametrelerinin deneysel olarak uygun şekilde belirlenmesi ve yeni uygulamaların gerçekleştirilmesi önemlidir.

Geo-HUSREV yöntemi ile geliştirilecek jeostatistik analiz yöntemi bakımından kriging yöntemi kullanılmıştır. Bu nedenle gerçekleştirilen Geo-HUSREV uygulamalarına KH denilmiştir. Yöntemin sezgisel optimizasyon bileşeni tarafında ise ABC algoritması kullanılmıştır. Uygulamalarda sezgisel öğrenme süreci için bir bloğu çıkar (Leave one block out) çapraz değerlendirme yaklaşımı kullanılarak optimizasyon süreci gerçekleştirilmiştir. Bu yaklaşıma göre belirlenen her blok ya da veri kümesi dışarıda bırakılarak diğer bloklardan ya da kümelerden faydalanılarak dışarıda bırakılan küme en iyi şekilde tahmin edilmeye çalışılır. Bunun için tüm kümelere uygun en iyi tahmini sağlayabilecek parametreler lokal veya global parametreler olmak üzere ABC algoritması ile bulunur. Kümeleme çalışması ile kümeleri belirlemek için k-ortalama yöntemini kullanılmıştır. Veri seti her KH uygulaması için kullanılan girdilere göre kümelendirilmiştir. Örneğin KH-3 uygulamasında yükseklik girdisi kullanılmıştır ve veriler yüksekliklerine göre kümelere ayrılmıştır. En yüksek noktalardan oluşan kümeyi tahmin etmek için diğer kümelerin noktaları ve optimizasyon parametreleri kullanılmıştır. Bu yaklaşım tüm kümeler için tekrar edilerek optimum parametreler iteratif olarak bulunmuştur.

Geo-HUSREV yönteminin kullanımında girdi olarak kullanılacak jeostatistik analiz yöntemi ve sezgisel optimizasyon algoritması, tahmin performansı için etkili olacaktır. Kullanıcı tarafından tasarlanan maliyet ve tahmin fonksiyonu da yöntemin başarısı üstünde doğrudan etkilidir. Ayrıca çapraz değerlendirme yaklaşımının kullanıcı tarafından belirlenmiş şekli de tahmin performansı üzerinde etkilidir.

Bu çalışmada KH-3 uygulaması için veri seti, yüksekliklerine göre bloklara/kümelere ayrılmıştır. Benzer olarak kümeleme, noktaların konumlarına göre veya yağış değerlerine göre de yapılabilir ve burada kullanılan yaklaşım ve küme sayısı, tahmin performansı üzerinde etkilidir. Bu nedenle Geo-HUSREV yöntemi için sonraki çalışmalarda seçilecek jeostatistik analiz yöntemi, optimizasyon algoritması, maliyet ve tahmin fonksiyonunun belirlenmesi, kümeleme yaklaşımları ve çapraz değerlendirme stratejileri bakımından çok sayıda uygulama gerçekleştirilebilir. Böylece esnek bir yapıya sahip olan Geo-HUSREV yöntemi çalışma alanı ve veriye özel olarak uyarlanabilir. Kümelenen veriler için her kümeyle özgü lokal parametrelerin bulunduğu bir Geo-

HUSREV çalışması bu tez çalışmasında ele alınan örnek için daha iyi tahmin başarıları elde edebilir. Bu gibi parametreler sonraki çalışmalarda incelenmelidir. Az sayıda örnek noktası ile tahmin yapılabilmesi, çalışma alanı ve veriye göre uyarlanabilir bir yapıda esnek olması hem jeoistatistik analizin mekânsal tahmin yeteneğini hem de yapay zekâ optimizasyon algoritmalarının öğrenme yeteneğini bir araya getirmesi Geo-HUSREV yönteminin en önemli özelliklerindedir.

Her karakteristik nokta için en düşük hata değerlerinin elde edildiği uygulamalarda kullanılan girdiler hem ANN hem de ANFIS uygulamaları bulguları incelenerek belirlenmiştir. Buna göre düşük yükseklikte yer alan test noktası için nem, basınç, denize uzaklık ve yükseklik girdileri, orta yükseklikte yer alan test noktası için boylam ve basınç girdileri, maksimum yükseklikte yer alan test noktası için nem, akarsulara uzaklık, basınç ve bakı girdileri, maksimum yükseklik ekstrapolasyon test noktası için nem, akarsulara uzaklık ve basınç girdileri, minimum yağış alan test noktası için sıcaklık, nem ve boylam girdileri, ortalama yağış alan test noktası için nem, basınç ve en yakın 1. ve 2. komşu değerleri girdileri, maksimum yağış alan test noktası için sıcaklık girdisi, maksimum yağış ekstrapolasyon test noktası için nem, sıcaklık ve basınç girdileri, rasgele test noktaları için nem, denize uzaklık ve basınç girdileri, son olarak seyrek istasyon bulunan konumlarda yer alan test noktaları için nem, sıcaklık ve enlem girdileri, düşük tahmin hataları görülen uygulamalarda kullanılmıştır. Her karakteristik noktanın en düşük hata değerlerinin görüldüğü uygulamalarda çoğunlukla kullanılan girdiler Çizelge 4.32. ile verilmiştir.

**Çizelge 4.32.** Karakteristik test noktaları için en düşük tahmin hataları sağlayan girdiler

Düşük Yükseklik	Maksimum Yağış	Maksimum Yağış Ekstrapolasyon	Maksimum Yükseklik	Maksimum Yükseklik Ekstrapolasyon	Minimum Yağış	Ortalama Yağış	Ortalama Yükseklik	Rasgele Test KOH ± mm	Seyrek Konumlar KOH ± mm
Nem	Sıc.	Nem	Nem	Nem	Sıc.	Nem	Boy.	Nem	Nem
Bas.	-	Sıc.	A.U.	A.U.	Nem	Bas.	Bas.	D.U.	Sıc.
D.U.	-	Bas.	Bas.	Bas.	Boy.	K1	-	Bas.	En.
Yük.	-	-	Bakı	-	-	K2	-	-	-

Çizelge 4.32.'de her karakteristik nokta için en iyi girdilerin neler olduğu verilmiştir. Bu bilgilere göre karakteristik test noktaları için başarılı tahmin performanslarının elde edilmesinde enlem, boylam ve en yakın komşu değerleri gibi yakınlık benzerlik ilişkisi ile ilgili değişkenlerin en önemli değişkenler olmadığı görülmektedir. Sadece ortalama yağış test noktasının düşük hatalı tahmininde 1. ve 2. en yakın komşu değerleri etkin olmuştur.

Girdilerin birlikte kullanımını bakımından, maksimum yağış ekstrapolasyon test noktası için düşük tahmin bulguları elde edilen uygulamaların büyük çoğunluğu 3 girdili uygulamalar ile elde edilmiştir. Ortalama yağış test noktası için ise en düşük tahmin hatalı uygulamalar çoğunlukla tek girdili uygulamalar ile elde edilmiştir.

Karakteristik test noktaları için yapay zekâ yöntemlerinden ANFIS yöntemi minimum yağış test noktası için düşük tahmin hatası bulguları ortaya çıkarmıştır. Diğer tüm karakteristik test noktaları için ANN yöntemi ANFIS yöntemine göre daha düşük tahmin hatası bulgularına sahiptir.

Tez çalışması kapsamında 14 mekânsal dağılım tahmini haritası üretilmiştir. Çok sayıda uygulama arasından seçilen en iyi ANN ve ANFIS yöntemine ait haritalar ve COK, RK ve KH yöntemleri ile elde edilen haritalar Şekil 4.27. üzerinde karşılaştırılmıştır.

ANN-709978, KH-1, RK-1 ve COK-1 uygulamalarının girdileri aynı olup kullanılan değişkenler denize uzaklık, nem ve basınç girdileridir. ANFIS-2121617-25H5, KH-2, RK-2 ve COK-2 uygulamasına ait haritalar ise akarsulara uzaklık, nem ve basınç girdileri ile elde edilmiştir. ANN-5106, KH-3, RK-3 ve COK-3 uygulamaları tek girdi kullanımının araştırılması ve yükseklik değişkeninin kullanılması ile COK, RK ve KH başarılarının incelenmesi için gerçekleştirilmiştir. Bu uygulamaların mekânsal tahmin haritaları arasındaki doku ve yağış büyüklüğü farklılıkları Şekil 4.27. üzerinde kolayca görülebilmektedir. Aynı bölge için yapay zekâ yöntemleri ile kriging, COK ve RK yöntemlerine göre oldukça farklı yağış dağılım tahmini haritaları elde edilmiştir. KH yöntemi diğer COK ve RK yöntemlerine göre özellikle maksimum yağış ekstrapolasyon noktasında tüm uygulamalarında daha başarılı bir harita üretmiştir. Haritalar arasındaki önemli farklılıklar, bu haritaların kullanılması ile yürütülecek afet duyarlılığı, risk çalışmaları ve planlama çalışmalarının nasıl farklı çıktılara yönlendirilebileceğini göstermektedir. Maksimum yağış ekstrapolasyon noktasında görülen çok düşük yağış tahmin bulguları nedeniyle RK, COK ve kriging tahmini haritaları ile o noktada taşkın, sel gibi afetler beklenirken aksi yönde kuraklığın beklenmesi yönünde bir çıkarım yapılabilir. Yeryüzünde bu gibi çeşitli karakteristik noktalarda istasyon noktası veya

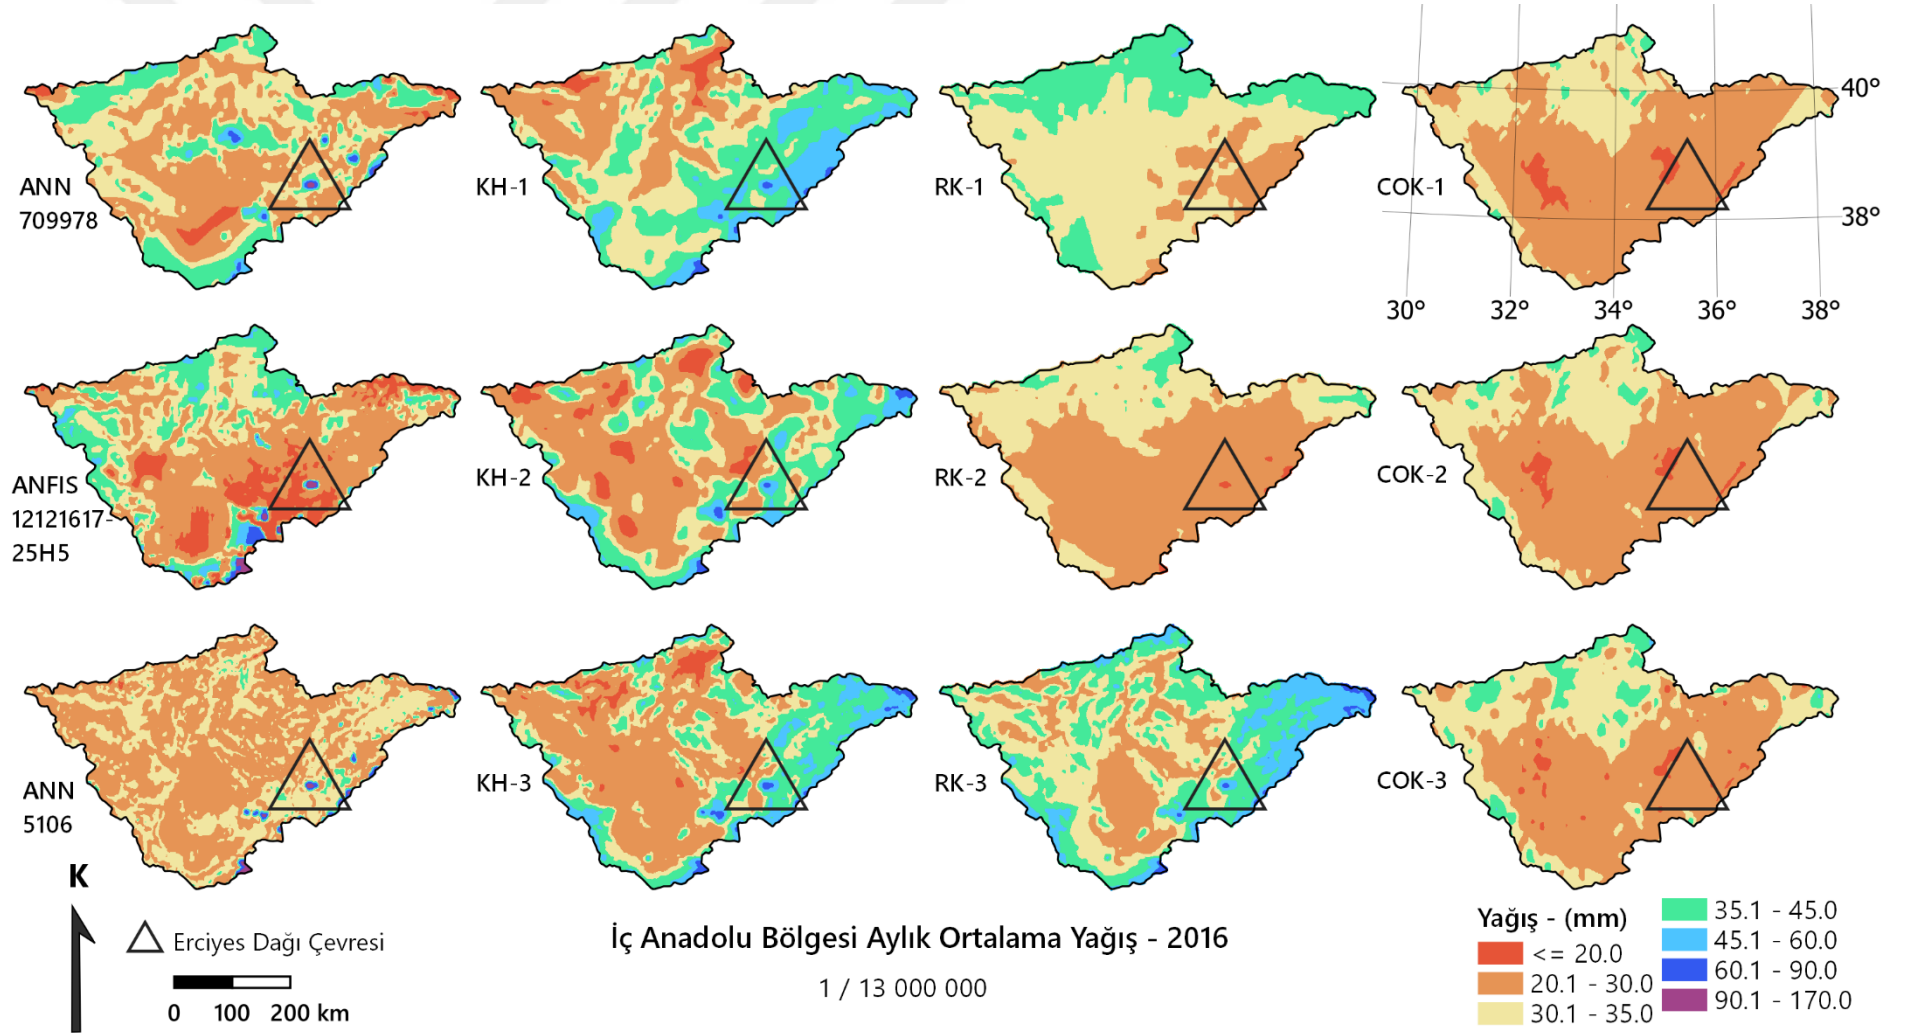
örneklem bulunmayabilir. Buna rağmen istasyon noktası bulunmayan böyle konumlar için uygun tahminler tezde ele alınan yaklaşımlar ile sağlanabilir. Bu çalışmada maksimum yağış ekstrapolasyon noktasında yer alan istasyon noktası değeri, bu nedenle test noktası olarak belirlenmiştir. Yöntemlerin başarısında en önemli unsur tahmin kabiliyetidir ve önemli bir farklılığın tahmin edilebilmesi oldukça önemlidir. Dünyada benzer konumlar için tez çalışmasında sunulan yaklaşımlar kullanılarak farklı mekânsal tahmin bulgularının bir arada incelenmesi son derece önemlidir. Örneğin taşkın ve sel çalışması için analiz yapılan bir uygulamada Şekil 4.27. ile verilen farklı tahmin haritalarının maksimum yağış değerlerinden oluşan maksimum yağış tahminleri haritası altlık olarak kullanılabilir. Benzer şekilde farklı tahmin haritalarının minimum yağış değerlerinden oluşan minimum yağış tahminleri haritası kullanılarak kuraklık gibi analizler için altlık harita kullanılabilir. Bu çalışmada istasyon noktası bulunmadığı varsayılan konumlardaki başarı, test noktaları ile doğrulanabilmiştir. Böylece tahmin haritalarının doğrulu bellidir. Aksi durumda belirtilen maksimum yağışlar, minimum yağışlar yaklaşımı kullanılarak hem jeoistatistik analiz hem de yapay zekâ yöntemlerinden gelen tahmin bulguları bir arada değerlendirilebilir. Tez çalışmasına ait uygulama bulgularının değerlendirilmesi ile çalışma kapsamında cevapları aranan sorulara yanıtlar verilmiştir.

Yağışların mekânsal tahmini için yapay zekâ yöntemleri kullanan çeşitli çalışmalar, bulgularını klasik yöntemlerin tahmin performansları ile de karşılaştırmıştır (Chang ve ark., 2005; Teegavarapu ve ark., 2009; Seo ve ark., 2015; Kajornrit ve ark., 2016). Yağışlar için yapılan çalışmalarda yapay zekâ yöntemleri veya yapay zekâ yöntemleri ile hibrit şekilde kullanılan jeoistatistik yöntemlerinin klasik yöntemlere göre daha iyi tahmin performansına sahip olduğu görülmüştür. Farklı çevresel değişkenler için yapılan çalışmalarda da benzer şekilde tahmin performanslarının değerlendirilmesinde klasik yöntemlerin performanslarını göz önünde bulundurulmuştur (Merwin ve ark., 2002; Li ve ark., 2011; Appelhans ve ark., 2015; Zhu ve ark., 2020; Mariano ve Monica, 2021).

Çalışma alanını kapsayan çalışmalarda olduğu gibi (Yavuz, 2010; Bostan ve ark., 2012; Bostan, 2013; Aydın, 2014; Çıtakoğlu ve ark., 2017; Gündoğdu, 2017; Çetin, 2018; Gündoğdu ve Hüsrevoğlu, 2018; Hüsrevoğlu, 2018; Tosunoğlu ve Gürbüz, 2019) kriging yöntemlerinin kullanımı oldukça yaygındır. Mekânsal tahminlerde klasik enterpolasyon yöntemleri ve jeoistatistik yöntemlerin yanı sıra tahmini yapılan konumun niteliklerini dikkate alan yapay zekâ yöntemlerinin kullanımı da incelenmelidir.



Ülkemizde, MGM tarafından yağışların mekânsal tahminlerinin gerçekleştirilmesinde jeoistatistik analiz yöntemleri kullanılmaktadır. Yağış gözlemi yapılan meteoroloji istasyonlarının sayılarının artırılması ve karakteristik özel noktalarda istasyonlara yer verilmesi elbette iyi bir mekânsal tahmin sağlamanın en iyi yoludur. Ancak geçmişten beri ölçüm yapan meteoroloji istasyonları daha az sayıdadır. Uzun yıllar verileri ile yapılacak çalışmalarda yeni istasyon değerleri kullanılmayacağından kullanılan yöntem ve yaklaşımlar son derece önemlidir. Araştırmacıların gerçeği temsil etmeyen haritaları altlık olarak kullanıp, taşkın duyarlılığı gibi konularda analizler yapması son derece önemli bir sorundur. Bu tez çalışmasında ortaya koyulduğu gibi uygun tahmin yaklaşımının sağlanması ile istasyon bulunmayan özel konumlar için daha doğru mekânsal tahminler gerçekleştirmek mümkündür. Tez çalışmasında ele alınan maksimum yağış ekstrapolasyon noktası uzun yıllar verisi olmayan bir istasyon noktasıdır. Bu çalışmada ilgili istasyon, test noktası olarak kullanılmıştır ve istasyon bulunmama durumu bu gibi karakteristik noktalarda simüle edilmiştir. Benzer şekilde yeryüzünde çeşitli çalışma alanları ve çeşitli çevresel değişkenler için çalışmada sunulan yapay zekâ yaklaşımları kullanılarak doğru tahmin değerleri elde edilmeye çalışılabilir.



Şekil 4.27. ANN, ANFIS, Geo-HUSREV (KH), RK ve COK haritalarının karşılaştırılması

## 5. SONUÇLAR VE ÖNERİLER

Tez çalışması kapsamında yapay zekâ yöntemlerinin yağışların mekânsal dağılımlarının tahmini için başarısı incelenmiştir. Bunun için Türkiye'nin İç Anadolu Bölgesi'nde 2016 yılı aylık ortalama yağış değerleri kullanılarak yapılan uygulamalar ile ANN, ANFIS, GA, PSO yöntemleri karşısında kriging, COK ve RK yöntemlerinin tahmin başarısı karşılaştırılmıştır. Yapay zekâ yöntemlerinin uygulanışı için farklı parametrelerin kullanımının ve yağışlar ile ilişkili 17 değişkenin tahminler için girdi olarak kullanımının etkisi ayrıca incelenmiştir. Çalışma, çok sayıda girdinin ve yöntemlere ait çok sayıda parametrenin denenmesi ile önemli bulgular ortaya koymuştur. Çalışma kapsamında nokta temelli örnek nokta değerleri kullanılarak yapay zekâ yöntemleri ile mekânsal tahmin haritası üretimi için bir çerçeve sunulmuştur.

Çalışma kapsamında jeoistatistik analiz ve sezgisel optimizasyon algoritmalarının birlikte kullanımını sağlayarak tahmin performanslarının iyileştirilmesini amaçlayan Geo-HUSREV yöntemi geliştirilmiştir. Geo-HUSREV yöntemi ile yapılan uygulamaların bulguları da diğer yöntemler ile karşılaştırılmıştır.

Yağışların mekânsal tahmini ve çalışma alanı için yapay zekâ yöntemlerinden ANN ve ANFIS yöntemleri, kriging, COK ve RK ve Geo-HUSREV yöntemlerine göre daha uygun tahmin performansları sergilemiştir. Çalışma kapsamında en uygun yağış dağılımı tahmini ANN-709978 uygulaması ile elde edilmiştir. Geo-HUSREV yöntemi kriging, COK ve RK yöntemlerinden daha iyi tahmin performansı sergilemiştir.

İncelenen ve tartışılan araştırma bulguları ışığında, Tobler'in (1970) yakın olan objelerin daha benzer olacağını ifade ettiği coğrafya kanunu temeline göre, komşu örnek nokta değerlerinden ve mekânsal bağımlılıktan faydalanan kriging, COK ve RK yöntemleri yapay zekâ yöntemlerine göre daha düşük doğrulukta tahmin bulguları üretmiştir. Özellikle maksimum yağış ekstrapolasyon noktası için bu yöntemler gerçek değerlerin çok altında tahmin değerleri ortaya koymuştur. Bu durum tahmini yapılan konum için komşu örnek nokta değerlerini kullanmanın her zaman başarılı tahminler sağlayamayacağını göstermiştir. Kriging, COK ve RK yöntemlerinin komşu noktalara bağlı olmaları karşısında yapay zekâ yöntemleri oldukça başarılı tahmin bulguları sağlamıştır. Tahmini yapılan konumun komşu noktalarının veya yakınlığa bağlı özelliklerinin kullanılması dışında tahmin noktasının özelliklerinin de tahminlerde dikkate alınması son derece önemlidir. RK yöntemi ile bu yetenek sağlanabilse de bu yöntem ile gerçekleştirilen uygulamalar yapay zekâ uygulamalarına göre başarısız

olmuştur. Yapay zekâ yöntemlerinin karmaşık ve lineer olmayan problemleri öğrenme yeteneği sayesinde ve tahmini yapılan konuma ait özneliklerin tahminlerde kullanılması ile klasik yöntemlere göre başarılı mekânsal tahmin bulguları elde edilmiştir. Yapay zekâ yöntemleri maksimum yağış ekstrapolasyon noktasında oldukça başarılı tahmin bulguları sağlamıştır. Farklı karakteristik test noktaları üzerinde başarısı incelenen yöntemlerin, farklı özelliklere sahip konumlarda başarısının nasıl olduğu incelenmiştir. Böylece sadece KOH değeri yerine, tahmin bulguları mekânsal olarak da incelenmiştir. Bu sayede sadece KOH değerine göre uygun görülebilen kriging, COK ve RK bulgularının aslında maksimum yağış ekstrapolasyon noktasında yüksek yağışları temsil edemediği tespit edilmiştir.

Geo-HUSREV yöntemi ile kriging, COK ve RK yöntemlerinden daha iyi bulgular elde edilmiştir. Geo-HUSREV yöntemi oldukça esnek bir yöntemdir ve farklı kullanımlarının daha detaylı şekilde incelenmesi sonraki çalışmalar için faydalı olacaktır. Yöntemin en önemli avantajı hem jeostatistik hem de yapay zekâ stratejilerini bir araya getirmesidir. Ayrıca yöntem az sayıda örnek noktası bulunan çalışmalar için hesaplanması gereken az sayıda parametreye sahip olduğu için daha başarılı tahmin bulguları sağlayabilir. Çalışma kapsamında ortaya koyulan Geo-HUSREV yöntemi için daha fazla uygulama gerçekleştirilerek yöntemin hem bu çalışma hem de farklı çalışmalar için mekânsal tahmin başarısı incelenmelidir. Sonraki çalışmalarda bu çalışmada kullanılan yaygın yapay zekâ yöntemleri dışında farklı yapay zekâ yöntemlerinin mekânsal tahmin başarılarının da incelenmesi önemlidir.

ANN ve ANFIS yöntemlerinin en iyi uygulamalarının PSO ve GA algoritmaları ile eğitilmesi tahmin bulgularını geliştirmemiştir. Bu algoritmaların tahmin bulgularını geliştirmesinin sağlanması için sonraki çalışmalarda farklı parametreler ile kapsamlı deneysel uygulamalar gerçekleştirilebilir.

Çalışma kapsamında belirlenen en iyi uygulamaların girdileri çoğunlukla nem, basınç, denize uzaklık, sıcaklık ve akarsulara uzaklık olmuştur. Nem ve basınç girdileri uygun tahmin bulguları görülen uygulamalarda ortak girdiler olmuştur. Buna karşın tamamen yakınlığa bağlı ilişkilere göre tahmin gerçekleştiren kriging, COK ve RK yöntemlerinin metodolojisinin aksine enlem, boylam ve en yakın komşu değerleri girdileri uygun tahmin çalışmalarında en az kullanılan değişkenler olmuştur.

Araştırma bulgularına göre performans değerlendirmesinde sadece KOH değerlerinin kullanılmasının yanıltıcı sonuçlara yol açabileceği sonucuna varılmıştır. Ayrıca kriging, COK ve RK yöntemleri ile elde edilen yağış tahmin haritalarının afetler,

su yönetimi gibi çalışmalar için yanıtıcı harita altlıkları olabilecekleri sonucuna varılmıştır.

Yağışların mekânsal dağılımlarının tahmininde veya çeşitli konularda ele alınan çevresel değişkenlerin mekânsal tahminlerinde sadece KOH değerlerine göre değerlendirme yapmanın ve mekânsal bağımlılık ve yakınlık-benzerlik temelinde tahmin gerçekleştiren jeostatistik analiz ile tahminler yapmanın dezavantajları ortaya konmuştur. Buna karşın yapay zekâ yöntemlerinin mekânsal tahmin yöntemi olarak kullanılmasının başarılı tahminler sağlayabileceği gösterilmiştir. Buna göre sonraki çalışmalarda gerçekleştirilecek mekânsal tahminler için hem jeostatistik analiz yöntemlerinin bulgularının incelenmesi hem de yapay zekâ yöntemleri ile elde edilen mekânsal tahmin bulgularının değerlendirilmesi oldukça önemlidir. Ayrıca farklı yöntemlere ait tahmin bulgularından elde edilen haritaların bindirilmesi ile minimum tahminler veya maksimum tahminler haritaları elde edilerek analizler gerçekleştirilebilir.

Bu çalışma binlerce uygulama sonucunda ortaya koyduğu bulgular ve yapay zekâ yöntemine ait modellerin nokta bazlı olarak haritalanması hakkında ortaya koyduğu çerçeve bakımından araştırmacılar için faydalı bilgiler sunmuştur. Sunulan çerçeve, yapay zekâ yöntemlerinin mekânsal tahmin yöntemi olarak kullanılması için istasyon gözlemleri gibi nokta temelli verilerden faydalanan araştırmacılara faydalı olacaktır.

Çalışma kapsamında ortaya konan Geo-HUSREV yöntemi MATLAB yazılımı ortamında programlanmıştır. Böylece tez çalışması kapsamında yeni bir yöntem ve bu yönteme ait yazılım kodları elde edilmiştir.

Harita Mühendisliği ve kartografya alanında, özgün ve güncel yaklaşımların kullanıldığı bu çalışmanın bulguları, ilgili alanda yapılacak diğer çalışmalar için önemli bilgiler sağlayacaktır.

## KAYNAKLAR

- Adhikary, S. K., Muttil, N. ve Yilmaz, A. G., 2017, Cokriging for Enhanced Spatial Interpolation of Rainfall in Two Australian Catchments, *Hydrological Processes*, 31 (12), 2143-2161.
- Amato, F., Guignard, F., Robert, S. ve Kanevski, M., 2020, A Novel Framework for Spatio-Temporal Prediction Of Environmental Data Using Deep Learning, *Scientific Reports*, 10 (1), 1-11.
- Apaydın, H., Sonmez, F. K. ve Yıldırım, Y. E., 2004, Spatial Interpolation Techniques For Climate Data In The Gap Region In Turkey, *Climate Research*, 28 (1), 31-40.
- Appelhans, T., Mwangomo, E., Hardy, D. R., Hemp, A. ve Nauss, T., 2015, Evaluating Machine Learning Approaches For The Interpolation Of Monthly Air Temperature At Mt. Kilimanjaro, Tanzania, *Spatial Statistics*, 14, 91-113.
- Arabameri, A., Arora, A., Pal, S. C., Mitra, S., Saha, A., Nalivan, O. A., Panahi, S. ve Moayedı, H., 2021, K-Fold and State-of-the-Art Metaheuristic Machine Learning Approaches for Groundwater Potential Modelling, *Water Resources Management*, 35 (6), 1837-1869.
- Aslantaş, P., Akyürek, Z. ve Heuvelink, G., 2016, Yağışın Zaman ve Mekânda Dağılımının Elde Edilmesi, *DÜMF Mühendislik Dergisi*, 7 (2), 257-269.
- Attar, M., Abedini, M. J. ve Akbari, R., 2019, Optimal Prioritization of Rain Gauge Stations for Areal Estimation of Annual Rainfall Via Coupling Geostatistics with Artificial Bee Colony Optimization, *Journal of Spatial Science*, 64 (2), 257-274.
- Aydın, O. ve Çiçek, İ., 2013, Ege Bölgesi'nde Yağışın Mekânsal Dağılımı, *Coğrafi Bilimler Dergisi*, 11 (2), 101-120.
- Aydın, O., 2014, Türkiye'de Yıllık Ortalama Toplam Yağışın Kriging Yöntemiyle Belirlenmesi, Doktora Tezi, *Ankara Üniversitesi*, Ankara, 330.
- Aydın, O. ve Raja, N. B., 2016, Yağışın Mekânsal Dağılımında Deterministik ve Stokastik Yöntemler: Mauritius Örneği, Doğu Afrika (Deterministic And Stochastic Methods To Analyse The Spatial Distribution of Precipitation: The Case of Mauritius, East Africa), *Turkish Journal of Geographical Sciences*, 114 (1), 1-14.
- Aydın, O., 2018, Evaluation of Kriging with External Drift Method In Spatial Modelling of Precipitation: A Case of Aegean Region, Turkey, *Dumlupınar University Journal of Social Science* (56).
- Azad, A., Manoochehri, M., Kashi, H., Farzin, S., Karami, H., Nourani, V. ve Shiri, J., 2019, Comparative evaluation of intelligent algorithms to improve adaptive neuro-fuzzy inference system performance in precipitation modelling, *Journal of Hydrology*, 571, 214-224.
- Bayat, B., Nasserı, M. ve Delmelle, E., 2021, Uncertainty-Based Rainfall Network Design Using a Fuzzy Spatial Interpolation Method, *Applied Soft Computing*, 106, 107296.
- Borges, P. d. A., Franke, J., Anunciação, Y. M. T. d., Weiss, H. ve Bernhofer, C., 2016, Comparison of Spatial Interpolation Methods for The Estimation of Precipitation Distribution in Distrito Federal, Brazil, *Theoretical And Applied Climatology*, 123 (1-2), 335-348.
- Bostan, P., Heuvelink, G. B. ve Akyurek, S., 2012, Comparison Of Regression And Kriging Techniques For Mapping The Average Annual Precipitation Of Turkey, *International Journal of Applied Earth Observation and Geoinformation*, 19, 115-126.

- Bostan, P. A., 2013, Analysis And Modeling Of Spatially And Temporally Varying Meteorological Parameter: Precipitation Over Turkey, Doktora Tezi, *Middle East Technical University*, Ankara, 94.
- Canlı, E., Loigge, B. ve Glade, T., 2018, Spatially Distributed Rainfall Information and Its Potential for Regional Landslide Early Warning Systems, *Natural Hazards*, 91 (1), 103-127.
- Cecinati, F., Rico-Ramirez, M. A., Heuvelink, G. B. ve Han, D., 2017, Representing Radar Rainfall Uncertainty With Ensembles Based On A Time-Variant Geostatistical Error Modelling Approach, *Journal of Hydrology*, 548, 391-405.
- Chang, C., Lo, S. ve Yu, S., 2005, Applying Fuzzy Theory and Genetic Algorithm to Interpolate Precipitation, *Journal of Hydrology*, 314 (1-4), 92-104.
- Chen, G., Wu, G., Chen, L., He, L. ve Jiang, C., 2011, Surface Modelling of Annual Precipitation in The Dongjiang River Basin, China, *2011 19th International Conference on Geoinformatics*, 1-4.
- Chen, W., Pourghasemi, H. R., Kornejady, A. ve Zhang, N., 2017, Landslide Spatial Modeling: Introducing New Ensembles of ANN, MaxEnt, and SVM Machine Learning Techniques, *Geoderma*, 305, 314-327.
- Chen, W., Panahi, M., Khosravi, K., Pourghasemi, H. R., Rezaie, F. ve Parvinnezhad, D., 2019, Spatial Prediction of Groundwater Potentiality Using ANFIS Ensembled with Teaching-Learning-Based and Biogeography-Based Optimization, *Journal of Hydrology*, 572, 435-448.
- Costache, R., Țincu, R., Elkhrachy, I., Pham, Q. B., Popa, M. C., Diaconu, D. C., Avand, M., Costache, I., Arabameri, A. ve Bui, D. T., 2020, New Neural Fuzzy-Based Machine Learning Ensemble for Enhancing The Prediction Accuracy of Flood Susceptibility Mapping, *Hydrological Sciences Journal*, 65 (16), 2816-2837.
- Cressie, N., 1993, *Statistics for Spatial Data*, John Wiley & Sons, p.
- Çakır, F. S., 2018, *Yapay Sinir Ağları Matlab Kodları Ve MATLAB Toolbox Çözümleri*, Nobel Akademik Yayıncılık, p.
- Çetin, M. ve Tülücü, K., 1998, Doğu Akdeniz Bölgesi'nde Aylık Yağışların Yersel Değişimlerinin Jeostatistik Yöntemle İncelenmesi, *Turkish Journal of Engineering and Environmental Science*, 22 (4), 279-288.
- Çetin, S., 2018, *Kızılırmak Havzasında Alansal Yağış İle Buharlaştırma-Terlemenin İzleme Ve Değerlendirilmesinde Uydu Görüntülerinin Kullanılması*, Doktora Tezi, Samsun.
- Çıtakoğlu, H., Çetin, M., Çobaner, M. ve Haktanır, T., 2017, Mevsimsel Yağışların Jeostatistiksel Yöntemle Modellenmesi ve Gözlemi Olmayan Noktalarda Tahmin Edilmesi, *İMO Teknik Dergi*, 7725 (7745), 469.
- Daniel, G. G., 2013, Artificial Neural Network, In: *Encyclopedia of Sciences and Religions*, Eds: Runehov, A. L. C. ve Oviedo, L., *Dordrecht: Springer Netherlands*, p. 143-143.
- Elmas, Ç., 2018, *Yapay Zeka Uygulamaları*, Ankara, Seçkin Yayıncılık, p. 375-404.
- Eriş, E. ve Ağralıoğlu, N., 2017, Ölçümleri Az Olan Kıyı Bölgelerinde Yağışın Yerel Dağılımının Belirlenmesi: Doğu Karadeniz Bölgesi, *Teknik Dergi*, 28 (1).
- Feki, H., Slimani, M. ve Cudennec, C., 2012, Incorporating Elevation In Rainfall Interpolation In Tunisia Using Geostatistical Methods, *Hydrological Sciences Journal*, 57 (7), 1294-1314.
- Guan, H., Wilson, J. L. ve Makhnin, O., 2005, Geostatistical Mapping of Mountain Precipitation Incorporating Autosearched Effects Of Terrain and Climatic Characteristics, *Journal of Hydrometeorology*, 6 (6), 1018-1031.

- Güler, M. ve Kara, T., 2014, A comparison of different interpolation techniques used in mapping monthly precipitation in northern Turkey, *Fresenius Environmental Bulletin*, 23 (2), 341-347.
- Gündoğdu, İ. B., 2014, Multivariate Geostatistics For Mapping Meteorological Precipitation, *Global Journal of Engineering Science and Research Management*, 6 (1), 20-25.
- Gündoğdu, İ. B., 2015, Geographically Weighted Regression and Secondary Variables for Mapping of Meteorological Data, *Journal of Geodesy and Geomatics Engineering*, 63-72.
- Gündoğdu, İ. B., 2017, Usage of Multivariate Geostatistics in Interpolation Processes for Meteorological Precipitation Maps, *Theoretical and Applied Climatology*, 127 (1-2), 81-86.
- Gündoğdu, İ. B. ve Hüsrevoğlu, M., 2018, Comparison of Different Prediction Approaches for Precipitation Distribution by Kriging Methods, *Journal of Scientific and Engineering Research*, 5 (4), 296-302.
- Hamdia, K. M., Zhuang, X. ve Rabczuk, T., 2021, An Efficient Optimization Approach For Designing Machine Learning Models Based On Genetic Algorithm, *Neural Computing and Applications*, 33 (6), 1923-1933.
- Hengl, T., Heuvelink, G. B. ve Rossiter, D. G., 2007, About Regression-Kriging: From Equations To Case Studies, *Computers & Geosciences*, 33 (10), 1301-1315.
- Hengl, T., 2009, A Practical Guide To Geostatistical Mapping, *Amsterdam*, The Netherlands: University of Amsterdam, p.
- Hengl, T., Walsh, M. G., Sanderman, J., Wheeler, I., Harrison, S. P. ve Prentice, I. C., 2018, Global Mapping Of Potential Natural Vegetation: An Assessment Of Machine Learning Algorithms For Estimating Land Potential, *PeerJ*, 6, e5457.
- Holland, J. H., 1975, Adaptation In Natural And Artificial Systems, *Ann Arbor, MI*, University of Michigan Press, p.
- Hu, Q., Li, Z., Wang, L., Huang, Y., Wang, Y. ve Li, L., 2019, Rainfall Spatial Estimations: A Review From Spatial Interpolation To Multi-Source Data Merging, *Water*, 11 (3), 579.
- Huffman, G. J., Stocker, E. F., Bolvin, D. T., Nelkin, E. J. ve Tan, J., 2019, GPM IMERG Final Precipitation L3 1 month 0.1 degree x 0.1 degree V06. DISC), G. E. S. D. a. I. S. C. G. Greenbelt, MD.
- Hutchinson, M. F., 1995, Interpolating Mean Rainfall Using Thin Plate Smoothing Splines, *International Journal of Geographical Information Systems*, 9 (4), 385-403.
- Hüsrevoğlu, M., 2018, Jeostatistik Analiz ile Yağış Haritalarının Görselleştirilmesi, Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya.
- İçağa, Y. ve Taş, E., 2018, Comparative Analysis of Different Interpolation Methods In Modeling Spatial Distribution of Monthly Precipitation, *Doğal Afetler ve Çevre Dergisi*, 4 (2), 89-104.
- İlker, A., 2012, Akdeniz Bölgesinde Yağışın Alansal Dağılımı, Yüksek Lisans Tezi, *Süleyman Demirel Üniversitesi*, Isparta, 83.
- Jang, 2023, Frequently Asked Questions - ANFIS in the Fuzzy Logic Toolbox, <http://www.cs.nthu.edu.tw/~jang/anfisfaq.htm#5>: [29.05.2023].
- Jang, J.-S., 1993, ANFIS: adaptive-network-based fuzzy inference system, *IEEE transactions on systems, man, and cybernetics*, 23 (3), 665-685.
- Javari, M., 2017, Comparison of Interpolation Methods For Modeling Spatial Variations of Precipitation In Iran, *International Journal of Environmental and Science Education*, 12 (5), 1037-1054.



- Kajornrit, J., Wong, K. W. ve Fung, C. C., 2016, An Interpretable Fuzzy Monthly Rainfall Spatial Interpolation System For The Construction of Aerial Rainfall Maps, *Soft Computing*, 20 (12), 4631-4643.
- Kale, M., 2018, Yeşilirmak Havzası Mekânsal Yağış Dağılımına ait Değişiminin Deterministik ve Stokastik Yöntemlerle Belirlenmesi, *Yerbilimleri Dergisi*, 39 (3), 263-276.
- Kalteh, A. M. ve Berndtsson, R., 2007, Interpolating Monthly Precipitation By Self-Organizing Map (SOM) And Multilayer Perceptron (MLP), *Hydrological Sciences Journal*, 52 (2), 305-317.
- Karaboğa, D., 2005, An Idea Based On Honey Bee Swarm for Numerical Optimization, *Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği*.
- Karaboğa, D., 2018, Yapay Zekâ Optimizasyon Algoritmaları, Nobel Akademi Yayınları, p.
- Kennedy, J. ve Eberhart, R., 1995, Particle Swarm Optimization, *Proceedings Of ICNN'95-International Conference On Neural Networks*, 1942-1948.
- Kennedy, J., 2017, Particle Swarm Optimization, In: Encyclopedia of Machine Learning and Data Mining, Eds: Sammut, C. ve Webb, G. I., Boston, MA: Springer US, p. 967-972.
- Krivoruchko, K., 2005. Introduction To Modeling Spatial Processes Using Geostatistical Analyst. 27. Erişim Adresi, <http://www.esri.com/library/whitepapers/pdfs/intro-modeling.pdf>.
- Kubat, C., 2014, Yapay Zeka ve Mühendislik Uygulamaları, Pusula, p.
- Kumari, M., Basistha, A., Bakimchandra, O. ve Singh, C., 2016, Comparison Of Spatial Interpolation Methods For Mapping Rainfall In Indian Himalayas Of Uttarakhand Region, In: Geostatistical and Geospatial Approaches for the Characterization of Natural Resources in the Environment, Eds: Springer, p. 159-168.
- Kühnlein, M., Appelhans, T., Thies, B. ve Nauss, T., 2014, Improving the accuracy of rainfall rates from optical satellite sensors with machine learning—A random forests-based approach applied to MSG SEVIRI, *Remote Sensing of Environment*, 141, 129-143.
- Li, J., Heap, A. D., Potter, A. ve Daniell, J. J., 2011, Application Of Machine Learning Methods To Spatial Interpolation Of Environmental Variables, *Environmental Modelling & Software*, 26 (12), 1647-1659.
- Li, J., 2019, A Critical Review Of Spatial Predictive Modeling Process In Environmental Sciences With Reproducible Examples In R, *Applied Sciences*, 9 (10), 2048.
- Lloyd, C. D., 2005, Assessing The Effect Of Integrating Elevation Data Into The Estimation Of Monthly Precipitation In Great Britain, *Journal of Hydrology*, 308 (1-4), 128-150.
- Ly, S., Charles, C. ve Degre, A., 2011, Geostatistical Interpolation Of Daily Rainfall At Catchment Scale: The Use Of Several Variogram Models In The Ourthe And Ambleve Catchments, Belgium, *Hydrology and Earth System Sciences*, 15 (7), 2259-2274.
- Mariano, C. ve Monica, B., 2021, A Random Forest-Based Algorithm For Data-Intensive Spatial Interpolation In Crop Yield Mapping, *Computers and Electronics in Agriculture*, 184, 106094.
- Matheron, G., 1963, Principles Of Geostatistics, *Economic Geology*, 58 (8), 1246-1266.
- Matheron, G., 1967, Kriging Or Polynomial Interpolation Procedures, *CIMM Transactions*, 70, 240-244.
- McCulloch, W. S. ve Pitts, W., 1943, A Logical Calculus Of The Ideas Immanent In Nervous Activity, *The Bulletin Of Mathematical Biophysics*, 5 (4), 115-133.

- McNally, A. ve NASA/GSFC/HSL, 2018, FLDAS Noah Land Surface Model L4 Global Monthly 0.1 x 0.1 degree (MERRA-2 and CHIRPS). DISC), G. E. S. D. a. I. S. C. G. Greenbelt, MD, USA, NASA.
- Merwin, D. A., Cromley, R. G. ve Civco, D. L., 2002, Artificial Neural Networks As A Method Of Spatial Interpolation For Digital Elevation Models, *Cartography and Geographic Information Science*, 29 (2), 99-110.
- Moayedi, H., Mehrabi, M., Mosallanezhad, M., Rashid, A. S. A. ve Pradhan, B., 2019, Modification of landslide susceptibility mapping using optimized PSO-ANN technique, *Engineering with Computers*, 35 (3), 967-984.
- Møller, M. F., 1993, A Scaled Conjugate Gradient Algorithm For Fast Supervised Learning, *Neural networks*, 6 (4), 525-533.
- Moral, F. J., 2010, Comparison Of Different Geostatistical Approaches To Map Climate Variables: Application To Precipitation, *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 30 (4), 620-631.
- NASA, METI, AIST, US, J. S. a. ve Team, J. A. S., 2019, ASTER Global Digital Elevation Model V003. NASA, METI, AIST, US, J. S. a. ve Team, J. A. S. NASA EOSDIS Land Processes DAAC.
- Oliver, M. A., 2010, The Variogram And Kriging, In: Handbook of Applied Spatial Analysis, Eds: Fischer, M. M.: Springer-Verlag Berlin Heidelberg 2010, p. 319-352.
- Oliver, M. A. ve Webster, R., 2015, Basic Steps In Geostatistics: The Variogram And Kriging, *New York*, Springer, p.
- Özçakal, E., 2014, Ege Bölgesi Yağış Ve Sıcaklık Değerlerinin Zaman Ve Mekân Boyutundaki Değişiminin İstatistiksel Analizi, Doktora Tezi, *Ege Üniversitesi*, İzmir, 312.
- Özelkan, E., Bağıs, S., Özelkan, E. C., Üstundağ, B. B., Yücel, M. ve Örmeci, C., 2015, Spatial Interpolation Of Climatic Variables Using Land Surface Temperature And Modified Inverse Distance Weighting, *International Journal of Remote Sensing*, 36 (4), 1000-1025.
- Özkaya, U., 2020, Derin öğrenme yöntemleri ile GPR B tarama görüntülerinin analizi / Analysis of GPR B scan images with deep learning methods, Doktora Tezi, *Konya Teknik Üniversitesi*, Konya.
- Poli, R., Kennedy, J. ve Blackwell, T., 2007, Particle Swarm Optimization: An Overview, *Swarm Intelligence*, 1, 33-57.
- Raja, N. B., Aydın, O., Türkoğlu, N. ve Çiçek, I., 2017, Space-Time Kriging Of Precipitation Variability In Turkey For The Period 1976–2010, *Theoretical and Applied Climatology*, 129 (1-2), 293-304.
- Rigol, J. P., Jarvis, C. H. ve Stuart, N., 2001, Artificial Neural Networks As A Tool For Spatial Interpolation, *International Journal of Geographical Information Science*, 15 (4), 323-343.
- Sadighi, M., Motamedvaziri, B., Ahmadi, H. ve Moeini, A., 2020, Assessing Landslide Susceptibility Using Machine Learning Models: A Comparison Between ANN, ANFIS, and ANFIS-ICA, *Environmental Earth Sciences*, 79 (24), 1-14.
- Sağıroğlu, Ş., Beşdok, E. ve Erler, M., 2003, Mühendislikte Yapay Zeka Uygulamaları -1 Yapay Sinir Ağları, *Kayseri*, Ufuk Kitap Kırtasiye Yayıncılık, p.
- Sammut, C. ve Webb, G. I., 2017, Encyclopedia Of Machine Learning And Data Mining, Springer Publishing Company, Incorporated, p.
- Sarma, D. D., 2010, Geostatistics With Applications In Earth Sciences, *Springer*, Springer Science & Business Media, p.

- Sekulić, A., Kilibarda, M., Heuvelink, G., Nikolić, M. ve Bajat, B., 2020, Random Forest Spatial Interpolation, *Remote Sensing*, 12 (10), 1687.
- Sekulić, A., Kilibarda, M., Protić, D. ve Bajat, B., 2021, A High-Resolution Daily Gridded Meteorological Dataset For Serbia Made By Random Forest Spatial Interpolation, *Scientific Data*, 8 (1), 1-12.
- Seo, Y., Kim, S. ve Singh, V. P., 2015, Estimating Spatial Precipitation Using Regression Kriging And Artificial Neural Network Residual Kriging (RKNNRK) Hybrid Approach, *Water Resources Management*, 29 (7), 2189-2204.
- Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K. ve Woo, W.-c., 2015, Convolutional LSTM network: A machine learning approach for precipitation nowcasting, *Advances in neural information processing systems*, 28.
- Sun, Q., Miao, C., Duan, Q., Ashouri, H., Sorooshian, S. ve Hsu, K. L., 2018, A review of global precipitation data sets: Data sources, estimation, and intercomparisons, *Reviews of Geophysics*, 56 (1), 79-107.
- Sun, W., Zhu, Y., Huang, S. ve Guo, C., 2015, Mapping The Mean Annual Precipitation Of China Using Local Interpolation Techniques, *Theoretical And Applied Climatology*, 119 (1-2), 171-180.
- Şen, Z., 2009, Spatial Modeling Principles In Earth Sciences, Springer, p.
- Şensoy, S., Ulupınar, Y., Demircan, M., Balta, İ., Taştekin, A. T. ve Alan, İ., 2007, Klimatolojik Uygulamalarda ArcGIS Kullanımı. 12. ESRI kullanıcıları Grubu toplantısı. ODTÜ, Meteoroloji Genel Müdürlüğü: 1-17.
- Taghizadeh-Mehrjardi, R., Emadi, M., Cherati, A., Heung, B., Mosavi, A. ve Scholten, T., 2021, Bio-Inspired Hybridization Of Artificial Neural Networks: An Application For Mapping The Spatial Distribution Of Soil Texture Fractions, *Remote Sensing*, 13 (5), 1025.
- Taylan, E. D. ve Damçayırı, D., 2016, Isparta Bölgesi Yağış Değerlerinin IDW ve Kriging Enterpolasyon Yöntemleri ile Tahmini, *İMO Teknik Dergi* (459), 7551-7559.
- Teegavarapu, R. S., Tufail, M. ve Ormsbee, L., 2009, Optimal Functional Forms For Estimation Of Missing Precipitation Data, *Journal of Hydrology*, 374 (1-2), 106-115.
- Tobler, W. R., 1970, A Computer Movie Simulating Urban Growth In The Detroit Region, *Economic Geography*, 46 (sup1), 234-240.
- Topal, B., 2007, Jeoistatistiksel Variogram Ve Modelleme Yazılımı: Sayaca (Ulubey, Ordu) Altın Cevherleşmesin'de Uygulanması, Yüksek Lisans Tezi, *Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü, Jeoloji Mühendisliği Anabilim Dalı*, 248.
- Tosunoğlu, F. ve Gürbüz, F., 2019, Mapping Spatial Variability Of Annual Rainfall Under Different Return Periods In Turkey: The Application Of Various Distribution Functions And Model Selection Techniques, *Meteorological Applications*, 26 (4), 671-681.
- Uyguçgil, H., 2007, Çok Değişkenli Maden Yataklarında Rezerv Tenör Tahmininde Jeostatistik Ve Coğrafi Bilgi Sistemleri Tekniklerinin Kullanımı, Doktora Tezi, *Eskişehir Osmangazi Üniversitesi, Eskişehir*, 224.
- Uzunlar, Z., 2006, Türkiye Yeraltı Sıcaklık Gradyan Dağılımının Derin Kuyu Sıcaklık Verileri Ve Variogram Analizi İle Belirlenmesi, Yüksek Lisans Tezi, *Fen Bilimleri Enstitüsü, Petrol ve Doğal Gaz Mühendisliği Anabilim Dalı, İstanbul*, 93.
- Valizadeh, N., Mirzaei, M., Allawi, M. F., Afan, H. A., Mohd, N. S., Hussain, A. ve El-Shafie, A., 2017, Artificial Intelligence And Geo-Statistical Models For Stream-Flow Forecasting In Ungauged Stations: State Of The Art, *Natural Hazards*, 86 (3), 1377-1392.

- Virrantaus, K., Fairbairn, D. ve Kraak, M.-J., 2009, ICA research agenda on cartography and GI science, *The Cartographic Journal*, 46 (2), 63-75.
- Waters, N., 2016, Tobler's First Law of Geography, *International Encyclopedia of Geography: People, the Earth, Environment and Technology*, 1-15.
- Webster, R., 2000, Is Soil Variation Random?, *Geoderma*, 97 (3), 149-163.
- Webster, R. ve Oliver, M. A., 2007, Geostatistics for Environmental Scientists Second Edition, *England*, John Wiley & Sons, p.
- Yavuz, H., 2010, Türkiye'de Bazı İklim Parametrelerinin Coğrafi Bilgi Sistemleri Destekli Zamansal Ve Mekansal Analizi, Yüksek Lisans Tezi, *Afyon Kocatepe Üniversitesi*, Afyon, 268.
- Yılmaz, A., 2019, Yapay Zeka, Kodlab, p. 128.
- Zhu, D., Cheng, X., Zhang, F., Yao, X., Gao, Y. ve Liu, Y., 2020, Spatial Interpolation Using Conditional Generative Adversarial Neural Networks, *International Journal of Geographical Information Science*, 34 (4), 735-758.

