

**YAPAY SİNİR AĞLARI İLE HEYELAN DUYARLILIK  
HARİTALARININ ÜRETİLMESİNDE FARKLI  
ALGORİTMALARIN KULLANIMININ ARAŞTIRILMASI**

**INVESTIGATION OF THE UTILIZATION OF DIFFERENT  
ALGORITHMS IN LANDSLIDE SUSCEPTIBILITY MAPPING  
WITH ARTIFICIAL NEURAL NETWORKS**

**ASLI CAN**

**PROF. DR. MURAT ERCANOĞLU**

**Tez Danışmanı**

**Hacettepe Üniversitesi  
Lisansüstü Eğitim-Öğretim ve Sınav Yönetmeliğinin  
Jeoloji Mühendisliği Anabilim Dalı için Öngördüğü  
YÜKSEK LİSANS TEZİ olarak hazırlanmıştır.**

**2014**

**Aslı CAN**'nın hazırladığı “Yapay Sinir Ağları İle Heyelan Duyarlılık Haritalarının Üretilmesinde Farklı Algoritmaların Kullanımının Araştırılması” adlı bu çalışma aşağıdaki jüri tarafından **JEOLJİ MÜHENDİSLİĞİ ANABİLİM DALI**’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Başkan

(Prof Dr. Tamer TOPAL)

.....

Danışman

(Prof. Dr. Murat ERCANOĞLU)

.....

Üye

(Prof. Dr. Harun SÖNMEZ)

.....

Üye

(Prof. Dr. Işık YILMAZ)

.....

Üye

(Doç. Dr. Dilek TÜRER)

.....

Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Fatma SEVİN DÜZ  
Fen Bilimleri Enstitüsü Müdürü

## ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

22/08/2014

ASLI CAN

## ÖZET

# **YAPAY SİNİR AĞLARI İLE HEYELAN DUYARLILIK HARİTALARININ ÜRETİLMESİNDE FARKLI ALGORİTMALARIN KULLANIMININ ARAŞTIRILMASI**

**Aslı CAN**

**Yüksek Lisans, Jeoloji Mühendisliği Bölümü**

**Tez Danışmanı: Prof. Dr. Murat ERCANOĞLU**

**Ağustos 2014, 140 sayfa**

Bu çalışma kapsamında, heyelan duyarlılık haritalarının oluşturulmasında literatürde yaygın olarak kullanılan yapay sinir ağları (ANN) yöntemi uygulanarak, yapay sinir ağlarının eğitiminde farklı algoritmaların kullanılmasının sonuç haritaları üzerindeki etkileri ve performanslarının araştırılması amaçlanmıştır. Bu amaçla, Batı Karadeniz Bölgesi, Karabük ili sınırları içerisinde bir çalışma alanı seçilmiştir. Arazi çalışmaları, inceleme alanına ait hava fotoğraflarından ve Google Earth uydu görüntülerinden yararlanılarak, 196 adet heyelan haritalanmış ve heyelan veri tabanı oluşturulmuştur. Heyelan duyarlılığı analizlerinde kullanılmak üzere; topoğrafik yükseklik, yamaç eğimi, bakı, topoğrafik nemlilik indeksi, litoloji ve bitki örtüsü indeksi parametreleri dikkate alınmıştır. Farklı eğitim algoritmaları kullanılarak eğitilen ANN modellerinin sonuç haritaları üzerindeki etkilerinin karşılaştırılması amacıyla, tek ve iki gizli tabakalı olmak üzere iki farklı ağın topolojik yapısı tasarlanmıştır. ANN tasarımında, bir adet gizli tabaka kullanılması durumunda test veri seti hata oranı en düşük olan ağ topolojisi 6-13-1 olarak, iki adet gizli tabaka kullanılması durumunda ise test veri seti hata oranı en düşük olan ağ topolojisi 6-11-6-1 olarak saptanmıştır. Bu ağların eğitiminde, geri yayılım (BBP), hızlı yayılım (QP), eşlenik eğitim (CGD) ve Levenberg-Marquardt (LM) olmak üzere dört farklı eğitim algoritması kullanılarak toplamda 8 adet ANN modeli oluşturulmuştur. Bu modeller gizli tabaka sayısı ve eğitim algoritmasına göre; tek gizli tabakalı ANN modeli için; BBP1, QP1, CGD1, LM1 olarak ve iki gizli tabakalı ANN modeli için; BBP2, QP2; CGD2 ve LM2 olarak adlandırılmış ve bu modeller kullanılarak çalışma alanı için 8 farklı heyelan duyarlılık haritası üretilmiştir. Sözü

geçen eğitim algoritmalarının, ANN modellerine etkileri ve performanslarını değerlendirmek amacıyla, mevcut heyelanlı alanlarla, üretilen duyarlılık haritaları karşılaştırılarak ROC eğrileri çizilmiş, ROC eğrisi altında kalan alanları (AUC) ve ayrıca iki veri seti arasındaki ilişki değerini gösteren  $r_{ij}$  katsayısı FULLSA yazılımı kullanılarak hesaplanmıştır. En yüksek performansa sahip haritanın, AUC değeri 0.817 ve  $r_{ij}$  değeri 0.972 olarak hesaplanan, CGD1 modeliyle üretilmiş heyelan duyarlılık haritası olduğu belirlenmiştir. Ayrıca, ANN kullanılarak oluşturulan heyelan duyarlılık haritaları, mevcut heyelanların dağılımı dikkate alınarak karşılaştırıldığında, “yüksek heyelan duyarlılığı”nı temsil eden alanları en iyi yansıtan haritanın CGD1 modeliyle üretilen ve “çok yüksek heyelan duyarlılığı”nı temsil eden alanları en iyi yansıtan haritanın ise QP2 modeliyle üretilen heyelan duyarlılık haritası olduğu sonucuna varılmıştır. Bu değerlendirmeler ve analiz performanslarından yola çıkılarak; eşlenik eğitim algoritması, geri yayılım, hızlı yayılım ve Levenberg-Marquardt algoritmalarından daha yavaş olmasına karşın, tahmin sonuçları bakımından en iyi olduğu, Levenberg-Marquardt algoritmasının test edilen algoritmalar arasında en hızlı olanı ve tahmin performansına bakıldığında, geri yayılım, hızlı yayılım algoritmaları kadar iyi olduğu, geri yayılım ve hızlı yayılım algoritmaları arasında ise hız ve tahmin performansı açısından belirgin bir farklılık bulunmadığı sonucuna varılmıştır.

**Anahtar Kelimeler:** Yapay sinir ağları, eğitim algoritmaları, geri yayılım, hızlı yayılım, eşlenik eğitim, Levenberg-Marquardt, performans analizleri, heyelan duyarlılığı.

## **ABSTRACT**

# **INVESTIGATION OF THE UTILIZATION OF DIFFERENT ALGORITHMS IN LANDSLIDE SUSCEPTIBILITY MAPPING WITH ARTIFICIAL NEURAL NETWORKS**

**Aslı CAN**

**Master of Science, Department of Geological Engineering**

**Supervisor: Prof. Dr. Murat ERCANOĞLU**

**August 2014, 140 pages**

This study aims to investigate the effects and performances of the uses of different learning algorithms in the training of artificial neural networks on the resulting maps by applying the artificial neural networks (ANN) method, which is commonly used for the creation of landslide susceptibility maps in the literature. For this purpose, a study area is selected within the borders of Karabük province in the Western Black Sea Region. By utilizing site investigations, aerial photographs of the study area and Google Earth satellite images, 196 landslides were mapped and a landslide database was created. In order to be used in the analysis of landslide susceptibility: topographical elevation, slope angle, aspect, wetness index, lithology and vegetation index parameters were taken into account. The topological structures of two different networks, which are composed of respectively single and double hidden layers, are designed so as to compare the effects of the ANN models that are trained by different learning algorithms on the resulting maps. In the ANN design; in the case of single hidden layer use, the lowest test data set error of network topology is detected as 6-13-1; in the case of two hidden layer use the lowest test data set error of network topology is detected as 6-11-6-1. In the training of these networks, by utilizing four different learning algorithms, which are batch back-propagation (BBP), quick propagation (QP), conjugate gradient descent (CGD) and Levenberg-Marquardt (LM), a total of 8 ANN models have been created. These models are named according to the

number of hidden layer and training algorithm; for single hidden layered ANN model; BBP1, QP1, CGD1, LM1, and for two hidden layer ANN model for; BBP2, QP2; CGD2 and LM2. By using models, 8 different landslide susceptibility maps were produced for the study area. In order to assess the effects and performance of the above mentioned learning algorithms on ANN models, by comparing the existing landslide areas and produced susceptibility maps, the ROC curves were plotted and the areas under the ROC curve (AUC) was calculated. In addition, the  $r_{ij}$  coefficient value that indicates the relationship between two sets of data was calculated by the using FULLSA program. The map with the highest performance with the AUC value 0.817 and  $r_{ij}$  value 0.972 is determined as the landslide susceptibility map produced by CGD1 model. In addition, the "high landslide susceptibility" representing areas are best reflected by the landslide susceptibility map was produced by the CGD1 model and the "very high landslide susceptibility" representing areas are best reflected by the landslide susceptibility map was produced by the QP2 model. Moving from these assessments and performance analysis; conjugate gradient descent algorithm is slower than batch back propagation, quick propagation, and Levenberg-Marquardt algorithms yet in terms of the estimated results it is detected as the best. Levenberg-Marquardt algorithm among the tested algorithms is determined as the fastest one and according to its predict performance it is as good as back propagation and quick propagation algorithms. Between the batch back-propagation and the quick propagation algorithms, there is no significant difference in terms of speed and prediction performance.

**Keywords:** Artificial neural networks, learning algorithms, batch back-propagation, quick propagation, conjugate gradient descent, Levenberg-Marquardt, performance analysis, landslide susceptibility.

## TEŞEKKÜR

Bu çalışma, Hacettepe Üniversitesi Bilimsel Araştırmalar Birimi Proje No: 735 tarafından desteklenmiştir.

Çalışmalarına başladığım günden itibaren bütün bilgi ve tecrübeleriyle bana yön veren ve özellikle tezimin şekillenmesinde büyük emeği geçen tez danışmanım Sayın Prof. Dr. Murat Ercanoğlu'na,

Tez çalışması süresince gerçekleştirilen arazi çalışmaları sırasında değerli bilgi ve yorumlarıyla katkıda bulunan Sayın Prof. Dr. Harun Sönmez'e,

Önemli yorum ve eleştirileri ile çalışmanın son halini almasında katkıda bulunan jüri üyelerim Sayın Prof. Dr. Tamer Topal, Sayın Prof. Dr. Işık Yılmaz ve Sayın Doç. Dr. Dilek Türer'e

Tez çalışması süresince gerçekleştirilen arazi çalışmaları sırasındaki katkılarından ve aynı zamanda haritalama çalışmalarında yardımlarından dolayı Araş. Gör. Dr. Gülseren Dağdelenler'e,

CBS programlarını kullanmadaki bilgi ve yeteneğinden tezimin her aşamasında yararlandığım ve program ile ilgili güçlüklerin aşılmasındaki yardımlarından dolayı sevgili arkadaşım Hidrojeoloji Yük. Müh. Ludwig Simon (Johannes Gutenberg Üniversitesi, Mainz)'a,

Tez çalışmam süresince, tavsiyeleriyle bana yön veren ve destek olan sevgili arkadaşım Araş. Gör. Nazlı Tunar Özcan'a,

Tez yazım aşamasında, sorularımı usanmadan cevaplayan ve bilgisini benden esirgemeyen sevgili arkadaşım Geoteknik Yük. Müh. Arash Maghsoudloo (Orta Doğu Teknik Üniversitesi)'ya,

Tez çalışması süresince gösterdikleri sabır, maddi ve manevi destekten dolayı patronlarım Sayın Osman Aydoğdu ve Sayın Serkan Nemli'ye, ayrıca manevi desteklerinden dolayı İksa Mühendislik'deki tüm çalışma arkadaşlarıma,

Manevi destekleriyle bana her zaman güç veren sevgili dostlarım Jeoloji Müh. Aktöre Zeyrek, Jeoloji Müh. Simge Cavunt ve Duygu Didem Tarı'ya ve sevgili Hendrik Hânke'ye,

Ve her zaman yanımda olan, cesaret veren ve beni destekleyen sevgili annem Ayşe Can, babam Muhterem Can, kardeşlerim Esra Can ve Berke Can'a

İçtenlikle teşekkür ederim.

Aslı CAN

# İÇİNDEKİLER

## Sayfa

|                                                                                    |      |
|------------------------------------------------------------------------------------|------|
| ÖZET .....                                                                         | i    |
| ABSTRACT .....                                                                     | iii  |
| TEŞEKKÜR.....                                                                      | v    |
| İÇİNDEKİLER .....                                                                  | vii  |
| ŞEKİLLER.....                                                                      | x    |
| ÇİZELGELER .....                                                                   | xiii |
| SİMGELER VE KISALTMALAR .....                                                      | xiv  |
| 1. GİRİŞ .....                                                                     | 1    |
| 1.1. Çalışma Alanının Tanıtımı .....                                               | 7    |
| 1.2. Çalışma Alanının Bölgesel Jeolojik Özellikleri .....                          | 9    |
| 1.3. Stratigrafi .....                                                             | 9    |
| 1.3.1. Ulus Formasyonu (Ku).....                                                   | 11   |
| 1.3.2. Abant Formasyonu (Ktab).....                                                | 11   |
| 1.3.3. Kışlaköy Formasyonu (Tek).....                                              | 11   |
| 1.3.4. Safranbolu Formasyonu (Tes) .....                                           | 12   |
| 1.3.5. Çerçen Üyesi (Tekaç).....                                                   | 12   |
| 1.3.6. Karabük Formasyonu (Teka) .....                                             | 12   |
| 1.3.7. Soğanlı Formasyonu (Teso) .....                                             | 12   |
| 1.3.8. Akçapınar Formasyonu (Tea).....                                             | 13   |
| 1.3.9. Alüvyon (Qal).....                                                          | 13   |
| 2. ÖNCEKİ ÇALIŞMALAR.....                                                          | 14   |
| 2.1. Çalışma Alanının Jeolojisi ve Jeomorfolojisine İlişkin Önceki Çalışmalar .... | 14   |
| 2.2. Tez Konusuna Temel Oluşturan Önceki Çalışmalar .....                          | 16   |
| 3. HEYELAN KAVRAMI VE HEYELAN DUYARLILIK HARİTALAMALARI .....                      | 34   |

|                                                                               |    |
|-------------------------------------------------------------------------------|----|
| 3.1. Heyelan Kavramı ve Heyelan Sınıflaması.....                              | 34 |
| 3.2. Heyelan Duyarlılığına İlişkin Temel Kavramlar .....                      | 36 |
| 3.3. Heyelan Duyarlılık Değerlendirmelerinde Kullanılan Yöntemler.....        | 37 |
| 4. YAPAY SİNİR AĞI SİSTEMLERİ .....                                           | 40 |
| 4.1. Yapay Sinir Ağlarının Tarihçesi.....                                     | 40 |
| 4.2. ANN Sistemlerinin Yapısı.....                                            | 41 |
| 4.3. Yapay Sinir Ağı Topolojisi .....                                         | 43 |
| 4.3.1. Çok Tabakalı İleri Beslemeli Ağ (Multilayer Feedforward Network) ..... | 43 |
| 4.4. Eğitim Algoritmaları (Training Algorithms).....                          | 46 |
| 4.4.1. Geri Yayılım (Batch-Backpropagation) (BBP).....                        | 46 |
| 4.4.2. Hızlı Yayılım (Quick Propagation) (QP) .....                           | 47 |
| 4.4.3. Eşlenik Eğim (Conjugate Gradient Descent) (CGD) .....                  | 48 |
| 4.4.4. Levenberg–Marquardt Algoritması (LM) .....                             | 48 |
| 5. HEYELAN ENVANTERİ VE PARAMETRE HARİTALARININ OLUŞTURULMASI.....            | 51 |
| 5.1. Heyelan Envanteri.....                                                   | 51 |
| 5.2. Parametre Haritalarının Oluşturulması.....                               | 55 |
| 5.2.1. Sayısal yükseklik modeli (SYM) ve SYM'den türetilen parametreler.....  | 55 |
| 5.2.1.1. Topoğrafik yükseklik .....                                           | 56 |
| 5.2.1.2. Yamaç eğimi .....                                                    | 58 |
| 5.2.1.3. Bakı .....                                                           | 60 |
| 5.2.1.4. Topoğrafik Nemlilik İndeksi .....                                    | 62 |
| 5.2.2. Jeolojik Parametre .....                                               | 64 |
| 5.2.2.1. Litoloji .....                                                       | 64 |
| 5.2.3. Çevresel Parametre.....                                                | 66 |
| 5.2.3.1. Bitki örtüsü indeksi (NDVI).....                                     | 66 |

|                                                                          |     |
|--------------------------------------------------------------------------|-----|
| 6. ANN ANALİZLERİ VE HEYELAN DUYARLILIK HARİTALARININ OLUŞTURULMASI..... | 68  |
| 6.1. ANN Tasarımı .....                                                  | 68  |
| 6.1.1. Veri Setlerinin Hazırlanması .....                                | 70  |
| 6.1.2. Gizli Tabaka ve Nöron Sayısının Belirlenmesi .....                | 71  |
| 6.1.3. Aktivasyon Fonksiyonu .....                                       | 80  |
| 6.1.4. Öğrenme ve Momentum Katsayısı .....                               | 80  |
| 6.1.5. İterasyon Sayısı .....                                            | 80  |
| 6.1.6. MSE (Ortalama Karesel Hata) .....                                 | 81  |
| 6.1.7. ANN'da Aşırı Öğrenmenin Kontrol Edilmesi .....                    | 81  |
| 6.2. Heyelan Duyarlılık Haritalarının Oluşturulması .....                | 87  |
| 6.2.1. BBP1 Modeli .....                                                 | 88  |
| 6.2.2. BBP2 Modeli .....                                                 | 91  |
| 6.2.3. QP1 Modeli .....                                                  | 94  |
| 6.2.4. QP2 Modeli .....                                                  | 97  |
| 6.2.5. CGD1 Modeli .....                                                 | 100 |
| 6.2.6. CGD2 Modeli .....                                                 | 103 |
| 6.2.7. LM1 Modeli .....                                                  | 106 |
| 6.2.8. LM2 Modeli .....                                                  | 109 |
| 6.3. Heyelan Duyarlılık Haritalarının Performans Değerlendirmesi .....   | 112 |
| 7. SONUÇLAR VE TARTIŞMA .....                                            | 117 |
| KAYNAKLAR.....                                                           | 126 |
| EKLER .....                                                              | 131 |
| ÖZGEÇMİŞ .....                                                           | 140 |

# ŞEKİLLER

## Sayfa

|                                                                                                             |    |
|-------------------------------------------------------------------------------------------------------------|----|
| Şekil 1.1. 1900-2011 yılları arasında dünyada meydana gelmiş doğal afetlerin sayısal dağılımı [4].          | 2  |
| Şekil 1.2. 2011 yılında dünyada meydana gelen doğal afet dağılımı (CRED [1]'den değiştirilerek alınmıştır.) | 3  |
| Şekil 1.3. Küresel heyelan tehlike dağılım haritası [6].                                                    | 5  |
| Şekil 1.4. Orta Asya ve Orta Doğu bölgeleri heyelan tehlike dağılım haritası [6].                           | 5  |
| Şekil 1.5. Çalışma alanının yer bulduru haritası.                                                           | 8  |
| Şekil 1.6. Batı Karadeniz Bölgesi ana tektonik birlikler [11].                                              | 9  |
| Şekil 1.7. Çalışma alanının jeolojik özellikleri [13].                                                      | 10 |
| Şekil 2.1. Çalışmalarda dikkate alınan parametreler ve kullanım oranları.                                   | 30 |
| Şekil 2.2. Çalışmalarda kullanılan parametreler ve sayıları.                                                | 31 |
| Şekil 3.1. Heyelan özelliklerini tanımlayan terminoloji [42].                                               | 34 |
| Şekil 4.1. İki nöron içeren bir biyolojik sinir ağı [46].                                                   | 40 |
| Şekil 4.2. Tipik bir yapay nöron [46].                                                                      | 42 |
| Şekil 4.3. Sigmoid fonksiyonu (Lippmann [60] 'dan değiştirilerek alınmıştır).                               | 43 |
| Şekil 4.4. Çok tabakalı bir ANN modeli [61].                                                                | 44 |
| Şekil 5.1. Çalışma alanı içerisindeki heyelanların mekansal dağılımları.                                    | 52 |
| Şekil 5.2. Çalışma alanındaki heyelanların alansal dağılımları.                                             | 53 |
| Şekil 5.3. Çalışma alanı içerisinde meydana gelen heyelanlara ait örnek fotoğraflar.                        | 54 |
| Şekil 5.4. (a) düzenli grid yapısı ve (b) üçgen şeklinde düzensiz ağ yapısı.                                | 56 |
| Şekil 5.5. Çalışma alanının sayısal yükseklik modeli.                                                       | 57 |
| Şekil 5.6. Çalışma alanına ait yamaç eğimi haritası.                                                        | 59 |
| Şekil 5.7. Çalışma alanına ait bakı haritası.                                                               | 61 |
| Şekil 5.8. Çalışma alanına ait nemlilik indeksi haritası.                                                   | 63 |

|                                                                                                                                             |     |
|---------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Şekil 5.9. Çalışma alanına ait bitki örtüsü indeksi haritası.....                                                                           | 67  |
| Şekil 6.1. Akış şeması.....                                                                                                                 | 69  |
| Şekil 6.2. Tek gizli tabakalı ANN tasarımı (6-13-1).....                                                                                    | 79  |
| Şekil 6.3. İki gizli tabakalı ANN tasarımı (6-11-6-1).....                                                                                  | 79  |
| Şekil 6.4. ANN modellerinin eğitim performans grafikleri; (a):BBP1, (b):BBP2, (c):QP1, (d):QP2, (e):CGD1, (f):CGD2, (g):LM1 ve (h):LM2..... | 83  |
| Şekil 6.5. BBP1 modeline göre duyarlılık dağılımları.....                                                                                   | 89  |
| Şekil 6.6. BBP1 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.....                                                        | 89  |
| Şekil 6.7. BBP1 Modelinden elde edilen heyelan duyarlılık haritası.....                                                                     | 90  |
| Şekil 6.8. BBP2 modeline göre duyarlılık dağılımları.....                                                                                   | 91  |
| Şekil 6.9. BBP2 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.....                                                        | 92  |
| Şekil 6.10. BBP2 Modelinden elde edilen heyelan duyarlılık haritası.....                                                                    | 93  |
| Şekil 6.11. QP1 modeline göre duyarlılık dağılımları.....                                                                                   | 94  |
| Şekil 6.12. QP1 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.....                                                        | 95  |
| Şekil 6.13. QP1 Modelinden elde edilen heyelan duyarlılık haritası.....                                                                     | 96  |
| Şekil 6.14. QP2 modeline göre duyarlılık dağılımları.....                                                                                   | 97  |
| Şekil 6.15. QP2 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.....                                                        | 98  |
| Şekil 6.16. QP2 Modelinden elde edilen heyelan duyarlılık haritası.....                                                                     | 99  |
| Şekil 6.17. CGD1 modeline göre duyarlılık dağılımları.....                                                                                  | 100 |
| Şekil 6.18. CGD1 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.....                                                       | 101 |
| Şekil 6.19. CGD1 Modelinden elde edilen heyelan duyarlılık haritası.....                                                                    | 102 |
| Şekil 6.20. CGD2 modeline göre duyarlılık dağılımları.....                                                                                  | 103 |

|                                                                                               |     |
|-----------------------------------------------------------------------------------------------|-----|
| Şekil 6.21. CGD2 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.....         | 104 |
| Şekil 6.22. CGD2 Modelinden elde edilen heyelan duyarlılık haritası. ....                     | 105 |
| Şekil 6.23. LM1 modeline göre duyarlılık dağılımları. ....                                    | 106 |
| Şekil 6.24. LM1 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.....          | 107 |
| Şekil 6.25. LM1 modelinden elde edilen heyelan duyarlılık haritası. ....                      | 108 |
| Şekil 6.26. LM2 modeline göre duyarlılık dağılımları. ....                                    | 109 |
| Şekil 6.27. LM2 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.....          | 110 |
| Şekil 6.28. LM2 modelinden elde edilen heyelan duyarlılık haritası. ....                      | 111 |
| Şekil 6.29. BBP1; BBP2; QP1 ve QP2 modellerine ait ROC eğrileri. ....                         | 113 |
| Şekil 6.30. CGD1; CGD2; LM1 ve LM2 modellerine ait ROC eğrileri. ....                         | 114 |
| Şekil 6.31. "Rij" modülünün akış şeması (Ercanoğlu [72]'dan değiştirilerek alınmıştır.) ..... | 116 |
| Şekil 7.1. Girdi parametrelerinin önem dereceleri.....                                        | 120 |
| Şekil 7.2. ANN modellerinden üretilen haritaların duyarlılık dağılımları. ....                | 121 |
| Şekil 7.3. Mevcut haritalanmış heyelanların duyarlılık sınıfları içindeki dağılımları. ....   | 123 |

## ÇİZELGELER

### Sayfa

|                                                                                                                             |     |
|-----------------------------------------------------------------------------------------------------------------------------|-----|
| Çizelge 1.1. Doğal afet sınıflaması [1].....                                                                                | 2   |
| Çizelge 1.2. 2000-2014 yılları arasında dünyada meydana gelen bazı büyük heyelanlar [9].....                                | 6   |
| Çizelge 2.1. Farklı araştırmacılar tarafından ANN ile heyelan duyarlılık değerlendirmelerinde kullanılan parametreler. .... | 32  |
| Çizelge 3.1.Varnes [42] tarafından önerilen heyelan sınıflama sistemi. ....                                                 | 35  |
| Çizelge 3.2. Hungr vd. [43] tarafından güncellenen Varnes [42] sınıflama sistemi. ....                                      | 36  |
| Çizelge 3.3. Heyelan duyarlılık değerlendirmesinde kullanılan yöntemler [45]. ....                                          | 38  |
| Çizelge 5.1. Litolojik birimlerin saha içerisindeki genel dağılımları. ....                                                 | 65  |
| Çizelge 6.1. Tek gizli tabakalı ANN'nin farklı ağ yapılarına ait hata oranları. ....                                        | 73  |
| Çizelge 6.2. İki gizli tabakalı ANN'nin farklı ağ yapılarına ait hata oranları. ....                                        | 74  |
| Çizelge 6.3. ANN modellerine ilişkin $r_{ij}$ değerleri.....                                                                | 115 |
| Çizelge 7.1. ANN modellerinin analiz sonuçları.....                                                                         | 119 |
| Çizelge 7.2. ANN modellerinin AUC ve $r_{ij}$ değerleri. ....                                                               | 124 |

## SİMGELER VE KISALTMALAR

|        |                                                                |
|--------|----------------------------------------------------------------|
| ANN    | Artificial Neural Network                                      |
| ASTER  | Advanced Spaceborne Thermal Emission and Reflection Radiometer |
| AUC    | Area Under Curve (Eğri altında kalan alan)                     |
| BBP    | Batch Back Propagation                                         |
| BP     | Back Propagation                                               |
| CBS    | Coğrafi Bilgi Sistemleri                                       |
| CGD    | Conjugate Gradient Descent                                     |
| CP     | Koşullu Olasılık                                               |
| CRED   | Center for Research on the Epidemiology of Disasters           |
| DEM    | Digital Elevation Model                                        |
| DEMAT  | Dem Analysis Tool                                              |
| EM_DAT | Uluslararası Afet Veritabanı                                   |
| FR     | Frekans Oranı                                                  |
| GSI    | Geological Survey Institute of Japan                           |
| H      | Hessian matrisi                                                |
| J      | Jacobian matrisi                                               |
| km     | kilometre                                                      |
| LM     | Levenberg–Marquardt                                            |
| LR     | Lojistik Regresyon                                             |
| m      | metre                                                          |
| MLP    | Multi Layer Perceptron                                         |
| MSE    | Mean Square Error                                              |
| MTA    | Maden Tetkik ve Arama                                          |
| NDVI   | Bitki Örtüsü İndeksi                                           |


|      |                                                          |
|------|----------------------------------------------------------|
| PNN  | Probabilistic Neural Network                             |
| QP   | Quick Propagation                                        |
| ROC  | Receiver-Operating Characteristics                       |
| SAM  | Sayısal Arazi Modeli                                     |
| SVM  | Destek Vektör Makinesi                                   |
| SYM  | Sayısal Yükseklik Modeli                                 |
| TIN  | Triangular Irregular Networks                            |
| TWI  | Topoğrafik Nemlilik İndeksi                              |
| USGS | Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu |
| YSA  | Yapay Sinir Ağları                                       |

# 1. GİRİŞ

Doğal afet tanımlaması, ulusal veya uluslararası düzeyde yardım gerektiren, ön görülemeyen ve çoğu kez aniden meydana gelen, büyük zararlara ve yıkımlara neden olan bir durum veya olay olarak tanımlanmaktadır [1]. Afet riski ise bir tehlikenin neden olacağı kayıpların (ölümler, yaralanmalar, ekonomik vb.) beklenen değeri olarak tanımlanmaktadır. Afet riski coğrafi olarak belli bölgelerde yoğunlaşmakta olup genel olarak yer yüzeyinin birçok bölümü, afet riskinin yüksek olduğu kesimleri kapsamaktadır. Ekonomik risk, ölüm riskine göre daha hızlı artış göstermekte ve bu artışlar da kentsel büyümeye bağlı olarak değişim göstermektedir [2]. Doğal afetler, gelişmiş ve/veya gelişmekte olan ülkeleri daha fazla etkilemektedir. Ancak, benzer şiddete sahip afetler, erken uyarı, afete hazırlık ve anında müdahale sistemlerine sahip olan gelişmiş ülkelerde, ekonomik kayıplar daha yüksek olsa dahi, daha az can kayıplarına neden olabilmektedir. Risk dereceleri, tehlike sıklığı ve şiddetine bağlı olarak zamanla değişim gösterebilmektedir.

Günümüzde gelişmiş ve gelişmekte olan ülkelerde doğal afetlerin yol açtığı hasarların artmasının temelinde, deprem, sel ve heyelan gibi doğa olaylarının sayısının artmasına ek olarak, hızlı nüfus artışı ve tehlikeli bölgeler üzerinde yerleşim ve yaşam alanları kurulması gibi insan etkileri de bulunmaktadır [3]. CRED (the Center for Research on the Epidemiology of Disasters) 1900 yılından günümüze kadar dünya genelinde meydana gelen 19.500'den fazla afet bilgisini EM\_DAT adı altında (Uluslararası Afet Veritabanı) tutmaktadır. Şekil 1.1'de 1900-2011 yılları arasında dünyada meydana gelmiş doğal afetlerin sayısal dağılımı verilmiştir. Bu şekil incelendiğinde, son 50-60 yıl içinde doğal afet sayısında önemli artışların olduğu görülmektedir. Bu artışın doğal afetlere ilişkin kayıtların tutulmasındaki artışla paralel olduğu söylenebilir. Ancak, nüfus artışına bağlı olarak tehlike arz eden bölgelerde yerleşimin gelişmesi, kısaca insan etkisi de, bu artışın en temel nedenlerinden biridir. Ayrıca, doğal afetlerin neden olduğu sosyo-ekonomik zararların son yıllarda, tüm dünyada çeşitli nedenlerden dolayı arttığı da görülmektedir. Örneğin; CRED, 2011 yılında dünya genelinde meydana gelen toplam 332 doğal afet olayının kayıtlara geçtiğini, bu rakamın 2001 ve 2010 yılları arasında ortalama yıllık afet sıklığından daha az olmasına karşın, insani ve ekonomik etkilerinin daha fazla olduğunu belirtmiştir. 2011 yılında gelişen doğal

afetlerden 244,7 milyon insanın etkilendiği, 30.773 insanın yaşamını yitirdiği ve tahmini olarak 366,1 milyar doların üzerinde ekonomik zararın olduğu rapor edilmiştir.




Şekil 1.1. 1900-2011 yılları arasında dünyada meydana gelmiş doğal afetlerin sayısal dağılımı [4].

EM\_DAT'ın veritabanında yer alan doğal afetler; biyolojik, jeolojik, hidrolojik, meteorolojik ve iklimsel olarak 5 ana başlık altında 12 tipte sınıflandırılmaktadır (Çizelge 1.1).

Çizelge 1.1. Doğal afet sınıflaması [1].

| Doğal Afetler    |                             |                            |              |                |
|------------------|-----------------------------|----------------------------|--------------|----------------|
| Biyolojik        | Jeolojik                    | Hidro-Meteorolojik         |              |                |
|                  |                             | Hidrolojik                 | Meteorolojik | İklimsel       |
| Salgın Hastalık  | Deprem                      | Sel                        | Kasırga      | Aşırı Sıcaklık |
| Böcek İstilasası | Volkan Patlaması            | Kütle Hareketleri<br>(yaş) |              | Kuraklık       |
| Hayvan İzdihamı  | Kütle Hareketleri<br>(kuru) |                            |              | Orman Yangını  |

2011 yılında dünya genelinde meydana gelen doğal afetlerin %52.1'ini hidrolojik, %25.3'ünü meteorolojik, %11.7'sini iklimsel ve %10.8'ini jeolojik afetler oluşturmaktadır (Şekil 1.2).



Şekil 1.2. 2011 yılında dünyada meydana gelen doğal afet dağılımı (CRED [1]'den değiştirilerek alınmıştır.)

Deprem, sel ve kasırgalarla birlikte dünyada en sık görülen doğal afetlerden biri de heyelanlardır. Deprem, şiddetli yağış veya insan etkisi gibi tetikleyici etkenlerin tek başına veya aynı anda etkimesiyle meydana gelen heyelanlar, dünyada en fazla can ve mal kaybına yol açan doğa olayları arasında yer almaktadır [5]. Son yıllarda heyelanlar gibi küresel ölçekte büyük afetlere neden olan olaylarda da bir artış olduğu görülmektedir.

Heyelan oluşumunda gözlenen artışın başlıca nedenleri, doğal kaynakların ve ormanların tahrip edilmesi sonucu zeminde gelişen duraysızlıklar ve nüfus artışına bağlı olarak büyüyen kentleşme ve kontrolsüz arazi kullanımındır. Ayrıca, yerleşimin olmadığı dağlık bölgelerde, ulaşım amaçlı yapılaşmaların olması nedeniyle, tehlike sınırları içerisine girilmektedir. Heyelan oluşumundaki bu artışta, iklimsel değişimlerin de önemli bir etkiye sahip olduğu belirtilmektedir [6].


Şekil 1.3'te dünya genelinde heyelan tehlike dağılım haritası verilmektedir. Bu şekle bakıldığında, orta ila çok yüksek derece heyelan tehlikesine sahip başlıca bölgeler; Orta Amerika, kuzeybatı Güney Amerika, kuzeybatı Amerika ve Kanada,

Kafkas bölgesi, İran, Türkiye, Himalayalar, Filipinler, Endonezya, Japonya ve Yeni Zelanda olarak sıralanabilir. Orta Asya ve Orta Doğu bölgeleri için daha detaylı bir heyelan tehlikesi haritası ise Şekil 1.4'te yer almaktadır. Bu bölgelerde yer alan ülkelere bakıldığında, Gürcistan, Ermenistan, Türkiye, İran, güney Rusya'nın küçük bir kısmı, Tacikistan, Kırgızistan, Afganistan, Nepal, kuzey Hindistan ve güney Çin'nin, orta ila ileri, yüksek ve çok yüksek heyelan tehlikesine sahip olduğunu söylebiliriz. Ayrıca Türkiye'nin özellikle dağlık kesimleri ile bol yağış alan kuzeybatı ve kuzeydoğu bölgelerinin, ileri veya yüksek ile çok yüksek derece heyelan tehlike bölgesi içinde yer aldığı görülmektedir [6].


2000 ve 2014 yılları arasında, dünya genelinde meydana gelen, can ve mal kaybına yol açan bazı büyük heyelanlar ise, USGS (Amerika Birleşik Devletleri Jeoloji Araştırmaları Kurumu) veri tabanından derlenmiş ve Çizelge 1.2' de sunulmuştur.

Heyelanların neden olduğu zararların azaltılmasına yönelik çalışmaların en önemli aşamalarından biri, heyelan türü, aktivitesi ve coğrafi konumu gibi özellikleri tanımlayan heyelan envanterinin ve heyelan özelliklerini yansıtacak bir veri tabanının oluşturulmasıdır. Hazırlanan bu veri tabanından yola çıkarak heyelan duyarlılık, tehlike ve risk değerlendirmeleri yapılabilmektedir [3], [7], [8].

Bu tez çalışmasında, yukarıda değinilen doğal afet kapsamı ve heyelan özeliğini temel alarak, Türkiye'de heyelanların sıklıkla meydana geldiği Batı Karadeniz Bölgesi'nde seçilen Karabük ili, Ovacık ilçesi içerisinde seçilmiş bir alanının yapay sinir ağları (ing. Artificial Neural Network (ANN)) kullanılarak heyelan duyarlılık haritalarının üretilmesi ve elde edilen sonuç haritalarının performanslarının değerlendirilmesi amaçlanmıştır. Bu amaç doğrultusunda, geri yayılım, hızlı yayılım, eşlenik eğitim ve Levenberg-Marquardt gibi farklı eğitim algoritmalarıyla eğitilen ANN modelleri kullanılarak, heyelan duyarlılık haritaları oluşturulmuş ve elde edilen sonuç haritaları ile mevcut heyelan envanter haritası karşılaştırılarak, bu algoritmaların sonuçlar üzerindeki etkileri ortaya konulmuştur.



Şekil 1.3. Küresel heyelan tehlike dağılım haritası [6].



Şekil 1.4. Orta Asya ve Orta Doğu bölgeleri heyelan tehlike dağılım haritası [6].

Çizelge 1.2. 2000-2014 yılları arasında dünyada meydana gelen bazı büyük heyelanlar [9].


| Yıl  | Bölge                    | Heyelan Türü                         | Tetikleyici Unsur        | Kayıplar                        |
|------|--------------------------|--------------------------------------|--------------------------|---------------------------------|
| 2000 | Tibet                    | Toprak Kayması                       | Kar ve Buzul erimesi     | 109 ölü                         |
| 2001 | El Salvador              | Yanal Yayılma                        | Deprem                   | ~585 ölü                        |
| 2002 | Kuzey Ossetia, Rusya     | Moloz Akması                         | Buzul parçalanması       | 125 ölü                         |
| 2003 | Sri Lanka                | Moloz Akması                         | Yağış                    | 260 ölü ve 180,000 evsiz        |
| 2003 | Kaliforniya, Amerika     | Moloz Akması                         | Yağış                    | 16 ölü                          |
| 2005 | Pakistan, Hindistan      | Kaya Düşmesi                         | Kashmir Depremi (7.6)    | 25,500 ölü                      |
| 2006 | Leyte, Filipinler        | Kaya ve Moloz Akması                 | Yağış                    | 1,100 ölü ve 375 evsiz          |
| 2008 | Sichuan, Çin             | Toprak Kayması, Kaya ve Moloz Akması | Wenchuan Depremi (8.0)   | 20,000 ölü                      |
| 2008 | Doğu Cairo, Mısır        | Kaya Kayması                         | İnsan Yapımı İnşaatlar   | 107 ölü, 57 yaralı ve 400 kayıp |
| 2010 | Bududa, Uganda           | Moloz Akması                         | Şiddetli Yağış           | 400+ ölü                        |
| 2010 | Rio De Janeiro, Brezilya | Moloz Akması                         | Şiddetli Yağış           | 350 ölü                         |
| 2012 | Filipinler               | Kaya ve Moloz Akması                 | Tayfun ve Şiddetli Yağış | 200+ ölü ve kayıp, 50,000 evsiz |
| 2013 | Endonezya                | Kaya ve Moloz Akması                 | Şiddetli Yağış           | 19 ölü                          |
| 2013 | Petropolis, Brezilya     | Çamur Akması                         | Şiddetli Yağış           | 13 ölü                          |
| 2014 | Badahşan, Afganistan     | Moloz Akması                         | Şiddetli Yağış           | 2100+ ölü                       |

### 1.1. Çalışma Alanının Tanıtımı

Çalışma alanı; Batı Karadeniz Bölgesi'nde Karabük ili Ovacık ilçesi sınırları içinde, 1/25000 ölçekli Zonguldak F29-c3 ve Zonguldak F29-c4 paftaları içinde olup, 36. UTM zonunun N4540000 – 4550000 / E480000 - 500000 koordinatları arasında yer almakta ve 200 km<sup>2</sup>'lik bir alanı kapsamaktadır (Şekil 1.5).

Çalışma alanında yer alan en önemli yerleşim merkezi, Karabük ilinin güney doğusunda bulunan Ovacık ilçesidir. Dağlık ve engebeli bir arazi yapısına sahip çalışma alanındaki en önemli yükseltiler; Kırış Tepe (1448 m), Aktaşerenler Tepe (1442 m), Nişançalısı Tepe (1394 m), Üçoluk Tepe (1378 m), Mantarlık Tepe (1340 m) ve Asarındoruk Tepe (1328 m)' dir. Bölgedeki en önemli akarsular, Ovacık İlçesi'nin kuzeyinden gelen Soğanlı Çayı'nın kolları olan; Bağırsak Deresi ve Koltuk Deresidir (Şekil 1.5).

Çalışma alanında, bölgede karasal iklimin yanı sıra bol yağışlı tipik Karadeniz iklimi de egemendir. Kış aylarının soğuk ve kar yağışlı olması, uzun süren don olayları, bahar ve yaz aylarında etkin olan ani ve şiddetli yağışların, bölgedeki heyelanların gelişmesinde önemli bir rol oynadığı, yerel halk tarafından bildirilmektedir. Yoğun olarak Karadeniz bitki örtüsüne sahip çalışma alanında; karaçam, sarıçam, meşe ve kayın türleri görülmekte olup, alt florada kızılçık, kuşburnu ve fındık türleri bulunmaktadır [10].



Şekil 1.5. Çalışma alanının yer bulduru haritası.

## 1.2. Çalışma Alanının Bölgesel Jeolojik Özellikleri

Çalışma alanının içinde bulunduğu Batı Karadeniz Bölgesi, Türkiye'nin en önemli tektonik kuşaklarından biri olan Batı Pontidler içerisinde İstanbul-Zonguldak zonu, Armutlu-Ovacık zonu ve Sakarya kıtasından oluşmaktadır (Şekil 1.6). İstanbul-Zonguldak zonunun temeli, bölgesel uyumsuzluklarla birbirinden ayrılan dört birimden oluşmaktadır. Bu birimler alttan üste doğru sırasıyla, Paleozoyik yaşlı karasal çakıltaşları, arkozik kumtaşı ve denizel kırıntılılar, Triyas yaşlı oldukça kalın menderesli nehir ve taşkın ovası çökelleri, Orta Jura yaşlı kumtaşı, silttaşı ve silisi-klastik türbiditler ile Üst Jura-Alt Kretase yaşlı platform karbonatlarından oluşmaktadır [11]. Paleozoyik yaşlı birimler üzerinde paralel diskordanslı olarak Oksfordiyen yaşlı ile başlayan, Alt Kretase'ye kadar uzanan Zonguldak formasyonu yer almaktadır [12]. Ulus formasyonu; konglomera, kumtaşı, kıltaşı ve silttaşı ardalanmasından oluşan filiş karakterli birimlerden oluşmaktadır.

Ulus formasyonu üzerinde Maastrichtiyen yaşlı Alaplı formasyonu, Alaplı formasyonu üzerinde de Eosen filiş olarak adlandırılan Çaycuma formasyonu ile Kuvaterner oluşumları bulunmaktadır [12].




Şekil 1.6. Batı Karadeniz Bölgesi ana tektonik birlikler [11].

## 1.3. Stratigrafi

Çalışma alanında yaşları Alt Kretase'den Kuvaterner'e kadar değişen değişik kayaç grupları yer almaktadır. Bu tez çalışmasında MTA Genel Müdürlüğü

tarafından üretilen 1/100000 ölçekli jeoloji haritası (MTA, 2002) temel alınmış ve çalışma alanında yer alan formasyonlar aşağıda açıklanmıştır. Çalışma alanına ilişkin genel jeolojik özellikler Şekil 1.7’de sunulmuştur.



#### AÇIKLAMALAR

|       |                                                                                       |
|-------|---------------------------------------------------------------------------------------|
| Qal   | Alüvyon (Kuvaterner)                                                                  |
| tea   | Akçapınar Formasyonu: Killi kireçtaşı, çört ve jips (Orta Eosen)                      |
| teso  | Soğanlı Formasyonu: Neritik Kireçtaşı, marn (Orta Eosen)                              |
| teka  | Karabük Formasyonu: Kumtaşı, silttaşı, çamurtaşı, konglomera (Alt-Orta Eosen)         |
| tekaç | Çeçen Üyesi: Kumtaşı, silttaşı, çamurtaşı, konglomera (Alt-Orta Eosen)                |
| tes   | Safranbolu Formasyonu: Kireçtaşı, marn (Alt-Orta Eosen)                               |
| tek   | Kışlaköy Formasyonu: Konglomera, kumtaşı, çamurtaşı, kumtaşı (Üst Paleosen-Alt Eosen) |
| Ktab  | Abant Formasyonu: Filiş (Üst Kampaniyen-Alt Eosen)                                    |
| ku    | Ulus Formasyonu: Kumtaşı, şeyl, konglomera, kireçtaşı (Alt Kretase)                   |
| —     | Yapısal Unsurlar                                                                      |
| ●     | Yerleşim                                                                              |

Şekil 1.7. Çalışma alanının jeolojik özellikleri [13].

### **1.3.1. Ulus Formasyonu (Ku)**

Şeyl, kıltaşı, marn, kireçtaşı gibi yerinde çökelmiş sedimanlarla kumtaşı, kumlu kireçtaşı ve konglomera gibi türbiditik çökellerin aralanmasından oluşan Ulus formasyonu, ilk olarak Akyol vd. (1974) tarafından tanımlanmıştır. Birim genellikle kumlu kireçtaşı ara tabakalı, grimsi yeşil, gri ve siyah renkli kumtaşı, şeyl, marn ve konglomeralardan oluşmaktadır. Çalışma alanının güneyinden itibaren batısı kesimlerine doğru yer alan Ulus formasyonunun yaşı, barındırdığı fosil içeriğine göre Alt Kretase olarak belirlenmiştir [13].

### **1.3.2. Abant Formasyonu (Ktab)**

Bloklu konglomera, kumtaşı, silt ve marndan oluşan birim Timur ve Aksay [13] tarafından adlandırılmıştır. Kırıntılı ve karbonat türü kayaçlar içeren birim, olistostromal kesimlerden, fliş istifi özelliği gösteren düzeylerden ve karasal-sığ deniz fasiyeslerindeki çökellerden oluşur. Olistostromlar çeşitli cins, köken yaşıta bloklar içeren türbiditik çökeller, moloz akma çökelleri, pelajik çamurtaşı, mikrit kireçtaşı ve marnlardan oluşur. Bu çökellerde akma, kayma yapıları gözlenir. Çalışma alanının güneydoğusunda küçük bir alanda yer alan bu formasyonun yaşı Üst Kampaniyen - Alt Eosen'dir [13].

### **1.3.3. Kışlaköy Formasyonu (Tek)**

Karabük, Safranbolu Tersiyer havzasının tabanını oluşturan konglomera, marn, kumtaşı, kireçtaşı, silttaşı ve kıltaşları ile temsil edilen istif Kışlaköy formasyonu olarak tanımlanır. Formasyonun tabanını, kırmızı, sarı, yeşil renkli konglomeralar oluşturur. Bu seviyenin üzerine dereceli olarak kıltaşı, silttaşı ve marn aralanması gelir. Formasyonun en üst seviyesinde ise kırmızı renkli kumtaşı, konglomera ve çamurtaşları yer alır. Kışlaköy formasyonu, Alt Kretase yaşlı Ulus formasyonu üzerinde açısız uyumsuzlukla yer almakta ve Eosen yaşlı Safranbolu formasyonu ile tedrici geçişlidir. Çalışma alanının doğusundan başlayıp batısına doğru yayılım gösteren Kışlaköy formasyonun yaşı, içeriğindeki fosil durumuna göre Üst Paleosen - Alt Eosen'dir [13].

#### **1.3.4. Safranbolu Formasyonu (Tes)**

Safranbolu formasyonu altta çok ince bir konglomera-kumtaşı seviyesi ile başlar ve üste doğru karbonatlı kumtaşı, kumlu kireçtaşı ve kireçtaşına geçer. Genellikle, orta-kalın tabakalı, sarımsı, beyaz, açık gri-pembe renklidir. Safranbolu formasyonu Safranbolu-Karabük havzasının kuzeyinde Ulus formasyonu üzerinde açısız uyumsuzlukla yer almakta olup, havzanın güneyinde ise Kışlaköy formasyonunu uyumlu olarak örter. Bol ve çeşitli fosiller içeren kireçtaşlarını kapsayan Safranbolu formasyonun yaşı Alt - Orta Eosen olarak belirlenmiştir [13].

#### **1.3.5. Çerçen Üyesi (Tekaç)**

Kırmızı, yer yer yeşil renkli konglomera, kumtaşı, silttaşı ve çamurtaşı araldanması Timur ve Aksay [13] Çerçen üyesi olarak adlandırılmıştır. Çerçen üyesi Karabük formasyonun üst kesimlerinde tedrici geçişli olarak yer alır. Birimin yaşı stratigrafik konumuna dayanılarak Orta Eosen olarak belirlenmiştir [13].

#### **1.3.6. Karabük Formasyonu (Teka)**

İlk kez Saner vd. (1980) tarafından adlandırılan Karabük formasyonu alt kesimleri çoğunlukla marn, üste doğru kilttaşı ve kumtaşı araldanmasından oluşur. Marnlar çok az kumtaşı ara seviyeleri içerir. Üst kesimlere doğru kumtaşı ara katkıları artar. En üst seviyelerde ise tamamen kumtaşı karakterindedir. Karabük formasyonu tedrici geçişli olarak Safranbolu formasyonu üzerinde yer alır ve Soğanlı formasyonu tarafından uyumlu olarak üzerlenir. Birimin yaşı tespit edilen fosillere göre Orta Eosen olarak belirlenmiştir [13].

#### **1.3.7. Soğanlı Formasyonu (Teso)**

Orta Eosen yaşı, kalın tabakalı kireçtaşları, Soğanlı formasyonu olarak tanımlanmıştır ve bu birim tamamen kireçtaşları ile temsil edilir. Formasyonun alt kesimlerinde detritik kireçtaşı seviyeleri yer alır. Üst kesimlere doğru tedrici olarak mikritik kireçtaşlarına geçer. Soğanlı formasyonu tabanda Karabük formasyonu Çerçen üyesi ile konkordan dokanak ilişkisi sunar [13].

#### **1.3.8. Akapınar Formasyonu (Tea)**

Beyaz, sarımsı gri renkli, killi kiretaşı, dolomitik kiretaşı ve ört bantları ile karakterize edilden istif, Akapınar formasyonu olarak adlandırılmıştır. Soğanlı formasyonu üzerine uyumlu olarak bulunan Akapınar formasyonu, doğuya doğru incelmekte olup, kalınlığı 150-200m arasında deėişmektedir. İçerisinde fosil tespit edilememiş, stratigrafik konumuna dayanarak birim Orta Eosen yaşı kabul edilmiştir [13].

#### **1.3.9. Alüvyon (Qal)**

Akarsu yataklarında, eski ukurluklar üzerine gelişmiş düz alanlardaki akıl, kum ve amur ökelleridir.

## 2. ÖNCEKİ ÇALIŞMALAR

Bu bölüm, çalışma alanını da içeren jeolojik ve jeomorfolojik çalışmalar ile tez konusunda temel alınan çalışmaları içerecek şekilde iki bölümde sunulmaktadır.

### 2.1. Çalışma Alanının Jeolojisi ve Jeomorfolojisine İlişkin Önceki Çalışmalar

Yergök vd. [12] yaptıkları çalışmada, Batı Karadeniz Bölgesi'nin jeolojisini genel olarak; Zonguldak yakın çevresindeki Paleozoyik yaşlı birimler, Zonguldak yakın çevresi ve sahil boyunca yer alan kesimleri Üst Mesozoyik-Tersiyer istifi ve Karabük yakın çevresi Kuvaterner istifleri şeklinde ayırmışlardır. Bölge ile ilgili en kapsamlı jeolojik çalışma olarak değerlendirilebilen bu çalışmada araştırmacılar bölgedeki formasyonların tanımlanması, kayaç türü özellikleri, birimlerin dokanak ilişkisi, kalınlık, yanal ilişki, fosil içeriği ve ortamsal yorumlamaları ayrıntılı bir şekilde incelemişlerdir.

Duman vd. [14] Batı Karadeniz Bölgesi, Aşağı Filyos vadisinin arazi kullanım potansiyelinin araştırılmasına yönelik yaptıkları çalışmada bölgenin, jeolojik yapı içerisindeki konumu, hidrojeolojik koşulları, kayaç türlerinin dayanım özellikleri, güncel jeomorfolojik süreçleri ve depremselliğe ilişkin verileri değerlendirmişlerdir. Arazi kullanım potansiyeli haritalarının oluşturulmasında litolojik özellikler ve bunların oluşturduğu zemin türleri, genel jeomorfolojik yapı içindeki konum, güncel dinamik süreç ve risklerin dağılımı, topoğrafik eğim, depreme karşı duyarlılık, maden ve endüstriyel hammadde açısından doğal kaynak değerleri esas alınarak sınıflama, heyelan, taşkın vb. doğal afetleri ön planda tutularak yapılmıştır. Araştırmacılar, kütle hareketleri, taşkın vb. doğal afetlere yol açabilen süreçleri ön planda tutarak, inceleme alanını ortak özellik sunan alanlara göre 5 ana sınıfına ayırmışlardır.

İsmailoğlu vd. [15] Batı Karadeniz Bölgesinin Aşağı Filyos Vadisi, Bartın, Karabük ve Alaplı Yörelerini içeren çalışmalarında heyelan ve taşkın alanlarını incelemişlerdir. Araştırmacılar başta Alaplı, Karabük ve Ovacuma olmak üzere tüm akarsu vadileri ve yol güzergâhları boyunca heyelanlar gözlemlemiş ve bu heyelanları oluşum mekanizmalarına göre i) dairesel kaymalar, ii) yarı dairesel-yarı düzlemsel kaymalar ve iii) düzlemsel kaymalar olarak üçe ayırmışlardır. Bölgede

filiş çökellerinin ayrışması sonucu toprak özelliği kazanmış alanlarda, nispeten sığ, çok yavaş olarak gelişen krip türü kütle hareketlerini de gözlemleyen araştırmacılar, Karabük ili içinde çamur akmalarının da büyük tehlike yarattığına değinmişlerdir. Araştırmacılar, potansiyel heyelan duyarlılık haritalarının hazırlanması gerektiğini vurgulayarak, yerleşim ve sanayi alanlarının bu zonların dışına kaydırılmasını ve bunun olanaksız olduğu durumlarda ise kaymanın özelliğine göre yeraltısularının drene edilmesi, şev açısının düşürülmesi ve istinat duvarlarının inşa edilmesi gibi uygulamaların yapılmasını önermişlerdir.

Aksoy [16] Karabük ili'nde yaptığı çalışmada mevcut yerleşim alanları ve olası yerleşim alanlarının belirlenmesi amacıyla genel jeolojik, jeofizik ve jeoteknik incelemelerde bulunmuştur. İnceleme alanını yerleşime uygunluk açısından; yerleşime uygun alanlar, önlemleriyle yerleşilebilir alanlar ve yerleşime uygun olmayan alanlar olarak sınıflandıran Aksoy (2005), şehir merkezinin dışına doğru dik (%20-40) ve çok dik (>%40) yamaçların hakim olduğunu ve yamaç eğimi %40 ve üzerinde olan alanlarda heyelan ve çamur akmalarının yerleşimi ve şehrin büyümesini kısıtladığını belirtmiştir.

Duman vd. [11] MTA tarafında 1997 yılında başlatılan “Türkiye Heyelan Haritası Projesi” kapsamında, tez çalışma alanını da içerdiği Zonguldak Paftası heyelan envanteri çalışmasını gerçekleştirmişlerdir. 39244 km<sup>2</sup>'lik bir yayılıma sahip olan çalışma alanında heyelan lokasyonlarını ve özelliklerini belirlemişler, heyelanları hareket tiplerine göre; düşme, devrilme, kayma ve akma şeklinde, aktivitesine göre; aktif ve aktif olmayan şeklinde ve yenilme yüzeylerinin derinliklerin göre sığ (d<5m) ve derin (d>5m) olarak sınıflandırmışlardır. Çalıştıkları alanda 367'si aktif, 8052'si aktif-derin ve 1596'sı aktif olmayan-derin heyelan olmak üzere toplam alanı 2610 km<sup>2</sup> olan 10015 adet heyelan tespit etmişler ve Kretase ve Eosen yaşlı filiş birimlerin ile Miyosen yaşlı volkanitlerin heyelanların en yoğun geliştiği birimler olarak belirlemişlerdir.

## 2.2. Tez Konusuna Temel Oluşturan Önceki Çalışmalar

Uluslararası literatürde heyelan duyarlılığının haritalanmasına yönelik çok sayıda çalışmaya rastlamak mümkündür. Bu çalışmalarda araştırmacılar, farklı yöntemler kullanarak heyelan duyarlılığını değerlendirmektedirler. Bu zamana kadar yapılan çalışmalarda, doğrusal olmayan ve karmaşık veri analizlerindeki yeteneğiyle ANN'ların heyelan duraylılık haritalamaları için, diğer yöntemlere oranla birçok üstünlüğe sahip olduğu belirtilmektedir [17], [3], [18], [19], [20], [21], [22], [23], [24], [25], [26], [27], [28], [29], [30], [31], [32]. Bu bölümde, tez konusuna da temel teşkil etmesi nedeniyle, sadece ANN kullanılarak gerçekleştirilen çalışmalara değinilmiştir.

Aleotti ve Chowdhury [17] heyelan duyarlılık ve tehlike haritalarının üretilmesinde, çalışmanın yapıldığı zaman için, yeni bir yaklaşım olan yapay sinir ağı yöntemi ile heyelan duyarlılık haritasını üretmek ve heyelan oluşumunda etkin olan parametrelerin ağırlık değerlerini belirlemek amacıyla yaptıkları çalışmada; jeolojik, jeomorfolojik, hidrolojik parametreleri dikkate almışlardır. Çalışmanın ilk aşamasında, arazi çalışmalarıyla heyelan envanter haritası oluşturulmuştur. Sonraki aşamada, heyelan oluşumunda etkin olduğu düşünülen parametrelere ait sayısal veri tabanı oluşturulmuş, sayısal olmayan veriler için göreceli olarak indeks değerler atanmıştır. Son aşamada, ileri beslemeli algoritmaya sahip yapay sinir ağı sistemi ile ağın öğrenme aşaması tamamlanmış ve sorgulama yapılarak çalışma alanının heyelan duyarlılık sınıfları belirlenmiştir. Araştırmacılar, geleneksel yöntemlerle büyük alanlarda yapılması güç olan heyelan duyarlılık değerlendirmelerinde, ANN yönteminin etkin bir yaklaşım olduğunu vurgulamışlardır.

Lee vd. [18] Hong Kong bölgesinin Lantau Adası'nda yaptıkları çalışmada; litoloji, topoğrafik yükseklik, yamaç eğimi, faylara olan yakınlık, drenaj ağı, erozyon, bitki örtüsü ve ortalama yıllık yağış parametrelerini kullanarak, yapay zeka ve CBS (Coğrafi Bilgi Sistemleri) yöntemleri ile heyelan duyarlılık haritası oluşturmuşlardır. Heyelan duyarlılık değerlendirmelerinin; doğal belirsizlikler, veri kalitesi, miktarı ve doğruluğuna bağlı parametre belirsizlikleri ve model belirsizlikleri olmak üzere, 3 tür belirsizlik içerdiğini ifade eden araştırmacılar, doğal belirsizliklerin, doğal koşullardan kaynaklandığını ve azaltılmayacağını belirtmişlerdir. ANN tabanlı

yöntemlerin üstünlüklerinin geleneksel yöntemlerden farklı olarak doğrusal olmayan ilişkileri kullanmaları, farklı nitelikteki verilen analizinde hiçbir sınırlamanın olmaması, sonuçların coğrafi bilgi sistemi ortamına aktarılması ve kullanılmasının basit olması ve yeni verilerin girilmesiyle sistemin otomatik olarak güncellenmesi olduğunu vurgulamışlardır. Kestirim değerleri ile mevcut koşulları değerlendiren araştırmacılar, yöntemin oldukça başarılı ve yüksek güvenilirlikte olduğuna dikkat çekmişlerdir.

Lee vd. [19] ANN yöntemi kullanılarak heyelan duyarlılığı analiz yöntemlerini geliştirmek amacı ile Kore'nin Yongin Bölgesi'nde yaptıkları çalışmada, heyelan oluşumunda etkin olan parametrelerden yamaç eğimi, yamaç şekli, toprak türü ve kalınlığı, drenaj ağı, ağaç yaşı ve ağaç çapını değerlendirmişlerdir. Heyelan envanter haritasını, hava fotoğrafı yorumlamaları ve arazi çalışmaları ile elde etmişlerdir. Heyelan indeksini geri yayımlı ANN yöntemini kullanarak hesaplayan araştırmacılar, duyarlılık haritasını ise CBS kullanarak oluşturmuşlardır. Üretilen heyelan duyarlılık haritasını, mevcut heyelan haritası ile karşılaştıran araştırmacılar, bu haritalar arasında tatmin edici bir uyum olduğunu saptamıştır. Araştırmacılar, ANN yönteminin, kesin ve doğru sonuçlar veren bir araç olduğunun söylenebilmesi için, çalışmanın yapıldığı zaman itibarıyla, daha fazla heyelan verisi ile çalışılması ve farklı alanlarda, yöntemin uygulanması gerektiğini vurgulamışlardır.

Lee vd. [20] yaptıkları çalışmada, ANN ile heyelan duyarlılık haritasının oluşturulması hedeflemişlerdir. Heyelan oluşumunda etkin olan parametrelerden; yamaç eğimi, yamaç şekli, toprak türü, toprak geçirgenliği, toprak kalınlığı, ağaç türü ve çapı olmak üzere toplam yedi parametre değerlendirmişlerdir. Araştırmacılar, ilk aşamada, Lee ve Min [33] tarafından yapılan çalışmada belirlenen, heyelan yoğunluğuna göre parametre sınıflarına atanan değerleri kullanarak, Kore'de Yongin bölgesinin heyelan duyarlılık haritasını oluşturmuşlardır. Sonraki aşamada, ANN yöntemi kullanılarak hesaplanan her bir parametrenin ağırlık değeri, ilk aşamada atanan değerlerle çarpılmış ve elde edilen heyelan duyarlılık indeksi değerleri dikkate alınarak, heyelan duyarlılık haritası oluşturmuşlardır. Araştırmacılar, ağırlık değerleri dikkate alınarak ve alınmayarak oluşturulan heyelan duyarlılık haritalarını karşılaştırmışlar ve ANN

yöntemi ile belirlenen ağırlık değerlerine göre üretilen haritanın performansının daha iyi olduğunu saptamışlardır. Lee vd. [20] ANN yönteminin; verinin istatistiksel dağılımı ile ilgili bir varsayımının bulunmaması, özel istatistiksel değişkenler gerektirmemesi, veri kaynağı ile ilgili sınırlama içermemesi ve dolayısıyla, parametrelere ait istatistiksel dağılımlar ile sınıfların tanımlanmasına olanak sağlaması nedeniyle, diğer istatistiksel yöntemlerden üstün olduğunu vurgulamışlardır.

Ermini vd. [21] heyelan risk haritalamalarının genellikle CBS ile yamaç duraysızlığına neden olan faktörlerin tespit ve analiz edilmesi yöntemiyle gerçekleştirildiğine dikkat çekmiştir. Her bir faktörün kayma sürecine olan etkisi doğrultusunda derecelendirildiği sezgisel yaklaşımların aksine “şimdiki ve geçmiş zaman, geleceğin anahtarıdır” ilkesine dayanan ve geçmiş heyelan olayları ile nedensel faktörler arasındaki ilişkileri istatistiksel olarak değerlendiren diğer yaklaşımların önemine değinmişlerdir. Araştırmacılar, çalışma alanı olarak seçtikleri Kuzey Apennines’in (İtalya) Reno Nehri havzasında heyelana ilişkin faktörler olarak; litoloji, eğim açısı, eğrisellik, arazi örtüsü ve eğim yukarı katkı alanı (upslope contributing area) seçmişlerdir. MLP (Multi-Layered Perceptron) ve PNN (Probabilistic Neural Network) olmak üzere iki farklı ANN modeli kullanmışlardır. Elde edilen heyelan duyarlılık haritalarındaki yüksek duyarlılığa sahip alanlar, güncel heyelan envanteri ile kıyaslanmış; MLP modelinin sınıflandırma (yüksek ve çok yüksek) performansı % 73 oranında iken PNN modeli % 68 doğruluk göstermiştir. Araştırmacılar, sınıflandırma problemlerinde MLP modelin daha uygun olduğunu ve heyelan alanı olmayan bölgelerde yüksek çıktı değerleri veren PNN modelinin bu hatasının, aşırı öğrenme veya hava fotoğraflarında bazı alanların yanlış belirlenmesi olarak açıklamışlardır. Ermini, Catani ve Casagli [21], tatmin edici sonuçlar aldıklarını belirtmişler ve ANN tabanlı istatistiksel yöntemlerin heyelan duyarlılığına yönelik çalışmalar için oldukça teşvik edici olduğunun altını çizmişlerdir.

Ercanoğlu [22] heyelanların sıklıkla geliştiği, Bartın ili’nin Kumluca-Ulus bölgesinde, ANN yöntemini kullanarak, çalışma alanının heyelan duyarlılık haritasını oluşturmuştur. Araştırmacı, heyelan duyarlılığının değerlendirilmesinde kullanılacak girdi parametre haritalarının (yamaç eğimi, eğim yönü, topoğrafik

yükseklik, topoğrafya şekli, nemlilik indeksi ve bitki örtüsü indeksi) oluşturulmasında, SAM (Sayısal Arazi Modeli) ve ASTER (Advanced Spaceborne Thermal Emission and Reflection Radiometer) uydu görüntüsünü kullanmıştır. İlk olarak girdi parametrelerini [0,1] aralığında normalize etmiş ve parametrelerin heyelan oluşumu üzerindeki etkilerini İstatistiksel İndeks Değeri (Wi) kullanarak belirlemiştir. Araştırmacı, yaptığı çalışmada litoloji parametresini, heyelanların tek bir jeolojik birim içinde gelişmiş olması nedeniyle analizlere dahil etmediğini belirtmiş ve ANN'daki ağırlık değişimine göre heyelan oluşumuna etkin en önemli parametrenin topoğrafik yükseklik olduğu sonucuna ulaşmıştır. ANN yöntemi uygulanarak elde edilen heyelan duyarlılık haritasının performansı, alansal yoğunluk, benzerlik ilişki değeri (rij) ve bağımsız bir doğrulama yöntemiyle değerlendiren araştırmacı, alansal yoğunluğu, % 87.2; rij değerini, 0.85 ve doğruluğu, % 82.5 olarak hesaplamıştır. Ercanoğlu [22] bu sonuçların heyelan duyarlılık haritası için tatmin edici olduğunu belirtmiş ve ANN yönteminin, farklı türde heyelanların oluşturduğu karmaşık mekanizmaların değerlendirilmesinde güçlü bir araç olarak kullanılabileceğini vurgulamıştır.

Goméz ve Kavzoğlu [23] Venezuela'nın Jabonosa Nehri Havzası'nda yaptıkları çalışmada heyelan duyarlılık haritasını, ANN yöntemi kullanarak üretmişlerdir. Heyelanların oluşmasında etkin olan parametrelerden; litoloji, topoğrafik yükseklik, yamaç eğimi, bakı, topoğrafik nemlilik indeksi, çizgisellik, toprak türü ve bitki örtüsünü dikkate almışlar ve bu parametrelerin elde edilmesinde, SAM ve uydu görüntülerinden yararlanmışlardır. ANN yönteminin; ihmal ettiği girdi verisindeki ince ayrıntıları tanımlayabilmesi, girdi verisi içinde belirli grupları genelleştirerek bilinmeyen modellerin çözümünde kullanması, girdi verisine ait bilginin otomatik olarak özetlenmesi ve sürekli-kategorik verinin birlikte kullanılabilmesi gibi birçok üstünlüğü olduğuna dikkat çekmişlerdir. ANN ile oluşturdukları heyelan duyarlılık haritasının, % 90 güvenilirlikte olduğunu belirten araştırmacılar, heyelan duyarlılığının değerlendirilmesinde ANN yönteminin son derece iyi sonuçlar verdiğini vurgulamışlardır.

Yeşilnacar ve Topal [24] heyelan değerlendirmelerinde kullanılan jeoteknik yaklaşımların en önemli sınırlamasının, büyük alanlar için, alanı temsil edecek şekilde veri temininin güç olması ve yüksek maliyet gerektirmesi olduğunu

belirtmişlerdir. Bu nedenle, heyelan duyarlılık değerlendirmelerine yönelik çalışmalarda, sıklıkla istatistiksel yöntemlerin kullanıldığını ifade etmişlerdir. Ancak, heyelan oluşumu ile heyelan oluşumunda etkin olan parametreler arasındaki ilişkinin doğrusal olmaması nedeniyle, geleneksel istatistiksel yöntemlerin, heyelan duyarlılık değerlendirmelerinde etkin olamadığını vurgulamışlardır. Araştırmacılar, LR (Lojistik Regresyon) ve ANN yöntemlerinin, bu sınırlamaları içermediğine dikkat çekerek, Batı Karadeniz'in Hendek bölgesinde doğal gaz boru hattının geçtiği bir alanda, her iki yöntemi kullanarak heyelan duyarlılık haritaları oluşturmuşlar. Heyelan oluşumun etkin 19 farklı parametre: baki, drenaj ağına uzaklık, faya uzaklık, sırtlara uzaklık, yola uzaklık, drenaj yoğunluğu, yükseklik, fay yoğunluğu, jeoloji, arazi örtüsü, plan ve profil eğriselliği, yol yoğunluğu, eğim, eğim uzunluğu, akarsu gücü, yüzey alan oranı, topoğrafik nemlilik indeksi, su havzası analiz edilmiştir. Çalışma alanını; çok düşük, düşük, yüksek ve çok yüksek olmak üzere dört heyelan duyarlılığı grubunda sınıflandırmışlardır. Yöntemlerin güvenilirliğini karşılaştırmak amacıyla söz konusu çalışmada, mevcut heyelanlar, oluşturulan haritalar ile karşılaştırılmıştır. LR analizi kullanılarak oluşturulan duyarlılık haritasında; mevcut heyelanların, yaklaşık % 48'inin, çok yüksek ve % 42'sinin yüksek heyelan duyarlılığı zonunda yer aldığı saptanmıştır. ANN yöntemi kullanılarak oluşturulan duyarlılık haritasında ise mevcut heyelanların, yaklaşık % 77'sinin çok yüksek ve % 19'unun yüksek heyelan duyarlılığı sınıfında yer aldığı belirlenmiştir. Yeşilnacar ve Topal [24] ANN yöntemi ile üretilen heyelan duyarlılık haritasının daha gerçekçi sonuçlar verdiğini vurgulamışlardır.

Heyelanların her yıl mal ve can kaybına neden olan doğanın en yıkıcı ve zarar verici faaliyetlerinden biri olduğuna dikkat çeken Kanungo vd. [25] Darjeeling Himalayalar bölgesini kapsayan çalışmalarında; heyelan duyarlılık zonlamasını (LSZ); geleneksel ağırlık atama sistemi, işlemleri ANN tekniğine bağlı objektif ağırlık atama sistemi, bulanık mantık ve kombine nöron ve bulanık küme teorisi yöntemleriyle değerlendirmiştir. Bu yöntemlerle oluşturdukları dört farklı LSZ haritası için heyelan oluşumuna neden olan faktörler olarak litoloji, eğim, baki, çizgisellik, arazi kullanımı ve arazi örtüsü parametrelerini seçmişlerdir. Nedensel faktörler ile ilgili tematik katmanlar uzaktan algılama verileri, saha araştırmaları ve CBS kullanarak oluşturmuşlardır. İlk LSZ haritası (Map-I) nedensel faktörlere ve bu

faktörlerin kategorilerine ağırlık atanması ve derecelendirilmesi uzmanın deneyimine ve bilgi birikimine bağlı olarak yapılan klasik ağırlık atama yöntemine göre oluşturulmuştur. Objektif ağırlık atama yaklaşımında ANN kara kutu yöntemini, ikinci haritanın (Map-II) ve her kategorideki tematik katmanların üyelik değerlerini belirlemek için kosinüs genliğini (benzerlik yöntemi) kullanan bulanık küme teorisi ise üçüncü haritanın (Map-III) üretilmesi için uygulamışlardır. Son olarak, araştırmacılar, her tematik katman ağırlıkları dördüncü bir haritayı (Map-IV) üretmek için bulanık küme yöntemiyle birleştirmişlerdir. Kanungo vd. [25] tüm bu işlemler sonucunda kombine nöron ve bulanık küme teorisi yöntemiyle oluşturulan haritanın (Map-IV) diğerlerine göre daha iyi sonuç verdiği sonucuna ulaşmışlardır.

Yüksel [34] Bartın ili'nin Kumluca-Ulus bölgesinde yaptığı çalışmada, CBS tabanlı heyelan duyarlılık haritalarının oluşturulmasında farklı istatistiksel yöntemlerin ve ANN yönteminin kullanımını araştırmıştır. İki değişkenli istatistiksel analizler, faktör analizi, ayırma analizi, lojistik regresyon analizi ve ANN yöntemleri kullanılarak inceleme alanının heyelan duyarlılık haritalarını oluşturmuş ve sonuç haritalarını kıyaslayarak, bu yöntemlerin güvenilirliğini ortaya koymuştur. Ayrıca, ANN'nin yapısal özelliklerini, ağ topolojilerini ve öğrenme algoritmalarını değiştirerek bu değişimlerin, sonuçlar üzerindeki etkilerini ve ANN yönteminin performansını değerlendirmiştir. Çok değişkenli istatistiksel analiz ve ANN analiz sonuçlarına göre zemin grubu, bitki türü, bitki örtüsü yoğunluğu, topoğrafik yükseklik, topoğrafik nemlilik indeksi ve yollara yakınlık, diğer parametrelere göre heyelan oluşumunda daha etkin parametreler olarak belirlemiştir. Araştırmacı, mevcut heyelanların dağılımını dikkate alarak yaptığı performans değerlendirmeleri sonucunda, "çok yüksek heyelan duyarlılığı"nı temsil eden alanları en iyi yansıtan haritanın, ANN yöntemi ile oluşturulan heyelan duyarlılık haritası olduğu sonucuna ulaşmıştır.

Pradhan ve Lee [26] Malezya'nın Selangor bölgesinde yaptıkları çalışmada ANN modeli kullanılarak, uzaktan algılama verileri ve CBS araçlarının kullanımıyla bölgesel heyelan tehlikesi analizi yapmışlardır. İlk olarak topoğrafik veri tabanından SAM oluşturmuşlar ve yamaç eğim açısı, eğim yönü, eğim eğriselliği ve drenaj gibi jeomorfolojik verileri SAM üzerinden elde etmişlerdir. Jeolojik veri tabanı kullanılarak bölgenin litolojisini çıkartmışlar ve çizgiselliklere olan uzaklıkları

hesaplamışlardır. Araştırmacılar, arazi örtüsüne ilişkin verileri Landsat-TM görüntüsü kullanılarak kontrolsüz sınıflanma yöntemiyle sınıflandırmışlar ve böylece; kentsel, sulak, orman ve tarım alanları, kalay madenleri, kauçuk ve palmye ağacı ekim bölgesi olarak gruplandırılmış farklı sınıfları belirlemişlerdir. Daha sonra, NDVI (Normalize Edilmiş Bitki Örtüsü İndeksi) haritası SPOT uydu görüntüleriyle ve diğer bir faktör olan yağış veri tabanı da meteorolojik verilerin enterpolasyonu ile elde etmişlerdir. ANN uygulamasında doğrulamayı, ANN yöntemiyle elde edilen heyelan tehlike haritası ile bilinen heyelan lokasyon verileri karşılaştırılarak yapmışlar ve yöntemin yüksek bir değer olan % 82.92 oranında doğruluk gösterdiği sonucuna varmışlardır. Faktörler arasındaki göreceli önem ve ağırlıklarını kıyaslayan araştırmacılar; yamaç eğiminin 3.123 ile en yüksek değeri, yamaç eğriselliğinin 1.593 ve faylara uzaklık faktörünün 1.529 değerlerini gösterdiği sonucuna ulaşmışlardır. Pradhan ve Lee [26] yaptıkları çalışmada yamaç eğiminin diğer faktörlere göre 2 kat daha fazla önem taşıyan bir faktör olduğuna dikkat çekmişlerdir.

Yılmaz [27] Tokat ilinin Kat beldesinde yaptığı çalışmada, FR (Frekans Oranı), LR (Lojistik Regresyon) ve ANN yöntemleriyle üretilen heyelan duyarlılık haritalarını karşılaştırmıştır. Araştırmacı, yaptığı analizlerde heyelan oluşumunda etkin faktörler olarak; jeoloji, faylara yakınlık, drenaj sistemi, topoğrafik yükseklik, eğim açısı, eğim yönü, topoğrafik nemlilik indeksi ve akış gücü indeksi kullanmıştır. FR, LR ve ANN yöntemleriyle elde edilen heyelan duyarlılık haritaları var olan heyelan lokasyonları ile karşılaştırılarak AUC (Area Under Curve) değerleri sırasıyla 0.826, 0.842 ve 0.852 olarak hesaplamıştır. Araştırmacı, girdi verilerinin işleme süreci, hesaplamalar ve çıktı alımı süreçlerinin LR ve ANN yöntemlerine göre FR modelinde kolayca anlaşılabilir olduğuna ve bu modelin veri dönüşümlerine ihtiyacı olmadığı vurgulamıştır. Yılmaz [27] ANN yönteminin diğer yöntemlere göre daha doğru sonuçlar verdiğini belirtmekle birlikte, yeterli sayıda veriyle FR modelinin heyelan duyarlılık değerlendirmesi için daha basit bir araç olarak kullanılabileceğine dikkat çekmiştir.

Yılmaz [28] heyelan duyarlılık haritalamasında CP (Koşullu Olasılık), LR, ANN ve SVM (Destek Vektör Makinesi) yöntemlerinin performanslarını değerlendirmiştir. Bu amaç kapsamında Sivas'ın Koyulhisar bölgesinde seçtiği çalışma alanında

heyelan oluşumuna etkin faktörler olarak; jeoloji, yamaç eğimi, yamaç eğim yönü, topoğrafik nemlilik indeksi (TWI), akış gücü indeksi (SPI), normalize edilmiş bitki örtüsü indeksi (NDVI), yerleşim ve yollara uzaklık analiz edilmiştir. Analizin son aşamasında heyelan duyarlılık haritaları, ANN, SVM, LR ve CP, modelleri kullanılarak oluşturulmuş ve daha sonra doğrulama yöntemleri ile karşılaştırmıştır. Doğrulama sonuçlarına göre her yöntem için AUC değerleri; ANN, 0.846; SVM, 0.841; LR, 0.831 ve CP, 0.827 olarak hesaplamıştır. Yılmaz [28] tüm modellerin tatmin edici doğruluk gösterdiğini fakat ANN modelinin diğer modellere göre daha hassas olduğunu belirtmiş ve diğer yöntemlerle karşılaştırıldığında girdi işlemi, hesaplama ve çıktı alım işlemleri oldukça basit olan CP modelinin heyelan duyarlılık haritaları hazırlanmasında ve değerlendirilmesinde basit bir araç olarak kullanılabileceğinin altını çizmiştir.

Kawabata ve Bandibas [29] Japonya'nın Honshu Adasında, ANN yöntemiyle heyelan duyarlılık haritalaması yapmışlardır. ASTER uydu görüntüsünden elde ettikleri piksel boyutu 15 m olan ve GSI'dan (Geological Survey Institute of Japan) aldıkları piksel boyutu 55 m olan iki farklı SAM (Sayısal Arazi Modeli) kullanarak CBS ortamında yapılan analizlerle heyelana ilişkin jeomorfolojik parametreleri üretmişlerdir. Jeoloji, eğim, bakı, yükseklik, jeolojik sınırlara uzaklık ve jeolojik sınırların yoğunluğu olmak üzere heyelan oluşumuna etkin altı farklı parametre kullanmışlar ve Niigata 2004 depreminden sonra bölge de meydana gelen heyelan lokasyonlarını kullanarak duyarlılık haritalaması için gerekli veri tabanını oluşturmuşlardır. ANN modelini eğitmek için ve modelin doğruluğunu belirlemek için heyelanlı ve heyelansız alanları içeren piksellerden oluşan iki ayrı veri seti hazırlamışlardır. Araştırmacılar, 15 m ve 55 m SAM'den üretilen verilerin kullanıldığı farklı ANN modellerinin heyelanlı olan alanlar için sırasıyla % 93.68 ve % 94.39 oranlarında ve heyelanlı olmayan alanlar için % 58.27 ve % 67.71 oranlarında doğruluk gösterdiği sonucuna ulaşmışlardır. Parametrelerin ANN modeli üzerindeki etkisini de kıyaslayan araştırmacılar, eğitim aşamasında tüm faktörlerin kullanılmasının daha doğru sonuçlar verdiğini gözlemlemiş ve modelin % 93.68 olan doğruluk oranının jeoloji parametresi kullanılmadan % 45.83 değerine düşmesi sebebiyle yaptıkları bu çalışmada heyelan duyarlılık haritalamasında en önemli faktörün jeoloji olduğunu sonucuna ulaşmışlardır. Buna karşın, heyelan duyarlılık haritalamaların en etkili faktörlerden biri olan eğim

parametresinin çıkarılması durumunda ise doğruluk oranının % 92.71'e düşmesi bu çalışmada eğimin diğer parametreler kadar önemli olmadığını göstermiştir. Ayrıca, 55 m SAM ile üretilen verilerin kullanıldığı ANN modelinin daha yüksek doğruluk oranı göstermesinin piksel boyutunun ANN modeli üzerindeki etkisi olduğuna dikkat çeken araştırmacılar bunun sebebinin daha büyük bir alanın tek piksel tarafından temsil ediliyor olması nedeniyle, bu verilerin daha basit ve lokal değişim değerlerinden etkilenmeyen, homojen veriler olarak ANN modeli için de daha etkin olduğuna değinmişlerdir. Kawabata ve Bandibas [29] çalışmalarının en önemli sonucu olarak; heyelanlı olmayan alanlar için tahmin doğruluğunun düşük olmasını heyelansız piksellerin gerçekte heyelan potansiyeli içerebiliyor olmasından kaynaklandığını belirtmişler ve bu sorunun oldukça ilgi çekici olduğunu, çözümü için gelecekteki heyelanlara ilişkin daha fazla veri gerektiğini vurgulamıştır.

Yılmaz [35] çalışma alanı Şebinkarahisar (Giresun–Türkiye) bölgesi olan çalışmada CP ve ANN modelleriyle oluşturulan heyelan duyarlılık haritalamalarında örnekleme stratejilerinin etkisini araştırmıştır. Girdi parametreleri olarak; jeoloji, faylar, drenaj sistemi, topoğrafik yükseklik, eğim açısı, eğim yönü, topoğrafik nemlilik indeksi, akış gücü indeksi, normalize edilmiş bitki örtüsü indeksi analiz edilmiştir. Heyelan duyarlılık haritaları, farklı örnekleme stratejileri uygulanarak CP ve ANN modelleriyle üretilmiştir. Araştırmacı, bilenen heyelan konumları ile karşılaştırdığı heyelan duyarlılık haritalarına göre en yüksek doğruluğun, ANN modeli ile üretilen haritalarda olduğu sonucuna varmıştır. Örnekleme stratejisiyle üretilen haritalarda kopma zonu (scarp) modeli (CP, 0.908; ANN, 0.921) en iyi doğruluk sonucunu, kök hücre (seed cell) modeli nispeten tatmin edici (CP, 0.886; ANN, 0.902) ve nokta (point) modeli (CP, 0.827; ANN, 0.848) en kötü sonucu vermiştir. Yılmaz [35] ANN modelinin CP modeline göre daha gerçekçi sonuçlar verdiğini, fakat CP modelinin uygulaması kolay ve daha anlaşılabilir olduğunun altını çizmiştir.

Pradhan vd. [36] Malezya'nın çevresel, jeolojik ve jeomorfolojik anlamda benzerlik gösteren üç farklı bölgesinde (Penang Island, Cameron Highland, Selangor) yaptıkları çalışmada, jeolojik ve çevresel koşullar, eğim, bakı, eğrisellik, yükseklik, drenajdan uzaklık, akarsu gücü indeksi, yoldan uzaklık, faydan uzaklık, jeoloji,

arazi kullanımı, normalleştirilmiş bitki örtüsü indeksi, topoğrafya, topografik nemlilik indeksi, toprak yapısı ve toprak malzemesinin dahil olduğu 15 farklı faktörle heyelan analizi için geri yayılım algoritması kullanan bir ANN modeli kullanmışlardır. ANN modeli kullanılarak hesaplanan parametre ağırlıklarının çalışılan her üç bölge için benzer sonuçlar verdiği ve topoğrafik eğimin tüm alanlar için en yüksek ağırlık değerini gösterdiği belirlenmiştir. Araştırmacılar, elde ettikleri haritaların doğrulanması için AUC değerini hesaplamışlardır. Buna göre Cameron % 89.32, Selangor % 86.15 ve Penang % 78.32 doğruluk göstermiştir. Pradhan vd. [36] ANN modellerinin doğrusal ve parametrik olmayan veya hiyerarşik haritalama fonksiyonlarını karakterize edebilir özellikte olması sayesinde, 15 farklı heyelan oluşturu parametre ile çalışılmasının mümkün olduğuna dikkat çekmişlerdir.

Choi vd. [37] test alanı olarak seçtikleri Kore'nin üç farklı bölgesinde (Youngin, Janghung ve Boeun) ANN modelinin doğrulanması ve çapraz doğrulanmasını amaçlayan bir çalışma gerçekleştirmişlerdir. Araştırmacılar, bu amaç doğrultusunda, heyelan oluşumuna ilişkin faktörleri; eğim, bakı, eğrisellik, jeomorfoloji, drenaj, etkin toprak kalınlığı, toprak türü, orman yoğunluğu, çizgiselliğe uzaklık ve arazi örtüsü olarak seçmişlerdir. Heyelan duyarlılığını, geri yayılım öğrenme algoritması kullanan bir MLP (Multi Layer Perceptron) modelinde seçilen faktörleri kullanılarak analiz etmişlerdir. Araştırmacılar, her üç bölge içinde, topoğrafik eğim faktörünün en yüksek ağırlık değerini, arazi örtüsü ve çizgiselliğe uzaklık faktörlerinin yüksek değerler ve orman yoğunluğu ve toprak türü parametrelerinin ise en düşük ağırlık değerleri gösterdiği sonucuna ulaşmışlardır. Her veri setinden hesaplanan ağırlıklar, tüm veri setlerine uygulanarak dokuz farklı durumu yansıtan dokuz farklı heyelan duyarlılık haritası oluşturmuşlardır (örneğin; Youngin bölgesi verileri hem aynı alanın haritası için, hem de Janghung bölgesi hem de Boeun bölgesi haritaları için kullanılmıştır). Choi vd. [37] elde ettikleri 9 heyelan duyarlılık haritasını heyelan lokasyonlarıyla çaprazlama doğrulamışlardır. En iyi doğruluğu % 81.36 oranıyla Janghung alanın ağırlıklarına göre Boeun haritasında ve en kötü doğruluğu % 71.72 oranıyla yine Janghung alanın ağırlıklarına göre Youngin haritasında elde edilmişlerdir. Buna karşın, çalışma alanları arasında Youngin bölgesinin en iyi (% 80.83) ve Janghung bölgesinin en düşük (% 77.96) doğruluğu gösterdiği sonucuna ulaşmışlardır.

Garcia-Rodriguez ve Malpica [38] Orta Amerika'nın en aktif deprem bölgelerinden biri olan El Salvador'da yaptıkları çalışmada, deprem etkisiyle tetiklenen heyelan duyarlılık değerlendirmesini ANN yöntemiyle araştırmışlardır. Bölgesel ölçekte heyelan duyarlılık analizi için geri yayılım öğrenme özelliğine sahip bir MLP modeli tasarlamışlardır. Araştırmacılar, heyelan değerlendirmelerine etkin faktörler olarak; yamaç eğimi, yükseklik, yamaç eğim yönü, yıllık yağış miktarı, litoloji, arazi kullanımı ve arazi pürüzlülüğünü analiz etmişlerdir. ANN modeliyle heyelan duyarlılık haritası oluşturmak için seçilen parametreleri CBS ortamında işlemişlerdir. Araştırmacılar, ANN modeli ile oluşturdukları heyelan duyarlılık haritasını bilinen heyelan lokasyonları ile kontrol etmişler ve ANN modelinden üretilen haritanın yüksek bir uyum gösterdiği sonucuna ulaşmışlardır. Araştırmacılar, aynı bölgeyi LR yöntemi ile değerlendirdikleri önceki çalışmalarını da ANN modeli ile kıyaslamışlar ve bu yaptıkları çalışmada ANN modelinin % 95.1 doğruluk oranıyla LR modelinden (% 89.4) daha doğru sonuç verdiğini belirtmişlerdir [38]. Garcia-Rodriguez ve Malpica [38] heyelan duyarlılık araştırmalarında iyi bir modelin tek başına yeterli olmadığını, heyelana ilişkin faktörlerin ve bağımsız değişkenleri de sonuç haritası üzerinde önemli etkileri olduğunu vurgulamışlardır.

Choi vd. [32] Kore'nin Boeun bölgesinde yaptıkları çalışmada FR, LR ve ANN modelleriyle elde edilen kombine heyelan duyarlılık haritalarının doğruluk oranları karşılaştırmışlardır. Araştırmacılar, SAM, NDVI, çizgisellik ve arazi örtüsü gibi heyelanlara ilişkin faktörleri ASTER uydu görüntüsü kullanarak elde etmişler ve bu faktörleri CBS ile işleyerek eğim, bakı ve eğrisellik haritaları oluşturmuşlardır. Araştırmacılar, ASTER ve CBS kullanarak oluşturdukları bu altı faktörün heyelanlı bölgelerle ilişkisini FR, LR ve ANN modelleriyle analiz ederek hesaplamış ve bu ilişkileri heyelan duyarlılık haritaları oluşturmak için faktör puanları olarak kullanmıştır. Elde ettikleri üç farklı heyelan duyarlılık haritasını, bu kez daha hassas ve gelişmiş duyarlılık haritaları oluşturmak için FR, LR ve ANN modelleri için yeni veri faktörleri olarak kullanmışlar ve oluşturdukları tüm duyarlılık haritalarını, eğitim aşamasından kullanılmamış, bilinen heyelan lokasyonlarıyla karşılaştırarak doğrulamışlardır. Buna göre; FR, LR ve ANN modelleriyle elde edilen ilk haritaların (FR % 84.34, LR % 85.40 ve ANN % 74.29) birleştirilmesiyle


oluşturulan kombine duyarlılık haritalarında (FR % 87.00, LR % 88.21 ve ANN % 86.21) doğruluk oranının arttığını gözlemlemişlerdir. Araştırmacılar, farklı modellerle oluşturulan haritaların bir araya getirilmesiyle elde edilen kombine haritaların daha doğru sonuçlar verdiğine dikkat çekmiş ve özellikle ANN modelinde doğruluk oranının % 12.22 artmış olmasının kombine modellerin tahmin doğruluğunu arttırmak için etkin bir yöntem olduğunu vurgulamışlardır.

Heyelan duyarlılık değerlendirmesini Çin' nin Qingchuan County bölgesinde seçtikleri bir alanda, literatürde sıkça tercih edilen geri yayımlı bir ANN modeli kullanarak gerçekleştiren Li vd. [39] bu çalışmada yağış ve deprem faktörlerinin heyelan duyarlılığındaki farklı etkilerini ortaya koymayı amaçlamışlardır. Araştırmacılar, Wenchuan depremi öncesi meydana gelmiş 473 adet yağış kaynaklı heyelanları (RIL) ve 885 adet deprem kaynaklı heyelanları (EIL) 2 farklı heyelan envanter haritası olarak belirlemişlerdir. Yağış ve depremin farklı etkilerini anlayabilmek için ilk olarak heyelana ilişkin konumsal ve topoğrafik faktörler arasındaki farklılıkları karşılaştırmışlardır. Bu amaç doğrultusunda ilk olarak istatistiksel analizlere göre her bir faktör için heyelan dağılım frekansı uygulanmış daha sonra bu faktörlerin önemi ve etkisini belirlemek için ANN modelini uygulamışlardır. ANN modelinde farklı faktörlerin kombinasyonları denenerek elde edilen ağırlıkları karşılaştıran ve sonunda en iyi tahmin modelinden türetilmiş her bir faktörün ağırlıkları, çalışma alanına uygulayan araştırmacılar, yamaç eğiminin hem RIL hem de EIL haritaları için en yüksek ağırlık değerine sahip olduğu sonucuna varmıştır. Dört farklı faktörle kurulan (yamaç eğimi, yükseklik, yamaç yüksekliği, drenaja uzaklık) RIL modeli % 93 ve beş farklı faktörle oluşturulan (yamaç eğimi, yükseklik, yamaç yüksekliği, akarsuya uzaklık, faylara uzaklık) EIL modeli % 98 oranıyla en yüksek başarıyı göstermiş. Araştırmacılar ayrıca, RIL modelini doğrulamada EIL verilerini kullanarak % 92 başarı ve EIL modelini doğrulamada RIL modeli kullanarak % 53 başarı elde etmişlerdir. Litoloji parametresinin elde edilen haritalar için belirgin bir etkisi olmadığına değinen araştırmacılar, drenaja uzaklık parametresinin RIL modelinde ve faylara uzaklık parametresinin EIL modelinde büyük bir etkisi olduğunu vurgulamışlardır. Heyelanların dünya genelinde en ciddi doğal afetlerden biri olduğuna değinen araştırmacılar, elde edilen heyelan duyarlılık haritalarının arazi kullanım planlaması için önemli olduğunu vurgulamışlardır.

Bui vd. [31] Vietnam'ın Hoa Binh bölgesinde yaptıkları çalışmada ANN ile heyelan duyarlılık haritalamasında potansiyel uygulamaları araştırmışlardır. Çok tabakalı, ileri beslemeli yapay sinir ağı analizi için eğitim, bakı, rölyef, litoloji, arazi kullanımı, toprak türü, yağış miktarı, yollara uzaklık, nehirlerle uzaklık ve faylara uzaklık faktörlerini kullanmışlardır. İki farklı geri yayılım eğitim algoritması; Levenberg-Marquard ve Bayesian algoritmalarını, bir eğitim seti kullanılarak sinoptik ağırlıkların belirlenmesinde uygulamışlardır. Araştırmacılar, elde ettikleri iki heyelan duyarlılık haritasını, tahmin oranı metoduna göre doğrulamışlar ve tahmin doğruluğu eğri altında kalan alanları (AUC) değerlendirmişlerdir. Levenberg-Marquard ve Bayesian algoritmalarına göre üretilen haritaların tahmin doğruluğu % 86.1 ve % 90.3 olarak belirlenmiş ve araştırmacılar her iki yöntemin de iyi tahmin kapasitesi olduğunu, buna rağmen heyelan duyarlılık haritalaması için Bayesian sinir ağı modelinin Levenberg-Marquard modelinden çok daha güçlü ve etkili bir model olduğunun altını çizmişlerdir.


Heyelan riski haritalamalarında, heyelan duyarlılık ve tehlike değerlendirmelerinin en önemli adım olduğuna dikkat çeken Zare vd. [40] İran'ın Vaz bölgesinde yaptıkları çalışmada MLP (Multi Layer Perceptron) ve RBF (Radial Basis Function) olmak üzere iki farklı ANN modeli kullanmışlardır. Yamaç eğimi, yamaç eğim yönü, yükseklik, arazi kullanımı, litoloji, akarsuya uzaklık, yollara uzaklık, faylara uzaklık ve yağış verilerinden oluşan 9 farklı heyelan oluşumuna etkin parametre değerlendirilmiştir. Araştırmacılar, farklı ağ topolojisine sahip ve BFGS (Broyden-Fletcher-Goldfarb-Shanno) eğitim algoritmasıyla eğitilen dört farklı MLP modeli ve bir adet RBF modeli olmak üzere toplam 5 farklı ANN modelini kıyaslamışlardır. Ayrıca, bir MLP modelinde farklı öğrenme katsayılarıyla (0.1'den 0.9'a kadar) "gradient descent" eğitim algoritmasının performansını değerlendirmişlerdir. Araştırmacılar, 0.9 öğrenme katsayısıyla gradient descent algoritmasının heyelan duyarlılık değerlendirmesinde daha iyi bir yaklaşım olduğuna dikkat çekmişlerdir. Heyelan envanter haritasının % 70'i (95 heyelan lokasyonu) eğitim veri seti ve kalan % 30'u (40 heyelan lokasyonu) doğrulama veri seti olarak belirlenmiş. Sonuç olarak; BFGS eğitim algoritmasıyla eğitilen 9 girdi katmanı, 14 gizli katman ve 1 çıktı katmanına sahip MLP modelinin RBF modelinden (% 88.10 - % 87.24) daha iyi bir performans verdiği sonucuna varmışlardır.

Yukarıda değerdendirilen alıřmalar kapsamında, ANN kullanılarak heyelan duyarlılık değerdendirmelerinde kullanılan parametrelerin kullanım oranına ilişkin dağılım histogramı, řekil 2.1’de yer almaktadır. Sözü geen alıřmalarda kullanılan ve heyelan oluşumuna ilişkin faktörler, 27 farklı parametre grubu altında derlenmiştir. řekil 2.1’den de görülebileceğı gibi; yama eğimi parametresi, söz konusu tüm alıřmalarda analiz edilmiştir. Pradhan ve Lee [26] yama eğiminin diğerd faktörlere oranla 2 kat fazla önemi olduğunu belirtmişlerdir. Yama eğimi parametresinin yanı sıra, hemen her alıřmada kullanılan diğerd önemli parametrelerin; bakı, bitki örtüsü ve litoloji olduğu görülmektedir. Söz konusu parametrelerin kullanım oranı % 71’ dir. Yapısal unsurlara uzaklık; % 62 ve topoğrafik yükseklik; % 57 kullanım oranıyla analizlerde en ok kullanılan parametreler olarak görülmektedir. Bu anlamda, sözü geen parametrelerin heyelan duyarlılığında kullanımı açısından arařtırmacılar arasında bir fikir birliğı olduğunu söylemek mümkündür. Genel olarak, heyelan duyarlılığı değerdendirmesinde kullanılan tüm parametreler, alıřma alanının özelliklerine ve amaca yönelik parametreler olarak büyük önem taşıyabilmekte veya bazı durumlarda gerekli görülmemektedir. Örneğın, hemen hemen tüm alıřmalarda dikkate alınan litoloji parametresini, Ercanoğlu [22] alıřma alanında heyelanların sadece tek bir litolojik birim içinde geliştiğini belirterek, analizlerde girdi parametresi olarak dikkate almamıştır. Li vd. [39] ise yaptığı alıřmada litoloji parametresinin sonuçlar üzerinde belirgin bir etkisi olmadığı sonucuna, buna karşın Kawabata ve Bandibas [29] ise parametre etkilerini kıyasladıkları alıřmalarında heyelan duyarlılığına en etkin parametrenin litoloji olduğu sonucuna ulaşmışlardır.



Şekil 2.1. Çalışmalarda dikkate alınan parametreler ve kullanım oranları.

Yapılan çalışmaya göre araştırmacıların kullandığı parametre sayısına ilişkin histogram ise Şekil 2.2’de yer almaktadır. Araştırmacıların heyelan duyarlılık değerlendirmelerinde ortalama 8 farklı parametre kullanarak analizleri gerçekleştirdikleri ortaya çıkmaktadır. En yüksek parametre sayısı 19 farklı parametre ile Yeşilnacar ve Topal [24] ’e aitken, en az parametre sayısı 5 farklı parametre Lee vd. [20] ’e aittir.



Şekil 2.2. Çalışmalarda kullanılan parametreler ve sayıları.

Çizelge 2.1’de değerlendirilen 21 adet çalışma için, uygulanan yöntem, çalışılan bölge, kullanılan parametreler ve bu parametrelerin kullanım yüzdeleri özetlenmiştir. Sözü edilen çalışmalarda heyelan oluşumuna ilişkin 27 farklı parametre; jeolojik, topoğrafik ve çevresel parametreler olmak üzere, 3 ana grupta toplanmıştır. Bu tez çalışmasında, jeolojik, topoğrafik ve çevresel faktörler gruplarında yer alan, tüm çalışmalar içinde kullanımı öne çıkan ve eldeki mevcut veriler dikkate alınarak bir parametre seçimine gidilmiştir.

Tez çalışmasının temel amacı, ANN’de farklı eğitim algoritmalarının araştırılmasına yönelik olduğundan çalışmalarda yer alan tüm parametrelere ilişkin bir değerlendirilmeye gerek duyulmamış, bu çalışmada kullanılan parametrelere ilişkin değerlendirilmelere ise, 5. Bölüm’de yer verilmiştir.

Çizelge 2.1. Farklı araştırmacılar tarafından ANN ile heyelan duyarlılık değerlendirmelerinde kullanılan parametreler.

| NO | ARAŞTIRMACI               | YÖNTEM           | BÖLGE                               | HAZIRLAYICI PARAMETRELER |    |    |    |    |    |    |            |    |    |    |    |    |    |    |    |     |     |     |     |     |     |          |    |    |    |    |   |
|----|---------------------------|------------------|-------------------------------------|--------------------------|----|----|----|----|----|----|------------|----|----|----|----|----|----|----|----|-----|-----|-----|-----|-----|-----|----------|----|----|----|----|---|
|    |                           |                  |                                     | JEOLÖJİK                 |    |    |    |    |    |    | TOPOĞRAFİK |    |    |    |    |    |    |    |    |     |     |     |     |     |     | ÇEVRESEL |    |    |    |    |   |
|    |                           |                  |                                     | J1                       | J2 | J3 | J4 | J5 | J6 | J7 | T1         | T2 | T3 | T4 | T5 | T6 | T7 | T8 | T9 | T10 | T11 | T12 | T13 | T14 | T15 | Ç1       | Ç2 | Ç3 | Ç4 | Ç5 |   |
| 1  | Lee vd. [18]              | ANN              | Hong Kong - Lantau                  | ✓                        | ✓  |    |    |    | ✓  | ✓  | ✓          |    |    |    |    |    |    |    | ✓  |     | ✓   |     |     |     |     |          | ✓  |    |    |    |   |
| 2  | Lee vd.[19]               | ANN              | Kore - Yongin                       |                          |    |    | ✓  | ✓  |    |    | ✓          |    |    |    | ✓  |    |    |    |    | ✓   |     |     |     |     |     |          | ✓  |    |    |    |   |
| 3  | Lee vd. [20]              | ANN              | Kore - Yongin                       |                          |    |    | ✓  | ✓  |    |    | ✓          |    |    |    | ✓  |    |    |    |    |     |     |     |     |     |     |          | ✓  |    |    |    |   |
| 4  | Ermini vd. [21]           | ANN              | İtalya - Kuzey Appennies            | ✓                        |    |    |    |    |    |    | ✓          |    | ✓  | ✓  |    |    |    |    |    |     |     |     |     |     | ✓   | ✓        |    |    |    |    |   |
| 5  | Ercanoğlu [22]            | ANN, NF          | Bartın (Kumluca-Ulus )              |                          |    |    |    |    |    |    | ✓          |    |    |    | ✓  | ✓  |    |    | ✓  | ✓   |     |     |     |     |     | ✓        |    |    |    |    |   |
| 6  | Goméz ve Kavzoğlu [23]    | ANN              | Venezüella - Jabonosa               | ✓                        |    | ✓  |    | ✓  |    |    | ✓          |    |    |    | ✓  |    |    |    | ✓  | ✓   |     |     |     |     |     | ✓        |    |    |    |    |   |
| 7  | Yeşilnacar ve Topal [24]  | LR, ANN          | Karadeniz - Hendek B.               | ✓                        | ✓  | ✓  |    |    |    |    | ✓          | ✓  |    | ✓  |    | ✓  | ✓  | ✓  | ✓  | ✓   | ✓   | ✓   | ✓   | ✓   | ✓   | ✓        |    |    | ✓  | ✓  |   |
| 8  | Kanungo vd. [25]          | ANN, FL          | Darjeeling - Himalayalar            | ✓                        | ✓  |    |    |    |    |    | ✓          |    |    |    |    | ✓  |    |    |    | ✓   |     |     |     |     |     | ✓        | ✓  |    |    |    |   |
| 9  | Yüksel [34]               | IA, FA, LR, ANN  | Bartın (Kumluca-Ulus )              |                          |    |    |    | ✓  |    |    | ✓          |    |    |    |    |    |    |    | ✓  | ✓   |     |     |     |     |     | ✓        |    |    | ✓  |    |   |
| 10 | Pradhan ve Lee [26]       | ANN              | Malezya - Selangor                  | ✓                        | ✓  |    |    |    | ✓  |    | ✓          |    |    | ✓  |    | ✓  |    |    |    |     | ✓   |     |     |     |     | ✓        | ✓  |    |    |    |   |
| 11 | Yılmaz [27]               | FR, LR, ANN      | Tokat - Kat                         | ✓                        | ✓  |    |    |    |    |    | ✓          |    |    |    |    | ✓  |    |    | ✓  | ✓   |     | ✓   |     | ✓   |     |          |    |    |    |    |   |
| 12 | Yılmaz [28]               | ANN, CP, LR, SVM | Sivas - Koyulhisar                  | ✓                        | ✓  |    |    |    |    |    | ✓          |    |    |    |    | ✓  |    |    | ✓  | ✓   |     | ✓   |     | ✓   |     | ✓        |    | ✓  |    | ✓  | ✓ |
| 13 | Kawabata ve Bandibas [29] | ANN              | Japonya - Honshu Island             | ✓                        | ✓  | ✓  |    |    |    |    | ✓          |    |    |    |    | ✓  |    |    | ✓  |     |     |     |     |     |     |          |    |    |    |    |   |
| 14 | Yılmaz [35]               | ANN, CP          | Giresun - Sebinkarahisar            | ✓                        | ✓  |    |    |    |    |    | ✓          |    |    |    | ✓  |    |    |    | ✓  | ✓   |     | ✓   |     | ✓   |     | ✓        |    |    |    |    |   |
| 15 | Pradhan vd. [36]          | ANN              | Malezya - Penang, Cameron, Selangor | ✓                        | ✓  |    |    | ✓  |    |    | ✓          |    |    | ✓  |    | ✓  |    |    | ✓  | ✓   |     | ✓   |     | ✓   | ✓   | ✓        | ✓  |    | ✓  |    |   |
| 16 | Choi et al. [37]          | ANN              | Kore - Youngin, Janghung, Boeun     |                          | ✓  |    | ✓  | ✓  |    |    | ✓          |    |    | ✓  |    | ✓  |    |    |    | ✓   |     |     |     | ✓   | ✓   | ✓        |    |    |    |    |   |

Çizelge 2.1. Devam ediyor.


| NO                             | ARAŞTIRMACI                      | YÖNTEM      | BÖLGE                  | HAZIRLAYICI PARAMETRELER |    |    |    |    |    |    |            |    |    |    |    |    |    |    |    |     |     |     |     |     |     |          |    |    |    |    |
|--------------------------------|----------------------------------|-------------|------------------------|--------------------------|----|----|----|----|----|----|------------|----|----|----|----|----|----|----|----|-----|-----|-----|-----|-----|-----|----------|----|----|----|----|
|                                |                                  |             |                        | JEOLJİK                  |    |    |    |    |    |    | TOPOĞRAFİK |    |    |    |    |    |    |    |    |     |     |     |     |     |     | ÇEVRESEL |    |    |    |    |
|                                |                                  |             |                        | J1                       | J2 | J3 | J4 | J5 | J6 | J7 | T1         | T2 | T3 | T4 | T5 | T6 | T7 | T8 | T9 | T10 | T11 | T12 | T13 | T14 | T15 | Ç1       | Ç2 | Ç3 | Ç4 | Ç5 |
| 17                             | Garcia-Rodriguez ve Malpica [38] | ANN         | El Salvador            | ✓                        |    |    |    |    | ✓  |    | ✓          |    |    |    |    | ✓  |    |    | ✓  |     |     |     |     | ✓   |     | ✓        |    |    |    |    |
| 18                             | Choi vd. [32]                    | FR, LR, ANN | Kore - Boeun           |                          |    | ✓  |    |    |    |    | ✓          |    |    | ✓  |    | ✓  |    |    |    |     |     |     |     |     | ✓   | ✓        |    |    |    |    |
| 19                             | Li vd. [39]                      | ANN         | Çin - Qingchuan County | ✓                        | ✓  |    |    |    |    |    | ✓          | ✓  |    |    |    | ✓  |    |    |    |     | ✓   | ✓   |     |     |     |          |    |    |    |    |
| 20                             | Bui vd. [31]                     | ANN         | Vietnam - Hoa Binh     | ✓                        | ✓  |    |    | ✓  | ✓  |    | ✓          |    |    |    |    |    |    |    |    |     | ✓   |     |     | ✓   |     | ✓        |    | ✓  |    |    |
| 21                             | Zare vd. [40]                    | ANN         | İran - Vaz Watershed   | ✓                        | ✓  |    |    |    | ✓  |    | ✓          |    |    |    |    | ✓  |    |    | ✓  |     |     | ✓   |     |     |     | ✓        |    | ✓  |    |    |
| PARAMETRE KULLANIM YÜZDESİ (%) |                                  |             |                        | 71                       | 62 | 24 | 14 | 33 | 24 | 5  | 100        | 10 | 5  | 29 | 14 | 71 | 5  | 5  | 57 | 38  | 24  | 43  | 10  | 24  | 29  | 71       | 38 | 5  | 33 | 5  |

J1:Litoloji, J2:Yapısal Unsurlara Uzaklık, J3:Yapısal Unsurların Yoğunluğu, J4: Toprak Kalınlığı, J5:Malzeme Özellikleri, J6:Yağış, J7: Erozyon Durumu; T1:Yamaç Eğimi, T2:Yamaç Uzunluğu, T3: Eğim Yukarı Katkı Alanı, T4:Yamaç Eğriselliği, T5:Yamaç Şekli, T6: Bakı, T7:Yüzey Alan Oranı, T8:Sırtlara Uzaklık, T9:Topoğrafik Yükseklik, T10:Topoğrafik Nemlilik İndeksi, T11: Drenaj Yoğunluğu, T12:Drenaja Uzaklık, T13:Su Havzası, T14:Akış Gücü İndeksi, T15:Jeomorfolojik Özellikler; Ç1:Bitki Örtüsü, Ç2:Arazi Kullanımı, Ç3: Yerleşime Uzaklık, Ç4:Yola Uzaklık, Ç5:Yol Yoğunluğu; ANN: Yapay Sinir Ağları, NF: Neuro Fuzzy, FL: Bulanık Mantık, LR: Lojistik Regresyon, İA: İstatistiksel Analiz, FR: Frekans Oranı, CP: Koşullu Olasılık, SVM: Destek Vektör Makinesi.

### 3. HEYELAN KAVRAMI VE HEYELAN DUYARLILIK HARİTALAMALARI

#### 3.1. Heyelan Kavramı ve Heyelan Sınıflaması

Basit şekliyle heyelan, bir yamaçtaki kaya, toprak zemin veya molozların yamaç dışına ve aşağı doğru hareketi olarak tanımlanmaktadır [41]. Şekil 3.1’de tipik bir heyelanın özelliklerini tanımlayan terminoloji yer almaktadır.



Şekil 3.1. Heyelan özelliklerini tanımlayan terminoloji [42].

Heyelanları tanımlamak ve heyelanların haritalanması için tüm heyelan sürecine basit isimler vermek ve bu isimlerin kurulan terminoloji ile uyumlu olmalarına dikkat etmek gereklidir. Heyelan tanımı yapılırken, heyelanı meydana getiren her bir hareketi açıklayan bir terim tanımlamak ya da tüm aşamaları kapsayan tek bir isim vermek amaçlanır. Günümüzde hala uluslararası jeoteknik kuruluşlarının fikir birliği sağladığı mevcut bir heyelan sınıflandırma yöntemi bulunmamaktadır. Literatürde, hareket türü, hareket hızı ve malzeme boyutu gibi farklı faktörler kullanılarak geliştirilmiş birçok heyelan sınıflandırma sistemi mevcuttur. Fell [8] yaptıkları çalışmada tüm mevcut heyelan sınıflandırma sistemlerin bazı eksikler içerdiklerine değinmişlerdir. Tüm bu sistemler içinde dünya genelinde en çok kullanılan sistem Varnes [42] tarafından hareket ve malzeme türüne geliştirilen heyelan sınıflama sistemidir.

Varnes [42] tarafından önerilen sınıflama sistemi, başlıca 6 hareket türünü içerir. Her hareket türü ayrıca heyelanı oluşturan birimlerin toprak ve kaya zemin olmasına göre, toprak zeminlerde tane boyu kavramı da gözetilerek alt bölümlere ayrılmıştır (Çizelge 3.1).

Çizelge 3.1.Varnes [42] tarafından önerilen heyelan sınıflama sistemi.

| Hareketin Türü |            | Malzemenin Türü                                          |                                 |                   |
|----------------|------------|----------------------------------------------------------|---------------------------------|-------------------|
|                |            | Ana Kaya                                                 | Toprak Zeminler                 |                   |
|                |            |                                                          | İri Taneli                      | İnce Taneli       |
| Düşme          |            | Kaya Düşmesi                                             | Moloz Düşmesi                   | Toprak Düşmesi    |
| Devrilme       |            | Kaya Devrilmesi                                          | Moloz Devrilmesi                | Toprak Devrilmesi |
| Kayma          | Dairesel   | Kayada Kayma                                             | Moloz Kayması                   | Toprak Kayması    |
|                | Ötelenmeli |                                                          |                                 |                   |
| Yanal Yayılma  |            | Kaya Yayılması                                           | Moloz Yayılması                 | Toprak Yayılması  |
| Akma           |            | Kaya Akması                                              | Moloz Akması<br>(Toprakta Krip) | Toprak Akması     |
|                |            | (derin krip)                                             |                                 |                   |
| Karmaşık       |            | İki ya da daha fazla hareket türünün bir arada gelişmesi |                                 |                   |

Malzemenin türü heyelan davranışını etkileyen en önemli faktörlerden biridir. Hungr vd. [43] yaptıkları çalışmada, Varnes [42] sınıflamasında malzemelerin kaya, moloz ve toprak olarak üçe ayrılmasının, ne jeolojik terminolojiye, ne de mekanik özelliklere dayalı jeoteknik sınıflandırmalara uygun olmadığını vurgulamışlar ve mevcut toprak ve kaya sistemlerini basitleştirilerek açıklamak amacıyla Varnes [42] sınıflaması için bir güncelleme yapmışlardır (Çizelge 3.2).

Bununla birlikte, uygulamalarda yaygın olarak kullanılması ve karmaşık bir terminoloji içermemesi sebebiyle, bu tez çalışmasında da Varnes [42] sınıflaması temel alınmıştır.

Çizelge 3.2. Hungr vd. [43] tarafından güncellenen Varnes [42] sınıflama sistemi.

| Hareketin Türü          | Kaya                                                                                                                                   | Toprak                                                                                                                                                                               |
|-------------------------|----------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Düşme</b>            | (1) Kaya Düşmesi                                                                                                                       | (2) Kaya Bloğu, Moloz, Silt Düşmesi                                                                                                                                                  |
| <b>Devrilme</b>         | (3) Kaya Bloğu Devrilmesi<br>(4) Kayada Bükülme Devrilmesi                                                                             | (5) Çakıl, kum, silt devrilmesi                                                                                                                                                      |
| <b>Kayma</b>            | (6) Kayada Dairesel Kayma<br>(7) Kayada Düzlemsel Kayma<br>(8) Kama Kayması<br>(9) Kayada Birleşik Kayma<br>(10) Kayada Düzensiz Kayma | (11) Kil, Silt Dairesel Kayma<br>(12) Kil, Silt Düzlemsel Kayma<br>(13) Çakıl, Kum, Moloz Kayması<br>(14) Kil, Silt Birleşik Kayma                                                   |
| <b>Yayılma</b>          | (15) Kaya Yayılması                                                                                                                    | (16) Kum, Silt Sıvılaşma Yayılması<br>(17) Hassas Kil Yayılması                                                                                                                      |
| <b>Akma</b>             | (18) Kaya Akması                                                                                                                       | (19) Kum, Silt, Moloz Kuru Akması<br>(20) Kum, Silt, Moloz Akma Kayması<br>(21) Hassas Kil Akması<br>(22) Moloz Akması<br>(23) Moloz Çıığı<br>(24) Zemin Akması<br>(25) Turba Akması |
| <b>Şev Deformasyonu</b> | (28) Dağ Şevi Deformasyonu<br>(29) Kaya Şevi Deformasyonu                                                                              | (30) Zemin Şevi Deformasyonu<br>(31) Zeminde Krip<br>(33) Toprak Akması (Solifluction)                                                                                               |

### 3.2. Heyelan Duyarlılığına İlişkin Temel Kavramlar

Heyelan duyarlılık değerlendirme çalışmaları, genel anlamda belirli bir bölge içinde heyelana karşı duyarlılık açısından aynı özelliklere sahip alanların, göreceli sınıflandırılması (çok düşük, düşük, orta, yüksek, çok yüksek duyarlı vb.) olarak tanımlanabilir.

Heyelan duyarlılığı, bir bölgede heyelan oluşumunda etkin olabilecek girdi parametrelerinin dikkate alınmasıyla, heyelan gelişmesi olası alanların, göreceli sınıflandırılması şeklinde tanımlanmaktadır [44].

Heyelan tehlikesi, belirli bir alanda ve zaman diliminde potansiyel olarak hasar verici bir etkiye sahip bir heyelanın oluşabilme olasılığıdır. Heyelan tehlikesinin

belirlenmesinde, şiddetli yağış ve deprem gibi tetikleyici parametrelerin dikkate alınmasını gerektirmektedir [44].

Heyelan riski ise, belirli bir alanda heyelan tehlikesinin meydana gelmesi durumunda oluşabilecek kayıpların hesabına dayanır. Heyelan Riski değerlendirmelerinde, heyelan sonucunda meydana gelebilecek yaşam kayıplarının yanında ekonomik, sosyal ve çevresel kayıplar da dikkate alınmaktadır [44].

Heyelan duyarlılık değerlendirmesi heyelan tehlike ve risk değerlendirmesine yönelik ilk adım olarak kabul edilebilir.

### **3.3. Heyelan Duyarlılık Değerlendirmelerinde Kullanılan Yöntemler**

Heyelan duyarlılık değerlendirmeleri ile ilgili literatür incelendiğinde, duyarlılık değerlendirmelerinde birçok farklı yöntemin mevcut olduğu ve bu yöntemlerin temelde birbirinden önemli farklılıklara sahip olduğu görülmektedir [3], [7], [8], [17]. Literatürde yaygın olarak kullanılan yöntemler genel olarak nitel (bilgiye dayalı) ve nicel (veriye dayalı ve fiziksel temelli) yöntemler olarak iki başlık altında toplanmaktadır. Envantere dayalı yöntemler ise değerlendirme çalışmalarına önemli bir girdi oluşturduğu ve sonuçta elde edilen haritaları doğrulamak için kullanılması sebebiyle, diğer tüm yöntemler için bir ilk adım olarak gereklidir (Çizelge 3.3).

Bilgiye dayalı veya sezgisel yöntemlerde uzman görüşü önemli rol oynar. Heyelan duyarlılık haritalaması doğrudan arazi çalışmaları sırasında veya jeomorfoloji haritasının bir türevi olarak ofis ortamında oluşturulabilir. Bu yöntem öznel olup uzmanın deneyimine bağlıdır ve bazı durumlarda son derece hassas sonuçlar verir. Bilgiye dayalı dolaylı haritalama yöntemleri ise CBS ortamında heyelan oluşumunda etken haritaların dolaylı olarak birleştirilmesiyle oluşturulabilir. Yine uzmanlık bilgisi temelinde, geçmiş heyelanlar ve bu heyelanların nedenler faktörlerine özel ağırlıklar atanarak belirli kombinasyonlar oluşturulur.

Çizelge 3.3. Heyelan duyarlılık değerlendirmesinde kullanılan yöntemler [45].

| Envanter Tabanlı Yöntemler                                                                                                                                                                                  |                                                                                                                                                                                                                                                                                                 |                                                                                                                                                                          |
|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|--------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| ✓ Heyelan envanter haritaları<br>✓ Olaya yönelik heyelan envanter haritaları<br>✓ Heyelan yoğunluk haritaları<br>✓ Heyelan aktivite haritaları                                                              |                                                                                                                                                                                                                                                                                                 |                                                                                                                                                                          |
| (Doğrulama)                                                                                                                                                                                                 | (Veri Girişi & Doğrulama)                                                                                                                                                                                                                                                                       | (Doğrulama)                                                                                                                                                              |
| Bilgi Tabanlı Yöntemler                                                                                                                                                                                     | Veri Tabanlı Yöntemler                                                                                                                                                                                                                                                                          | Fiziksel Tabanlı Yöntemler                                                                                                                                               |
| <u><b>Doğrudan haritalama</b></u><br>✓ Jeomorfolojik tehlike haritaları<br><br><u><b>Dolaylı haritalama</b></u><br>✓ Boolean logic<br>✓ Bulanık mantık<br>✓ Çakıştırma<br>✓ Mekansal kriter değerlendirmesi | <u><b>İki değişkenli istatistiksel yöntemler</b></u><br>✓ Girdi ağırlıkları<br>✓ Bilgi değeri<br>✓ Frekans oranı<br><br><u><b>Çok değişkenli istatistiksel yöntemler</b></u><br>✓ Lojistik regresyon<br>✓ Diskriminat analizi<br>✓ Kümeleme analizi vb.<br><br><u><b>Yapay sinir ağları</b></u> | <u><b>Statik yöntemler</b></u><br>✓ Sonsuz eğim<br>✓ Profil<br>✓ 3-D modelleme<br><br><u><b>Dinamik yöntemler</b></u><br>✓ Yağış/eğim hidrolojisi<br>✓ Sismik akümülayon |
| Nitel Yöntemler                                                                                                                                                                                             | Nicel Yöntemler                                                                                                                                                                                                                                                                                 |                                                                                                                                                                          |

Veriye dayalı yöntemlerde geçmiş heyelan verileri tüm veri sınıflarının görelî önemi hakkında bilgi edinmek için kullanılır. Üç ana veri odaklı yaklaşım vardır; iki değişkenli veya çok değişkenli istatistiksel analizler ve ANN analizi. Fiziksel tabanlı yöntemlerde ise heyelan süreçlerinin fiziksel tabanlı şev duraylılığı modelleri oluşturularak modellenmesi şeklinde bir yol izlenmektedir [45].

Heyelan duyarlılık değerlendirilmelerinde kullanılan tüm yöntemler genellikle iki varsayıma dayanmaktadır:


- Geçmiş, gelecek için bir rehberdir ve geçmişte heyelan meydana gelmiş alanlarda, gelecekte de heyelan olması muhtemeldir. Bu nedenle ayrıntılı heyelan envanteri oluşturulması, heyelan duyarlılık değerlendirmesinde önem taşımaktadır.

- Gemiřte heyelan meydana gelmiř alanlara benzer evresel zellikleri (topoėrafya, jeoloji, zemin, jeomorfoloji ve arazi kullanımı gibi) olan alanlarda da gelecekte heyelan oluřması muhtemeldir [45].

Bu tez alıřmasında yntemler konusunda ayrıntılı bir deėerlendirme yapılmamıř, tez alıřmasının amacı doėrultusunda farklı ėrenme algoritmalarına sahip ANN modelleri kullanarak heyelan duyarlılık haritalarının oluřturulması ve elde edilen sonu haritaları ile mevcut heyelan envanter haritaları karřılařtırılarak, bu algoritmaların sonular zerindeki etkileri ve ANN ynteminin heyelan duyarlılık haritalarının retilmesindeki performansının deėerlendirilmesi yoluna gidilmiřtir.

## 4. YAPAY SİNİR AĞI SİSTEMLERİ

İnsan sinir sistemi, nöron adı verilen küçük tek hücreli yapılardan oluşur. Bir nöron 5 temel element içerir; dendrit, dendronitler, hücre gövdesi, sinaps ve akson (Şekil 4.1). Dendritler, diğer nöronlardan gelen sinyalleri alır, sinyal dendronlar tarafından hücre gövdesine taşınır ve burada gelen sinyalin gücüne göre kompozit sinyaller üretilir ve akson boyunca sinapslara iletilir. Yapay sinir ağı (ing. Artificial Neural Network (ANN)) da, bu biyolojik sinir sisteminin bilgisayar ortamındaki modeli olarak tanımlanabilir [46].



Şekil 4.1. İki nöron içeren bir biyolojik sinir ağı [46].

### 4.1. Yapay Sinir Ağlarının Tarihçesi

ANN, insan beyni üzerinden modellenmiş sistemler olup, ANN'nin kökeni 1940'lı yıllara dayanmaktadır. İlk kez McCulloch ve Pitts [47] biyolojik nöronların matematiksel bir modelini sunmuşlardır. McCulloch ve Pitts'e göre bir nöron aktif ve pasif olmak üzere olası iki durumu olan mantıksal bir kapıdır. Bu modelde, bir nöronun diğer nöronların çıktıları tarafından sağlanan birkaç girdisi vardır. Nöronların aktif ya da pasif olma durumu, çıkan sinyal değerine göre belirlenir. Sinyal değeri belirli bir eşik değerinden büyükse nöron aktif; aksi takdirde pasiftir. McCulloch ve Pitts'in bu çalışması yapay sinir hücreleriyle her türlü mantıksal ifadeyi tanımlayabilmenin mümkün olduğunu göstermiştir. Daha sonra Hebb [48] nöronlar arasındaki bağlantı ağırlıklarının ayarlanması amacıyla, yapay sinir ağının

değerlerini değiştiren bir öğrenme kuralı önermiştir. “Hebbian öğrenme” kuralı olarak bilinen bu kural, günümüzde kullanılan öğrenme kurallarının temelini oluşturmaktadır. İlk bağımsız öğrenme algoritması ise Rosenblatt [49] tarafından önerilmiştir. Bu algoritma, “ceza ve ödül paradigmasına” dayanan ve daha sonraları çok katmanlı algılayıcıların temelini oluşturacak algılayıcı (perceptron) algoritmasıdır. Widrow ve Hoff [50] tarafından yapılan çalışmalarda, Rosenblatt’ın algılayıcı modeli ile aynı özelliklere sahip, fakat öğrenme algoritması daha gelişmiş olan matematiksel modeller geliştirilmiştir. Kohonen [51] o dönemde problem çözme yeteneği olmadığı düşünülmeye başlayan ve ilgi kaybeden algılayıcı modeline karşı, “Hebbian öğrenme” kuralına geri dönerek iki katmanlı sinir sistemleri için öğrenme kuralı uygulayan bir model önermiştir. Daha sonra Hopfield [52] “Hebbian öğrenme” kuralını geliştirerek bütün nöronların birbirlerine bağlı olduğu, matematiksel olarak daha iyi tanımlanmış bir model geliştirmiş ve yapay sinir ağlarının çözülmesi zor olan problemlere çözüm üretebileceğini göstermiştir. Bununla birlikte, yapay sinir ağlarına olan ilgi gün geçtikçe artmış, Kohonen [53], Hopfield ve Tank [54], Rumelhart [55], Sejnowski ve Rosenberg [56], Grossberg [57], Carpenter ve Grossberg [58], ve daha birçok araştırmacı tarafından yapılan çalışmalarda, yapay sinir ağı modelleri ve öğrenme algoritmaları geliştirilmiştir [59].


#### 4.2. ANN Sistemlerinin Yapısı

Bir yapay nöron, matematiksel olarak iki modül ile temsil edilir; (i) lineer aktivasyon ve (ii) sonlu bir bant içinde sinyal seviyelerini sınırlayan bir doğrusalsızlık. Şekil 4.2’de yapay bir ağın tipik yapısı görülmektedir. Burada toplama fonksiyonu bir hücre gövdesi görevi görür ve girdiler dendritler gibi davranır. Sinapslar doğrusal olmayan bir fonksiyon (aktivasyon fonksiyonu) olarak modellenir ve ağdan doğrusal olmayan birime olan bağlantı akson gibi çalışır. Burada  $Net$   $x_1, x_2, \dots, x_n$  şeklinde temsil edilen girdilerin doğrusal bir toplamıdır. Matematiksel olarak Eş. 4.1’de olduğu gibi ifade edilmektedir.

$$Net = \sum_{i=1}^n w_i x_i \quad (4.1)$$

Ağırlıklar bir yapay sinir hücresine gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Girdilerin üretilecek çıktı üzerindeki etkisini ayarlayabilmek için


girdiler geldikleri bağlantıların  $w_1, w_2, \dots, w_n$  ile temsil edilen ağırlıkları ile çarpılır. Bu ağırlıkların değerleri pozitif, negatif veya sıfır olabilir. Artı ve eksi değerler bilginin pozitif veya negatif bir etkisi olduğunu gösterir. Ağırlığı sıfır olan girdilerin ise çıktı üzerinde herhangi bir etkisi olmamaktadır.



Şekil 4.2. Tipik bir yapay nöron [46].

Toplama fonksiyonundan çıkan toplam, seçilmiş bir aktivasyon fonksiyonuyla işlenerek bir çıktıya ( $y$ ) dönüştürülür. Burada toplam, bazı eşik değerleri ile karşılaştırılır ve istenilen değerler arasında sınırlanır. Eğer toplam eşik değerinden büyükse işlem elemanı bir sinyal üretir, aksi durumda işlem elemanı bir sinyal üretmez. Her iki tepki de, ağ için önemlidir. Aktivasyon fonksiyonu genellikle türevi kolay hesaplanabilir, doğrusal olmayan bir fonksiyon seçilir (Şekil 4.3). Minimum ve maksimum değerleri asimptotlarda birbirine yaklaştıran “S” eğrisi en çok tercih edilen fonksiyondur. Dikkate alınan aralıklar, 0 ve 1 arasında ise Sigmoid, -1 ile 1 arasında ise Hiperbolik Tanjant fonksiyonu olarak seçilmelidir. Her iki fonksiyonun türevleri ise süreklidir.

Aktivasyon fonksiyonundan sonra sonuç üzerinde ayarlama ve sınırlama gibi ek işlemler yapılabilir. Normalde çıktı direk olarak aktivasyon fonksiyonunun sonucu ile eş değerdir. Fakat bazı ağ topolojileri, transfer sonucunu komşu işleme elemanları arasındaki rekabet yüzünden değiştirebilir. Nöronlarda büyük bir güç olmadığı sürece, işlemci elemanların birbirini önleyici rekabetine izin verilir. Rekabet hangi yapay nöronun aktif olacağını ya da çıktı sağlayacağını belirler.



Şekil 4.3. Sigmoid fonksiyonu (Lippmann [60] 'dan değiştirilerek alınmıştır).

Aynı zamanda rekabetçi girdiler hangi işlemci elemanın öğrenme veya adaptasyon sürecine katılacağını belirlemede de yardımcı olur. Çoğu öğrenme algoritmalarında yapay nöron çıktısı ve istenen çıktı arasındaki fark hata olarak hesaplanır. Pek çok basit ağ mimarisi bu hatayı doğrudan kullanır fakat bazıları kendi amaçlarına uygun hata değişimi yapabilir. Hata bir önceki katmanlara doğru geri yayılır. Bu geri yayılım değeri öğrenme fonksiyonu tarafından ayarlandıktan sonra, her gelen bağlantı ağırlıklarıyla onları bir sonraki öğrenme döngüsünden önce değiştirmek için çarpılır. Öğrenme fonksiyonun amacı, her işlemci elemanın girdi ağırlıklarını değiştirmektir.


#### 4.3. Yapay Sinir Ağı Topolojisi

Bir ANN'nin tasarım sürecinde ilk adım olarak ağ mimarisine (topolojisine) karar verilmelidir. Araştırmacılar tarafından yaygın olarak uygulanan iki temel ANN mimarisi vardır, bunlar: ileri beslemeli (feedforward) ağlar ve geri dönüşümlü (recurrent) ağlardır [61]. İleri beslemeli ağ modeli, bağlantıların doğrudan ileri beslemeli olduğu ağları içerir. Bu ağ yapısı tek tabakalı veya çok tabakalı olarak kurulabilir. Bu tez çalışmasında çok tabakalı ileri beslemeli ağ ile çalışılmış ve kurulan ağın farklı eğitim algoritmalarına göre performansı değerlendirilmiştir.

##### 4.3.1. Çok Tabakalı İleri Beslemeli Ağ (Multilayer Feedforward Network)

Çok tabakalı ağlar, girdi ve çıktı tabakaları arasında bir veya birden fazla tabaka içeren ağlardır. Bu ilave katmanlar, girdi ve çıktı tabakalarıyla doğrudan bağlantısı olmayan gizli birimler veya nöronlar içerir. Rumelhart [55] tarafından doğrusal olmayan problemlerin çözümü için geliştirilen bu ağlar, genellikle geri yayılım (back

propagation) ve ileri besleme (feedforward) özelliğine sahip olup denetimli (supervised) olarak eğitilirler. Basit bir ileri beslemeli, geri yayımlı, çok tabakalı ağ genel olarak girdi tabakası, gizli tabaka ve çıktı tabakası olmak üzere üç tabakadan oluşur (Şekil 4.4).



Şekil 4.4. Çok tabakalı bir ANN modeli [61].

Tüm çok tabakalı ağlar için gizli tabaka sayısı ve her tabakaya düşen birimlerin sayısı belirlenmelidir. Bu işlemler yapıldıktan sonra son aşama, girdinin sunulmasının ardından istenilen çıktının elde edilebilmesi için ağın ağırlıklarının ayarlanmasıdır. Bu aşama ANN'nin eğitimi veya ağ ağırlıklarının öğrenmesi olarak bilinmektedir [61]. Ağdaki her bir tabaka yapılacak uygulamaya bağlı olarak yeterli sayıda nöron içerir. Katmanlardaki bu nöronlar ardışık halde bir sonraki nörona bağlıdır ve her bağlantı bir ağırlık değeri taşır. Girdi tabakası farklı kaynaklardan (örneğin kaynak katmanlar) gelen verileri alır. Bu nedenle, girdi tabakasındaki nöron sayısı, veri kaynaklarının sayısına da bağlıdır. Gizli tabaka ve çıktı tabakası aktif olarak gelen verileri işler. Gizli tabaka ve bu katmandaki nöron sayısı genellikle deneme yanılma ile belirlenir [25]. Çıktı tabakasındaki nöron sayısı ise uygulamayla sabitlenir. Her bir gizli nöron bağlı olduğu bir önceki katmanın nöronlarından aldığı ağırlıklı girdilere yanıt verir ve her bir gizli nöron üzerindeki kombine etki tespit edildikten sonra, bu nöronlardaki aktivasyon bir transfer fonksiyonu ile belirlenir [20]. Herhangi türevlenebilir ve doğrusal olmayan

fonksiyon bir aktivasyon fonksiyonu olarak kullanılabilir, ancak genellikle sigmoid fonksiyonu kullanılır. Sigmoid fonksiyonu ağdaki çıktıları 0 ile 1 arasında sınırlar. Elde edilen çıktı değeri istenilen çıktı değeri ile karşılaştırılır ve aradaki fark hata sinyali olarak gizli tabakadaki nöronlara aktarılır ve her bir nöron hesaplanan toplam hatanın sadece bir kısmını içerir. Bu süreç, girdi tabakasına kadar tekrarlanır ve hata sinyalleri temel alınarak bağlantı ağırlıkları yeniden düzenlenir. Hesaplanan hata değeri kabul edilebilir bir değere gelene kadar bağlantı ağırlıkları değiştirilerek tekrarlamaya devam edilir ve böylece ağın eğitim aşaması tamamlanır [60].

Denetimli eğitimde ağa hem girdiler, hem de çıktılar verilir. Sinir ağı girdileri işleyerek ürettiği çıktılarla istenilen çıktıları karşılaştırabilir. Ağın ürettiği çıktı ve istenilen çıktı arasındaki fark, hata olarak kabul edilir ve MSE (Mean Square Error) değeri ile hesaplanır. Bu değer, eğitim verileri için belirlenen MSE değerinin altına düştüğü zaman eğitimi durdurmak için kullanılır. MSE değerinin sıfıra olan yakınlığı, hedeflenen ve tahmin edilen değerler arasında iyi bir ilişki olduğunu gösterir. MSE değeri aşağıdaki formülle ifade edilir;

$$MSE = \left(\frac{1}{N}\right) * \sum_{i=1}^n (y - y')^2 \quad (4.2)$$

Bu formülde; y hedef çıktı, y' üretilen çıktı ve N veri sayısıdır.

Ağın eğitimini sağlayan veri seti, “eğitim seti” olarak adlandırılır. Ağın eğitimi sırasında, aynı veri seti, bağlantı ağırlıkları en uygun değerlere ulaşmaya kadar birçok kez işlenir. Bazen bir ağ öğrenme işlemini gerçekleştiremez. Bunun sebebi girdi verisinin, istenilen çıktıyı üretmek için gereken bilgileri tam olarak içermiyor olmasıdır. İdeal olarak eğitilmiş bir ağın test edilmesi için “test seti” olarak adlandırılan ayrı bir veri setinin olması gerekir. Bu sayede sistem doğruluğu kontrol edilir. Eğer ağ sorunu çözemiyorsa, ağın tasarımı için; girdi ve çıktılar, katman sayısı, her katmanın eleman sayısı, katmanlar arasındaki bağlantılar, toplama ve transfer fonksiyonları, eğitim algoritmaları ve başlangıç ağırlıkları gözden geçirilmelidir. Ağ tasarımının en önemli unsurlarından biri eğitim algoritmalarıdır. Eğitim sırasında ağırlıkları ayarlamak amacıyla gerekli

uyarlanabilir geribildirim uygulamak için kullanılan birçok algoritma vardır. Bu tez çalışmasında kullanılan ve literatürde yaygın olarak kullanılan eğitim algoritmaları aşağıdaki bölümlerde açıklanmıştır.

#### 4.4. Eğitim Algoritmaları (Training Algorithms)

ANN'lerin eğitimi için problemin türüne en uygun algoritmanın seçilmesi gerekmektedir. Rumelhard [55]'nin hata geri yayılım algoritmasının (error back propagation) sinir ağlarını etkili bir şekilde eğittiğini göstermesinden bu yana, birçok eğitim algoritması geliştirilmiş, fakat bunlardan sadece birkaçının verimli olarak bir sinir ağını eğittiği gözlenmiştir. Buna rağmen, en iyi eğitim algoritmasının bile nöron sayısı azaltılmış bir sinir ağının eğitiminde güçlük çektiği bilinmektedir [62]. Bu çalışmada, çok katmanlı ağların eğitim aşamasında kullanılan en yaygın yaklaşımlardan “Batch-Backpropagation”, “Quick Propagation”, “Conjugate Gradient Descent”, ve “Levenberg–Marquardt” eğitim algoritmaları kullanılmıştır.

##### 4.4.1. Geri Yayılım (Batch-Backpropagation) (BBP)

İlk olarak geri yayılım (ing. Back Propagation (BP)) algoritması Rumelhart [55] tarafından önerilmiştir ve ANN uygulamaları için oldukça başarılı olduğu birçok çalışmada kanıtlanmıştır. Genel olarak, bir BP algoritmasının amacı ağırlıkları ayarlayarak girdi (w) ve çıktı (u) çiftleri arasındaki özel ilişkiyi öğrenmektir [63]. Hesaplanan çıktı (z) değerlerinin, istenilen çıktı (t) değerlerine ulaşmasını sağlamak için ağırlıklar, “gradient descent” kuralı ile ayarlanır ve hata (E) minimize edilir. Ağırlıkların minimize edilmesinde Eş. 4.3 kullanılır.

$$\Delta W = -\eta \left( \frac{\partial E}{\partial W} \right) \quad (4.3)$$

Burada  $\eta$  öğrenme katsayı ve  $\Delta W$  ağırlık vektörlerinde artan değişimdir.  $\eta$  değeri ne kadar büyük olursa ağırlıklardaki değişimler de o kadar büyük olmaktadır [64]. Her ne kadar ileri beslemeli sinir ağlarının eğitiminde, araştırmacılar tarafından en sık kullanılan ve ilk popüler olan algoritma olsa da, BP algoritmasının yavaş yakınsama ve kararsızlık sebepleriyle çoğunlukla osilasyona maruz kalması,

yetersiz öğrenme gibi sorunlara neden olabilmektedir [65]. Literatürde üzerinde değişiklik yapılmış birçok BP algoritmasına rastlamak mümkündür [49], [48].

Bu çalışmada, Alyuda NeuroIntelligence 2.3 programında mevcut olan Batch-Backpropagation (BBP) algoritması kullanılmıştır. BBP algoritmasında her ağ türev elde etmek için değerlendirilir ve toplam türevini elde etmek için toplanır.

$$\frac{\partial E}{\partial W} = \sum_p \frac{\partial E_p}{\partial W} \quad (4.4)$$

Bu işlemden sonra ağırlıklar güncellenir ve ağırlıkları güncellemek için Eş. 4.5'de verilen denklem kullanılır.

$$w(t + 1) = w(t) - \eta \frac{\partial E}{\partial W} \quad (4.5)$$

BBP algoritmasında, gradyan tam olarak hesaplanır ve ağırlık değişimleri gradyanla doğru orantılı olur. Her adımda, ağırlıklar hatayı en aza indirecek yönde ayarlanır.

#### 4.4.2. Hızlı Yayılım (Quick Propagation) (QP)

Temeli, geri yayılım metoduna dayanan hızlı yayılım (ing. Quick Propagation (QP)) algoritması, Fahlman [67] tarafından geliştirilmiştir. QP algoritması, BP algoritmasının sezgisel modifikasyonu olarak tanımlanır. Momentum olmaksızın sezgisel öğrenme ve eğitim sırasında optimize edilen öğrenme hızı özellikleriyle bilinir [50], [51]. Ağırlıklar arasında tam bağımsızlık varsayımını kabul eden bu algortmada, belirli sayıda tekrarlanan sonunda ağda ilerleme sağlanamaması durumunda başlangıç ağırlık değerleri değiştirilerek işlem yeniden tekrarlamaya (iterasyon) başlanır. Ağırlık değerlerindeki artışın büyüklüğü, hızlı yayılım katsayısı olarak tanımlanan parametre ile denetlenmektedir [66]. QP algoritması, BP'de olduğu gibi ağırlıkların güncellenmesinde  $\partial E / \partial w$  değerini hesaplar ancak bunun için basit "gradient descent" yerine Newton yöntemiyle bağlantılı ikinci dereceden bir denklem kullanır.

$\Delta W$  ağırlık artışın hesaplanmasında kullanılan ikinci dereceden denklem Eş. 4.6'daki gibidir;

$$\Delta W(t) = \frac{S(t)}{S(t-1) - S(t)} \Delta W(t-1) \quad (4.6)$$

Burada  $S(t) = \left(\frac{\partial E}{\partial w}\right)(t)$  'yi temsil etmektedir [64].

QP algoritması, BP algoritmasının ölçek problemini çözen en iyi algoritmalarından biridir, birçok problemin çözümünde BP'den daha hızlıdır [64], [67], [51].

#### 4.4.3. Eşlenik Eğim (Conjugate Gradient Descent) (CGD)

Eşlenik eğim (ing. Conjugate Gradient Descent (CGD)) öğrenme algoritması, geri yayılım (Steepest Descent) ile Newton yöntemleri arasındadır ve en dik (steepest) doğrultuda olduğundan genellikle daha hızlı olan eşlenik (conjugate) doğrultu boyunca arama yapar. Genel olarak, ağırlıklar mevcut arama doğrultusu boyunca en uygun mesafe (öğrenme oranı;  $\alpha_k$ ) tarafından güncellenir (Eş.4.7).

$$W^{(k+1)} = W^{(k)} + \alpha_k d_k \quad (4.7)$$

Burada  $d_k$  mevcut gradyan ( $g_k$ ) ve bir önceki arama doğrultusunun ( $d_{k-1}$ ) doğrusal bir fonksiyonu olarak seçilen "steepest descent" doğrultusudur [63].

CGD algoritmasının en önemli avantajı yeni bir doğrultu vektörü belirlemek için kullanılan basit formüldür. Ayrıca, doğrultular gradyanlara dayalı oluşu için işlem süresince her adımda çözüme doğru tek tip ilerleme yapılabilir. Oldukça gelişmiş bir eğitim algoritması olan CGD algoritması, geri yayılım algoritmasına göre daha doğru ve güvenilir sonuçlar vermektedir. Ayrıca büyük ölçekli ANN'lerinin eğitiminde de oldukça verimlidir [64].

#### 4.4.4. Levenberg–Marquardt Algoritması (LM)

Levenberg–Marquardt (LM) algoritması, Kenneth Levenberg ve Donald Marquardt tarafından geliştirilmiştir [62]. Hızlı ve sabit yakınsama özelliğine sahip olan bu algoritma, Gauss-Newton ve Steepest-Descent (geri yayılım) algoritmalarının en

iyi özelliklerinden oluşur ve bu iki metodun kısıtlamalarını ortadan kaldırır. Gauss-Newton algoritmasının hız avantajı ve Steepest-Descent methodunun kararlılık özelliğini alan LM algoritmasının temeli, kombine bir eğitim süreci gerçekleştirmesidir. Bu anlamda en etkili eğitim algoritmalarından biri olarak kabul edilmektedir [62].

Hessian matrisi elde etmek amacıyla ağırlıklarının güncellenmesinde Newton metodu kullanılırsa, toplam hata fonksiyonun ikinci dereceden türevinin hesaplanması gerekmektedir ve bu işlem bazen çok karmaşık olmaktadır. Hesaplama işleminin basite indirgenmesi için Jacobian matrisi kullanılmaktadır. Hessian matrisi  $H$  ve Jacobian matrisi  $J$  arasındaki ilişki Eş. 4.8'deki gibi yazılabilir.

$$H \approx J^T J \quad (4.8)$$

LM algoritması Hessian matrisine farklı bir yaklaşım getirir;

$$H \approx J^T J + \mu I \quad (4.9)$$

Burada  $I$  birim matrisi,  $\mu$  ise birleşim katsayısıdır ve her zaman pozitifdir. Bu yaklaşımın Gauss-Newton (Eş. 4.10) ile birleşmesiyle LM algoritması Eş. 4.11'de olduğu gibi yazılır.

$$\Delta W^{r+1} = \Delta W^r - (J_k^T J_k)^{-1} J_k e_k \quad (4.10)$$

$$\Delta W^{r+1} = \Delta W^r - (J_k^T J_k + \mu I)^{-1} J_k e_k \quad (4.11)$$

LM algoritması ağırlık eğitimi süresince Gauss-Newton ve Steepest-Descent algoritmaları arasında gider gelir.  $\mu'$  nun sıfıra yakın olduğu durumlarda Gauss-Newton,  $\mu'$  nun büyük olduğu durumlarda ise Steepest-Descent algoritması kullanılır. Birleşim katsayısı  $\mu$  çok büyük olduğunda, Steepest-Descent algoritması içinde öğrenme katsayısı olarak yorumlanabilir (Eş. 4.12).

$$\Delta W^{r+1} = \Delta W^r - \alpha g_k \quad (4.12)$$

$$\alpha = \frac{1}{\mu} \quad (4.13)$$


Levenberg–Marquardt algoritması, öğrenme oranı ve momentum faktörünü dikkate almaz [25]. Her ne kadar LM algoritması, eğitim süresi açısından iyi ve hızlı bir performans sağlasa da, sadece çok tabakalı yapay sinir ağları için kullanılabilir olması nedeniyle her zaman tercih edilemez. Algoritmanın en önemli problemi, Hessian matrisinin her ağırlık güncellemesinde tekrar tekrar hesaplanmasıdır. Bu durum da, küçük ölçekli ağlar için oldukça hızlı olan LM algoritmasının, büyük ölçekli ağlar için Steepest-Descent algoritmasından daha yavaş ve verimsiz olmasına yol açmasıdır. Ayrıca, Jacobian matrisinin hesaplanmasında da çok fazla yer gereksinimi olmasından dolayı yine büyük ölçekli ağlarda bellek problemi yaşanır. Bu nedenle LM algoritması küçük ve orta ölçekteki MLP ağları için önerilir [62], [63], [69].

## 5. HEYELAN ENVANTERİ VE PARAMETRE HARİTALARININ OLUŞTURULMASI

### 5.1. Heyelan Envanteri

Heyelan envanter haritaları, heyelan duyarlılık, tehlike ve risk haritalarının üretilmesi için gerekli olan temel bilgileri ve heyelan özelliklerini içeren en önemli değerlendirme ölçütlerinden birisidir. Heyelan duyarlılık değerlendirme yöntemlerinin çoğu için temel oluşturan heyelan envanteri, bir bölgedeki heyelanların konumu (nokta veya poligon olarak), türü, aktivitesi ve fiziksel özellikleri gibi konulara ilişkin bilgileri içeren veri topluluğu olarak tanımlanmaktadır [8]. Heyelan envanterinin hazırlanması için birçok yöntem kullanılabilir. İlk aşamada, geçmişte meydana gelmiş heyelanlar hakkında bilgi edinilmelidir. Bunun sebebi, aynı özelliklere sahip alanların ayırt edilebilmesi ve bu özellikler kullanılarak ileriye dönük modellenmesi amaçlanmaktadır. Ancak, zaman içerisinde arazi kullanımındaki değişiklikler, yol yapımı vb. sebeplerden dolayı meydana gelen değişimlerin belirlenebilmesi için, mevcut heyelan veri tabanlarının güncellenebilmesi veya kontrol edilmesi gerekmektedir. Günümüzde heyelanlı bölgelerin yorumlanmasında, dünyanın birçok yerinde yüksek çözünürlükte uydu görüntüleri ile Google Earth yazılım verilerinin sayısal yükseklik modeliyle birleştirilerek kullanımı iyi bir alternatif olarak kabul edilmektedir [45].


Bu tez çalışmasında, çalışma alanına ait heyelan envanter haritasının hazırlanmasında; ayrıntılı saha çalışmalarının yanı sıra, Google Earth yazılımından ve hava fotoğraflarından yararlanılmıştır. Bu çalışmalar sonucunda, 200 km<sup>2</sup> alana sahip çalışma alanında toplam alanı 19.89 km<sup>2</sup> olan toplam 196 adet heyelan haritalanmıştır (Şekil 5.1).





Şekil 5.1. Çalışma alanı içerisindeki heyelanların mekansal dağılımları.

Çalışma alanında meydana gelen heyelanların boyutları incelendiğinde ise, alansal olarak en küçük boyutlu heyelan  $12210 \text{ m}^2$  lik bir alan kaplamaktayken, en büyük boyutlu heyelan ise  $0.80 \text{ km}^2$  lik bir alana karşılık gelmektedir. Mevcut heyelanların alansal dağılımları Şekil 5.2’de görülmektedir. Varnes [42] sınıflamasına göre çalışma alanı içerisindeki yenilmeler, kütleli dairesel toprak kaymaları olarak sınıflandırılmıştır. Bu sınıflama yapılırken, sayısı az olmakla birlikte zon şeklinde gelişen çoklu kaymalar ile farklı türde duraysızlık içeren karmaşık kaymalar (örneğin; akma ile başlayıp, dairesel kayma ile devam eden heyelanlar) ayrı ayrı değerlendirilmemiştir.

Çalışma alanı içerisinde meydana gelen heyelanlara ilişkin örnek fotoğraflar, Şekil 5.3’de verilmiştir.



Şekil 5.2. Çalışma alanındaki heyelanların alansal dağılımları.



Şekil 5.3. Çalışma alanı içerisinde meydana gelen heyelanlara ait örnek fotoğraflar.

## **5.2. Parametre Haritalarının Oluřturulması**

Tez alıřması kapsamında bu blmde, duyarlılık analizlerinde kullanılan parametreler ele alınarak bunların alıřma alanı ierisindeki daėılımları ve heyelanlarla olan iliřkilerinden bahsedilecektir. Parametreler, Blm 2’de yer verilen alıřmalarda arařtırmacılar arasında yksek oranda kullanıma sahip olan ve eldeki mevcut veriler dikkate alınarak seilmiřtir. Sz konusu bu parametreler; topoėrafik ykseklik, yama eėimi, bakı, litoloji, TWI (Topoėrafik nemlilik indeksi) ve NDVI (Bitki rts indeksi) olarak dikkate alınmıř ve ANN analizlerinde girdi verileri olarak kullanılmıřlardır.


Dikkate alınan ve retilen tm haritalarda znrlk, 25x25m’lik hcre boyutu kullanarak hazırlanmıřtır. Sayısal ykseklik modelinden (SYM) tretilen parametreler ArcGIS 10 (ArcMap 10) programının sayısal ykseklik modelinin analiz aracı (DEMAT) kullanarak retilmiřtir. Heyelan duyarlılık analizlerinde kullanılan, litoloji parametresi kategorik veri ve diėer tm parametreler, her bir pikseldeki deėerleri dikkate alınarak srekli veri olarak kullanılmıřlardır.

### **5.2.1. Sayısal ykseklik modeli (SYM) ve SYM’den tretilen parametreler**

Heyelan duyarlılık analizlerinin en nemli faktrlerden biri olan topoėrafik zelliklerin belirlenebilmesi iin ilk olarak bir Sayısal Ykseklik Modeli (SYM) oluřturulması gereklidir. SYM yeryz topoėrafyasını orman, bina, bitki rts v.b. detayları iermeksizin yansıtan, sayısal bir modeldir. SYM’nin oluřturulmasında; mevcut topoėrafik haritaların sayısallařtırılması, topoėrafik tesviye, Elektronik Mesafe lm (EDM), diferansiyel GPS lmleri, sayısal fotogrametri, InSAR ve LIDAR verilerinin kullanılması gibi eřitli yntemler vardır. Literatrde yaygın olarak dzenli grid yapıları ve gen řeklinde dzensiz aėlar (TIN) olmak zere iki farklı sayısal ykseklik modeli ile karřılařılmaktadır. Bu iki modelin rnek gsterimi řekil 5.4(a,b)’de verilmiřtir. Bunlardan bu tez alıřması kapsamında, basit oluřu ve bařka veri ortamlarına kolaylıkla uyum saėlayabilmesi aısından (25x25m’lik) dzenli grid yapısı kullanılmıřtır.

alıřma alanının SYM, Harita Genel Komutanlıėı’ndan temin edilen 1/25000 lekli sayısal topoėrafik verileri ArcMap 10 programının enterpolasyon aracı (Topo to Raster) kullanarak elde edilmiřtir. Tez kapsamında, duyarlılık

analizlerinde kullanılan SYM'den türetilmiş topoğrafik parametreler; topoğrafik yükseklik, yamaç eğimi ve bakı parametreleridir. Bu parametreler çalışma alanına ait mevcut SYM kullanılarak ArcGIS 10 (ArcMap 10) programının konumsal analiz (spatial analysis) aracı kullanılarak üretilmiştir.




Şekil 5.4. (a) düzenli grid yapısı ve (b) üçgen şeklinde düzensiz ağ yapısı.

#### 5.2.1.1. Topoğrafik yükseklik

Topoğrafik yükseklik, deniz seviyesinden itibaren olan yüksekliği ifade etmektedir. Araştırmacılar, heyelan ve yükseklik arasındaki ilişkinin belirsizlikler içermesine karşın yükseklikle ilişkili diğer parametreler üzerinde etkisinin olduğunu düşünmektedirler. Örneğin yükseklik, fiziksel erozyon ve kimyasal ayrışmayla birlikte toprak özelliklerini (toprak yapısı, derinlik ve tane boyu) önemli ölçüde etkiler [23]. Bölüm 2'de incelenen çalışmaların % 57'sinde topoğrafik yükseklik parametresinin girdi olarak kullanıldığı görülmektedir (bkz. Çizelge 2.1). Her ne kadar heyelanların topoğrafik yüksekliğin fazla olduğu bölgelerde yoğun olacağı düşünülse de, araştırmalarında girdi parametresi olarak yüksekliği kullanan araştırmacıların büyük çoğunluğu, heyelan sıklığının düşük topoğrafik yüksekliklerde daha fazla olduğunu belirlemişlerdir. Heyelanların daha düşük topoğrafik yüksekliklerde meydana gelmesi, yüksek bölgelerin, duraylı birimlerden oluşması ve bu bölgelerin yoğun bitki örtüsü ile kaplı olmasıyla açıklanabilir [70]. Aynı zamanda arazi kullanımının çok yüksek bölgelerde daha az olması, başka bir deyişle insan etkisinin de, heyelanların düşük topoğrafyalarda sık görülmesinin sebebi olarak düşünülebilir.

Çalışma alanının genel dağılımına bakıldığında; alanındaki yükseklik değerleri 454-1447 m arasında değişmekte olup, ortalama yükseklik 1020.7 m olarak belirlenmiştir (Şekil 5.5).




Şekil 5.5. Çalışma alanının sayısal yükseklik modeli.

#### 5.2.1.2. Yamaç eğimi

Yamaç eğimi, yamaç yüzeyi ve yeraltısuyu akışının hızına, toprak yapısına, erozyon potansiyeline, hidrolojik ve jeomorfolojik süreçler gibi birbirinden farklı özellikler üzerinde doğrudan veya dolaylı bir şekilde, önemli oranda etki etmektedir. Bu nedenle araştırmacılar arasında yamaç eğimi için “heyelan duyarlılık analizlerinin anahtar faktörlerinden biridir” görüşü hakimdir [23], [25]. Bölüm 2’de incelenen tüm çalışmalarda, araştırmacılar yamaç eğimini girdi parametresi olarak kullanmışlardır (bkz. Çizelge 2.1). Buradan yola çıkarak, yamaç eğiminin heyelan duraylılığı üzerinde en etkili ve vazgeçilmez parametre olduğunu söylemek mümkündür. Heyelan duyarlılık değerlendirmelerinde, heyelan sıklığının hangi yamaç eğimlerinde daha fazla olduğunu belirleyebilmek için, farklı eğim dereceleri sınıflandırılarak heyelanların hangi eğim sınıfı aralıklarında yoğunlaştığı belirlenmektedir. Genel olarak, eğim açısının düşük olduğu alanların heyelana karşı daha az duyarlı olduğu kabul edilmekte, heyelan duyarlılığının, şevin eğim açısının artmasına bağlı olarak arttığı düşünülmektedir. Ancak bu varsayımlar, çalışma alanında da gözlemlendiği üzere, bölgesel heyelan özellikleri ve diğer parametreler ile de ilişkili olarak değişim gösterebilmekte, düşük yamaç eğimlerinde de önemli oranda heyelanlar gözlemlenmektedir.

Yamaç eğimin çok yüksek olduğu yamaçlarda ise, toprak malzemenin yeterli kalınlık değerine (en az 1-2m) ulaşamaması ve dayanımlı kaya malzemesinin varlığı ile heyelanların daha az geliştiği düşünülebilir [22], [23]. İncelenen çalışmaların birçoğunda heyelanların 20° ila 40° arasında değişen yamaçlarda daha sık oluşma eğiliminde olduğu belirlenmiştir [18], [24], [29], [33], [34], [26], [27], [28], [29], [35], [30], [31], [37], [39], [40].

Bu tez çalışmasında kullanılan yamaç eğimi haritası, SYM yardımıyla ArcGIS 10 programı kullanılarak oluşturulmuştur (Şekil 5.6). Çalışma alanındaki yamaç eğimi değerleri, 0° - 45° arasında değişmekte olup, ortalama yamaç eğimi 15°’dir.




Şekil 5.6. Çalışma alanına ait yamaç eğimi haritası.

### 5.2.1.3. Bakı

Bakı (yamaç yönelimi), genel olarak saat yönünde 0°'den 360°'a kadar derecelendirilmiş azimut değerleri ile ifade edilir. Wilson ve Gallant [71] ise bakıyı topoğrafik dikliğin azalım doğrultusunun kuzeyden itibaren saat yönünde yapmış olduğu açı olarak tanımlamaktadır. Araştırmacılar arasında, bakı parametresinin heyelan üzerindeki etkisine yönelik net bir görüş birliği yoktur. Bazı araştırmacılar, bakının heyelanlar üzerinde hiçbir önemli etkiye sahip olmadığını söylerken, bazı araştırmacılar da yamaç yönelimi ve heyelan oluşumu arasında önemli bir ilişki olduğunu savunmuşlardır [23]. Bu ilişki, güneş görmeyen yamaçlarda karın daha uzun süre kalması, bölgenin genel yağış yönü, nem tutma ve bitki örtüsü gibi faktörlerin yamaç duraylılığında azalıma yol açtığı şeklinde açıklanabilir [23], [38].

Tez çalışması kapsamında incelenen çalışmaların %71'inde bakı girdi parametresi olarak kullanılmıştır (bkz. Çizelge 2.1). Araştırmacılar yaptıkları çalışmalarda, bakı değerlerini gruplandırırlarında hangi yönelimlerde heyelanların yoğunlaştığını belirlemişlerdir. Örneğin, Yeşilnacar ve Topal [24] yaptıkları çalışmada, sahadaki heyelanların farklı yamaç yönelimlerinde eşit oranda oluştuğunu belirtmiş ve bakının çalışmalarında etkin bir parametre olmadığını vurgulamışlardır. Buna karşın Ercanoğlu [22] ve Kawabata ve Bandibas [29] batıya, Kanungo vd. [25], Yılmaz [35], Choi vd. [32] ve Zare vd. [40] doğu ve güneydoğuya, Yılmaz [27] ve Yılmaz [28] güneydoğu ve güneye bakan yamaçlarda heyelanların daha fazla görüldüğünü belirtmişlerdir. Çalışma alanının bakı haritası SYM yardımıyla ArcGIS 10 programı kullanılarak oluşturulmuştur (Şekil 5.7).



Şekil 5.7. Çalışma alanına ait bakı haritası.

#### 5.2.1.4. Topoğrafik Nemlilik İndeksi


Topoğrafik nemlilik indeksi (TWI), akarsu havzası içindeki bir noktada, su akışının toplamı olarak tanımlanmakta ve heyelan duyarlılık değerlendirmelerinde sıkça kullanılmaktadır. İncelenen çalışmalar içinde yaygın olarak kullanılan parametrelerden biri olan nemlilik indeksi, 21 çalışmanın 8'inde (% 38) girdi parametresi olarak kullanılmıştır (bkz. Çizelge 2.1). Gomez ve Kavzoğlu [23] nemlilik indeksini, topraktaki su içeriğinin dolaylı bir ölçümü olarak tanımlamışlar ve toprak neminin özellikle sık heyelanların gelişiminde önemli bir etkisi olduğunu belirtmişlerdir.

Topoğrafik nemlilik indeksini hesaplamak için Eş. 5.1 kullanılmaktadır.

$$TWI = \ln\left(\frac{A_s}{\tan\beta}\right) \quad (5.1)$$

Topoğrafik nemlilik indeksinin elde edilmesinde akış yönünden türetilen akış toplama alanı bilgisi ve yamaç eğimi kullanılır. Bu eşitlikte;  $A_s$ , havza alanını;  $\beta$  ise yamaç eğimini ifade etmektedir.

SYM'den üretilen inceleme alanının topoğrafik nemlilik indeksi haritası, Şekil 5,8'de sunulmaktadır. Çalışma alanındaki nemlilik indeksi değerleri, 3 ile 20 arasında değişmekte olup, mevcut heyelanların % 96'sının, 4 ile 10 arasında değişen nemlilik indeksi değerlerine sahip alanlarda meydana geldiği görülmektedir.



Şekil 5.8. Çalışma alanına ait nemlilik indeksi haritası.

## 5.2.2. Jeolojik Parametre

### 5.2.2.1. Litoloji

Litoloji, heyelan türünü ve mekanizmasını doğrudan kontrol eden en önemli jeolojik parametrelerden biridir. Litoloji parametresi, incelenen çalışmalarda en yaygın olarak kullanılan parametrelerden biri olup, 21 çalışmanın 15 tanesinde (% 71) girdi parametresi olarak kullanılmıştır (bkz. Çizelge 2.1). Kanungo vd. [25] ve Yılmaz [27] yaptıkları çalışmalarda, heyelan oluşumuyla ilgili en etkin girdi parametresinin litoloji olduğu sonucuna varmışlardır. Bununla birlikte, bazı araştırmacılar bu parametreyi heyelan duyarlılık analizlerinde dikkate almamışlardır. Örneğin, Ercanoğlu [22] yaptığı çalışmada, heyelanların sadece bir birim içinde geliştiğini belirlemiş ve analizlerde bu parametreyi dikkate almamıştır. Li vd. [39] ise yaptığı çalışmada litoloji parametresinin sonuçlar üzerinde belirgin bir etkisi olmadığı sonucuna ulaşmıştır. Lee vd. [18], Ermini vd. [21], Goméz ve Kavzoğlu [23], Yeşilnacar ve Topal [24], Kanungo vd. [25], Pradhan ve Lee [26], Yılmaz [27], Yılmaz [28], Kawabata ve Bandibas [29], Yılmaz [35], Pradhan vd. [36], Garcia-Rodriguez ve Malpica [38], Li vd. [39], Bui vd. [31], Zare vd. [40] ise litoloji parametresini, genellikle heyelanların hangi litolojik birimlerde daha yoğun olarak meydana geldiğini belirlemek amacıyla, farklı sınıflandırmalar yaparak kullanmışlardır.

MTA (2002)'in yaptığı genel jeoloji haritasına göre çalışma alanında 9 farklı formasyona rastlanmaktadır (bkz. Şekil 1.6). Çalışma alanı içerisinde gözlenen litolojik birimler, Ulus formasyonu (Ku), Abant formasyonu (KTab), Kışlaköy formasyonu (Tek), Safranbolu formasyonu (Tes), Çeçen üyesi (Tekaç), Karabük formasyonu (Teka), Soğanlı formasyonu (Teso), Akçapınar formasyonu (Tea), Alüvyon (Qal)'dir. Çalışma alanında yer alan litolojik birimlerin genel saha içerisindeki alansal dağılımlarına bakıldığında Ulus formasyonu (Ku) birimi % 36 yüzdesiyle ilk sırada yer almaktadır. Ardından % 24'lik yüzdesiyle Kışlaköy formasyonu (Tek) birimi gelmektedir. Çizelge 5.1'e göre en düşük yüzdeye sahip olan birim Soğanlı formasyonu (Teso) 'dur.

Çizelge 5.1. Litolojik birimlerin saha içerisindeki genel dağılımları.

| Litolojik birimler          | Alansal dağılım (%) | Heyelanların birimler içinde dağılımı (%) |
|-----------------------------|---------------------|-------------------------------------------|
| Alüvyon (Qal)               | 5.3                 | 0.00                                      |
| Akçapınar formasyonu (Tea)  | 0.12                | 0.00                                      |
| Soğanlı formasyonu (Teso)   | 0.69                | 0.00                                      |
| Karabük formasyonu (Teka)   | 16.59               | 8.07                                      |
| Çeçen üyesi (Tekaç)         | 3                   | 2.93                                      |
| Safranbolu formasyonu (Tes) | 12.78               | 9.98                                      |
| Kışlaköy formasyonu (Tek)   | 24.35               | 24.70                                     |
| Abant formasyonu (KTab)     | 0.95                | 0.83                                      |
| Ulus formasyonu (Ku)        | 36.21               | 53.49                                     |

### 5.2.3. Çevresel Parametre

#### 5.2.3.1. Bitki örtüsü indeksi (NDVI)


Bitki örtüsü, araştırmacılar tarafından erozyon kontrolünde önemli rol oynayan bir parametre olarak değerlendirilmekte ve heyelan duyarlılığı çalışmalarında da yaygın olarak kullanılmaktadır. Birçok çalışma, özellikle sığ heyelan bitki örtüsü ve şev stabilitesi arasında açık bir ilişki ortaya çıkarmaktadır. Bu ilişki bitki örtüsü yoğunluğunun azalmasıyla, heyelan olasılığının artması ile açıklanmaktadır [23]. Bu parametrenin, incelenen çalışmaların % 71'inde, girdi parametresi olarak kullanıldığı belirlenmiştir (Bkz. Çizelge 2.1). Bitki örtüsü indeksi, araştırmacılar arasında en yaygın olarak kullanılan, NDVI olarak adlandırılan normalleştirilmiş bitki örtüsü indeksi değerine göre belirlenmiştir. Ercanoğlu [22], Kanungo vd. [25], Pradhan ve Lee [26], Yılmaz [28], Yılmaz [35], Pradhan vd. [36] ve Choi vd. [37] yaptıkları heyelan duyarlılık çalışmasında bitki örtüsü göstergelerini belirlemek amacıyla, eğim tabanlı bitki örtüsü indeksi NDVI' ı kullanmışlardır. NDVI bir yüzey yansıtma ölçüsüdür ve bitki örtüsü gelişimi ve sağlıklı biyokütle ile ilgili nicel bir tahmin verir [28].

Landsat TM+ uydu görüntüsü kullanılarak NDVI aşağıdaki Eş. 5.1'e göre hesaplanır;

$$NDVI = (IR - R)/(IR + R) \quad (5.1)$$

Burada IR elektromanyetik spektrumun kızıl ötesi bandı, R ise elektromanyetik spektrumun kırmızı bandındaki yansıma değerlerini ifade etmektedir.

Çalışma alanının NDVI haritası, Landsat TM kullanılarak ArcGIS 10 programının NDVI aracıyla oluşturulmuştur (Şekil 5.9).



Şekil 5.9. Çalışma alanına ait bitki örtüsü indeksi haritası.

## 6. ANN ANALİZLERİ VE HEYELAN DUYARLILIK HARİTALARININ OLUŞTURULMASI

Bu çalışmada, tek ve iki gizli tabakadan oluşan çok tabakalı yapay sinir ağı mimarisinde ve dört farklı eğitim algoritmasına sahip ANN modelleri kullanılarak heyelan duyarlılık haritalarının oluşturulması ve eğitim algoritmalarının performanslarının karşılaştırılması yönünde bir çalışma yöntemi izlenmiştir. Söz konusu ağ tasarımları ve eğitim algoritmaları dikkate alınarak, heyelan duyarlılık haritaları üretilmiş ve bunlardan mevcut durumu en iyi yansıtan ağ tasarımı ve algoritmasının ortaya konulması hedeflenmiştir.


Bu hedef doğrultusunda, parametre haritalarının hazırlanması, veri setinin oluşturulması, ANN modellerinin oluşturulması, sonuç haritalarının üretilmesi ve performans değerlendirmesi aşamalarını gösteren akış şeması Şekil 6.1’de yer almaktadır.

### 6.1. ANN Tasarımı

ANN’nın tasarım aşamasında öncelikle;

- ✓ Eğitim, doğrulama ve test veri setlerinin oranları,
- ✓ Gizli katmandaki nöron sayısı,
- ✓ Aktivasyon fonksiyonu,
- ✓ Öğrenme katsayısı,
- ✓ Momentum katsayısı,
- ✓ İterasyon sayısı,
- ✓ MSE (The Mean Square Error),

değerlerinin belirlenmesi gerekmektedir. İzleyen paragraflarda sözü edilen bu parametreler ilişkin ayrıntılara değinilmiştir.



Şekil 6.1. Akış şeması.

### 6.1.1. Veri Setlerinin Hazırlanması

ANN yöntemi uygulamalarının ilk aşamasında, ağın eğitilebilmesi için gerekli olan veri setlerinin hazırlanması gerekmektedir. Heyelanlı ve heyelan olmayan alanları temsil eden veri setleri, heyelan oluşumunda etkin olduğu düşünülen ve Bölüm 5'te ayrıntılı olarak değinilen, topoğrafik yükseklik, yamaç eğimi, bakı, litoloji, bitki örtüsü indeksi ve topoğrafik nemlilik indeksi olmak üzere altı adet sürekli değişken içermektedir. 25x25m'lik hücre boyutuna sahip parametre haritalarından elde edilen her bir girdi verisi, 320.000 adet heyelanlı ve heyelan olmayan alanları temsil eden piksel değerine sahiptir. ANN analizlerinin daha az veriyle yapılabilmesi için literatürde, heyelan envanteri içerisinde örneklem yaparken kullanılan farklı yaklaşımlar vardır. Bunlardan bazıları; kopma zonu, kök hücre ve heyelanın taç kısmından alınan nokta örneklem yaklaşımlarıdır [35]. Bu çalışmada, analizlerinin yapıldığı programının çalışma kapasitesi dahilinde 320.000 adet veriyi temsil etmesi için nokta örneklem yaklaşımı tercih edilmiştir. Haritalanmış heyelanlarının taç noktalarından alınan 196 noktaya karşılık, 196 tane de heyelan olmayan alanlardan rastgele nokta seçilmiş ve her bir girdi parametresi için toplam 392 adet veri hazırlanmıştır.

ANN analizleri için veri setinin hazırlanmasında verilerin normalleştirilmesi, ANN analizleri için bu çalışmada kullanılan Alyuda NeuroIntelligence 2.3. programı ile gerçekleştirilmiştir. Altı adet değişkene ait değerlerin “-1” ile “1” arasında normalleştirilmesinde Eş. 6.1 ve Eş. 6.2’de verilen eşitlikler kullanılmaktadır.

$$SF = (SR_{\max} - SR_{\min}) / (X_{\max} - X_{\min}) \quad (6.1)$$

$$X_P = (SR_{\min}) + (X - X_{\min}) * SF \quad (6.2)$$

Bu eşitliklerde;

SF: Normalleştirme faktörü,

X: Normalleştirilecek değer,

XP: Normalleştirilen değer,

SRmax: Normalleştirme aralığının en büyük değeri,

SRmin: Normalleştirme aralığının en küçük değeri,

Xmax: Değişkenin en büyük değeri,

Xmin: Değişkenin en küçük değeri

temsil etmektedir.

ANN'nin öğrenme sürecinin doğru bir şekilde tamamlanabilmesi için ağı eğitilmesi, test edilmesi ve doğruluğunun kontrol edilmesi gerekmektedir. Bu nedenle veri seti; eğitim (training), deneme (test) ve doğrulama (validation) veri setleri olarak üç bölüme ayrılmalıdır. ANN'nin eğitim aşaması için kullanılan ve girdi veri setinin büyük bir kısmını oluşturan eğitim veri seti, ağı doğru sonuçları tahmin edebilme yeteneğini en üst seviyeye çıkartabilmek ve hatayı en küçük değere indirgeyebilmek için kullanılmaktadır. Test veri seti, öğrenme sürecinde değerlendirmeye alınmamakta ve öğrenme aşamasından sonra ağı tahmin başarısının test edilmesinde kullanılmaktadır. Doğrulama veri seti ise, ağı tahmin edebilme yeteneğinin azalması durumunda, ağırlık değerleri dışındaki diğer ağ parametrelerinin ayarlanması amacıyla kullanılmaktadır. Literatürde veri setlerinin, toplam girdinin ne kadarını temsil edeceği konusunda kesin bir kural bulunmamakla birlikte yapılan çalışmaların bir çoğunda eğitim veri setinin girdilerin yaklaşık % 70'ini, deneme ve doğrulama veri setlerinin ise girdilerin yaklaşık % 10'u ile % 30'u arasında kalan kesimini kapsadığı görülmektedir.

Bu çalışmada, eğitim, deneme ve doğrulama veri setleri, analizlerde kullanılan veri setinden, Alyuda NeuroIntelligence 2.3. programı tarafından gelişigüzel seçilmiştir. Veri setinin % 68'i eğitim, % 16'sı test ve % 16'sı doğrulama veri seti olarak ayrılmıştır.

### **6.1.2. Gizli Tabaka ve Nöron Sayısının Belirlenmesi**

Ağ tasarımının ilk aşamasında, gizli tabaka sayısı ve her tabakaya düşen nöron sayısı belirlenmelidir. Çok tabakalı yapay sinir ağlarının en önemli özelliği birden fazla gizli tabaka içerecek şekilde tasarlanabilmeleridir. Buna karşın, literatürde genellikle bir veya iki gizli tabaka kullanılarak tasarlanan ağların iyi performans gösterdiği, bir ya da ikiden daha fazla gizli tabaka içeren ağların herhangi bir avantajı olmadığı belirlenmiştir [60], [24], [55]. Gizli tabaka sayısının artması, ağı yanlış tahminde bulunmasına ve hesap süresinin artmasına neden olabilmektedir.

Gizli tabakadaki nöron sayısı da, ağın performansında etkin bir elemandır. Bazı durumlarda, tek bir gizli tabakada çok sayıda nöron bulunmasındansa, daha az sayıda nöron içeren iki gizli tabakalı ağlar daha iyi performansa sahip olabilmektedir [27].

İncelenen çalışmalarda, Lee vd. [19] ve Lee vd. [20] 7 adet girdi için 15; Goméz ve Kavzoğlu [23] 9 adet girdi için 28; Yeşilnacar ve Topal [24] 19 adet girdi için 13; Ercanoğlu [22] 6 adet girdi için 3; Pradhan ve Lee [26] 9 adet girdi için 19; Yılmaz [27] 8 adet girdi için 17; Yılmaz [28] 11 adet girdi için 23; Kawabata ve Bandibas [29] 6 girdi için 40; Yılmaz [35] 9 adet girdi için 19; Pradhan vd. [36] 15 adet girdi için 32; Choi vd. [37] 14 adet girdi için 30; Garcia-Rodriguez ve Malpica [38] 7 adet girdi için 2; Choi vd. [32] 6 adet girdi için 12; Li vd. [39] 10 adet girdi için 18; Zare vd. [40] 9 adet için 14 adet nöron kullanarak tasarladıkların ağların en yüksek performansa sahip olduğunu belirlemişlerdir.

Bu tez çalışmasında, en iyi performansa sahip ANN'nin tasarlanabilmesi için geri yayılım (BBP), hızlı yayılım (QP), eşlenik eğim (CGD) ve Levenberg–Marquardt (LM) öğrenme algoritmaları için bir adet gizli tabaka kullanılarak test veri seti hata oranı en düşük olan ağ topolojisi 6-13-1 olarak belirlenmiştir (Çizelge 6.1). Ağ tasarımı, iki adet gizli tabaka kullanılması durumunda ise test veri seti hata oranı en düşük olan ağ topolojisi 6-11-6-1 olarak saptanmıştır (Çizelge 6.2). ANN'da iki adet gizli tabaka kullanılması durumunda, 1. tabakadaki nöron sayısının 2. tabakadaki nöron sayısından fazla olması gerekmektedir [34]. Bu nedenle, ağ tasarımı 2. gizli tabakadaki nöron sayısı, 1. gizli tabakadaki nöron sayısından az olacak şekilde, farklı nöron sayıları kullanılarak en iyi ağ seçilmeye çalışılmıştır. Bu işlemler gerçekleştirilirken, sözü edilen yazılımın Ağ Mimarisi modülünden yararlanılarak, eğitim, doğrulama ve test verisi için, hata oranı değeri en düşük olan ağ yapıları seçilmiştir.

Bir adet gizli tabaka içeren ağ tasarımı (6-13-1), Şekil 6.1'de ve iki adet gizli tabaka içeren ağ tasarımı (6-11-6-1), Şekil 6.2'de verilmektedir.

Çizelge 6.1. Tek gizli tabakalı ANN'nin farklı ağ yapılarına ait hata oranları.

| Ağ no     | Ağ yapısı       | Bağlantı<br>ağırlığı sayısı | Eğitim veri seti<br>için hata oranı | Doğrulama<br>veri seti için<br>hata oranı | Test veri seti<br>için hata oranı |
|-----------|-----------------|-----------------------------|-------------------------------------|-------------------------------------------|-----------------------------------|
| 1         | [6-1-1]         | 9                           | 0.1123                              | 0.1392                                    | 0.1561                            |
| 2         | [6-2-1]         | 17                          | 0.1034                              | 0.1299                                    | 0.1447                            |
| 3         | [6-3-1]         | 25                          | 0.1032                              | 0.1342                                    | 0.1499                            |
| 4         | [6-4-1]         | 33                          | 0.1022                              | 0.1285                                    | 0.1465                            |
| 5         | [6-5-1]         | 41                          | 0.1046                              | 0.1324                                    | 0.1479                            |
| 6         | [6-6-1]         | 49                          | 0.0942                              | 0.1123                                    | 0.1376                            |
| 7         | [6-7-1]         | 57                          | 0.1019                              | 0.1272                                    | 0.1438                            |
| 8         | [6-8-1]         | 65                          | 0.1018                              | 0.1281                                    | 0.1446                            |
| 9         | [6-9-1]         | 73                          | 0.0899                              | 0.1099                                    | 0.1339                            |
| 10        | [6-10-1]        | 81                          | 0.1027                              | 0.1286                                    | 0.1432                            |
| 11        | [6-11-1]        | 89                          | 0.0967                              | 0.1224                                    | 0.1381                            |
| 12        | [6-12-1]        | 97                          | 0.0936                              | 0.1229                                    | 0.1392                            |
| <b>13</b> | <b>[6-13-1]</b> | <b>105</b>                  | <b>0.0898</b>                       | <b>0.1082</b>                             | <b>0.1321</b>                     |
| 14        | [6-14-1]        | 113                         | 0.0957                              | 0.1218                                    | 0.1392                            |
| 15        | [6-15-1]        | 121                         | 0.0966                              | 0.1230                                    | 0.1378                            |

Çizelge 6.2. İki gizli tabakalı ANN'nin farklı ağ yapılarına ait hata oranları.

| Ağ No | Ağ yapısı  | Bağlantı<br>ağırlığı sayısı | Eğitim veri seti<br>için hata oranı | Doğrulama<br>veri seti için<br>hata oranı | Test veri seti<br>için hata oranı |
|-------|------------|-----------------------------|-------------------------------------|-------------------------------------------|-----------------------------------|
| 1     | [6-1-1]    | 9                           | 0.0566                              | 0.0961                                    | 0.0488                            |
| 2     | [6-2-1]    | 17                          | 0.0265                              | 0.0969                                    | 0.0484                            |
| 3     | [6-3-1]    | 25                          | 0.1094                              | 0.1290                                    | 0.0806                            |
| 4     | [6-4-1]    | 33                          | 0.0151                              | 0.0648                                    | 0.0329                            |
| 5     | [6-5-1]    | 41                          | 0.0295                              | 0.0790                                    | 0.0523                            |
| 6     | [6-6-1]    | 49                          | 0.0167                              | 0.0746                                    | 0.0437                            |
| 7     | [6-7-1]    | 57                          | 0.1062                              | 0.1290                                    | 0.0892                            |
| 8     | [6-8-1]    | 65                          | 0.0268                              | 0.0672                                    | 0.0341                            |
| 9     | [6-9-1]    | 73                          | 0.0377                              | 0.0967                                    | 0.0484                            |
| 10    | [6-10-1]   | 81                          | 0.0305                              | 0.0718                                    | 0.0270                            |
| 11    | [6-11-1]   | 89                          | 0.0156                              | 0.0747                                    | 0.0250                            |
| 12    | [6-12-1]   | 97                          | 0.0226                              | 0.0808                                    | 0.0484                            |
| 13    | [6-13-1]   | 105                         | 0.0217                              | 0.0603                                    | 0.0596                            |
| 14    | [6-14-1]   | 113                         | 0.0302                              | 0.0806                                    | 0.0484                            |
| 15    | [6-15-1]   | 121                         | 0.0239                              | 0.0911                                    | 0.0303                            |
| 16    | [6-1-1-1]  | 11                          | 0.0592                              | 0.1141                                    | 0.0643                            |
| 17    | [6-2-1-1]  | 19                          | 0.0157                              | 0.0595                                    | 0.0175                            |
| 18    | [6-3-1-1]  | 27                          | 0.0340                              | 0.0968                                    | 0.0484                            |
| 19    | [6-4-1-1]  | 35                          | 0.0448                              | 0.0817                                    | 0.0373                            |
| 20    | [6-5-1-1]  | 43                          | 0.0340                              | 0.0806                                    | 0.0484                            |
| 21    | [6-6-1-1]  | 51                          | 0.0241                              | 0.0773                                    | 0.0616                            |
| 22    | [6-7-1-1]  | 59                          | 0.0208                              | 0.0622                                    | 0.0495                            |
| 23    | [6-8-1-1]  | 67                          | 0.0293                              | 0.0794                                    | 0.0447                            |
| 24    | [6-9-1-1]  | 75                          | 0.0792                              | 0.1129                                    | 0.0806                            |
| 25    | [6-10-1-1] | 83                          | 0.0373                              | 0.0874                                    | 0.0556                            |
| 26    | [6-11-1-1] | 91                          | 0.0717                              | 0.1613                                    | 0.1129                            |
| 27    | [6-12-1-1] | 99                          | 0.0355                              | 0.0808                                    | 0.0460                            |
| 28    | [6-13-1-1] | 107                         | 0.0670                              | 0.1099                                    | 0.0927                            |
| 29    | [6-14-1-1] | 115                         | 0.0150                              | 0.0569                                    | 0.0513                            |
| 30    | [6-15-1-1] | 123                         | 0.0525                              | 0.1088                                    | 0.0594                            |
| 31    | [6-1-2-1]  | 14                          | 0.0952                              | 0.1314                                    | 0.0877                            |
| 32    | [6-2-2-1]  | 23                          | 0.0500                              | 0.0814                                    | 0.0485                            |
| 33    | [6-3-2-1]  | 32                          | 0.0981                              | 0.1290                                    | 0.0968                            |

Çizelge 6.2. Devam ediyor.

| Ağ No | Ağ yapısı  | Bağlantı<br>ağırlığı sayısı | Eğitim veri seti<br>için hata oranı | Doğrulama<br>veri seti için<br>hata oranı | Test veri seti<br>için hata oranı |
|-------|------------|-----------------------------|-------------------------------------|-------------------------------------------|-----------------------------------|
| 34    | [6-4-2-1]  | 41                          | 0.0792                              | 0.1129                                    | 0.0806                            |
| 35    | [6-5-2-1]  | 50                          | 0.0268                              | 0.0673                                    | 0.0301                            |
| 36    | [6-6-2-1]  | 59                          | 0.0403                              | 0.0754                                    | 0.0763                            |
| 37    | [6-7-2-1]  | 68                          | 0.0330                              | 0.0736                                    | 0.0702                            |
| 38    | [6-8-2-1]  | 77                          | 0.0278                              | 0.0683                                    | 0.0598                            |
| 39    | [6-9-2-1]  | 86                          | 0.0302                              | 0.0806                                    | 0.0484                            |
| 40    | [6-10-2-1] | 95                          | 0.0343                              | 0.0665                                    | 0.0486                            |
| 41    | [6-11-2-1] | 104                         | 0.0139                              | 0.0673                                    | 0.0363                            |
| 42    | [6-12-2-1] | 113                         | 0.0258                              | 0.0790                                    | 0.0797                            |
| 43    | [6-13-2-1] | 122                         | 0.0154                              | 0.0900                                    | 0.0446                            |
| 44    | [6-14-2-1] | 131                         | 0.0213                              | 0.0704                                    | 0.0274                            |
| 45    | [6-15-2-1] | 140                         | 0.0393                              | 0.0863                                    | 0.0516                            |
| 46    | [6-1-3-1]  | 17                          | 0.0739                              | 0.1041                                    | 0.0713                            |
| 47    | [6-2-3-1]  | 27                          | 0.0259                              | 0.0727                                    | 0.0541                            |
| 48    | [6-3-3-1]  | 37                          | 0.0216                              | 0.0867                                    | 0.0652                            |
| 49    | [6-4-3-1]  | 47                          | 0.0632                              | 0.1065                                    | 0.0601                            |
| 50    | [6-5-3-1]  | 57                          | 0.0223                              | 0.0466                                    | 0.0383                            |
| 51    | [6-6-3-1]  | 67                          | 0.0635                              | 0.1095                                    | 0.0750                            |
| 52    | [6-7-3-1]  | 77                          | 0.0217                              | 0.0660                                    | 0.0577                            |
| 53    | [6-8-3-1]  | 87                          | 0.0717                              | 0.1129                                    | 0.0484                            |
| 54    | [6-9-3-1]  | 97                          | 0.0186                              | 0.0870                                    | 0.0548                            |
| 55    | [6-10-3-1] | 107                         | 0.0150                              | 0.0524                                    | 0.0162                            |
| 56    | [6-11-3-1] | 117                         | 0.0288                              | 0.0654                                    | 0.0490                            |
| 57    | [6-12-3-1] | 127                         | 0.0356                              | 0.0824                                    | 0.0496                            |
| 58    | [6-13-3-1] | 137                         | 0.0421                              | 0.0968                                    | 0.0484                            |
| 59    | [6-14-3-1] | 147                         | 0.0187                              | 0.0622                                    | 0.0708                            |
| 60    | [6-15-3-1] | 157                         | 0.0397                              | 0.0844                                    | 0.0549                            |
| 61    | [6-1-4-1]  | 20                          | 0.0398                              | 0.1014                                    | 0.0492                            |
| 62    | [6-2-4-1]  | 31                          | 0.0963                              | 0.1301                                    | 0.0862                            |
| 63    | [6-3-4-1]  | 42                          | 0.0183                              | 0.0523                                    | 0.0512                            |
| 64    | [6-4-4-1]  | 53                          | 0.0325                              | 0.1020                                    | 0.0649                            |
| 65    | [6-5-4-1]  | 64                          | 0.0755                              | 0.1129                                    | 0.0645                            |
| 66    | [6-6-4-1]  | 75                          | 0.0548                              | 0.0855                                    | 0.0521                            |

Çizelge 6.2. Devam ediyor.


| Ağ No | Ağ yapısı  | Bağlantı<br>ağırlığı sayısı | Eğitim veri seti<br>için hata oranı | Doğrulama<br>veri seti için<br>hata oranı | Test veri seti<br>için hata oranı |
|-------|------------|-----------------------------|-------------------------------------|-------------------------------------------|-----------------------------------|
| 67    | [6-7-4-1]  | 86                          | 0.0248                              | 0.0701                                    | 0.0531                            |
| 68    | [6-8-4-1]  | 97                          | 0.0284                              | 0.0756                                    | 0.0876                            |
| 69    | [6-9-4-1]  | 108                         | 0.0721                              | 0.0959                                    | 0.0975                            |
| 70    | [6-10-4-1] | 119                         | 0.0213                              | 0.0717                                    | 0.0402                            |
| 71    | [6-11-4-1] | 130                         | 0.0242                              | 0.0507                                    | 0.0583                            |
| 72    | [6-12-4-1] | 141                         | 0.0404                              | 0.0842                                    | 0.0627                            |
| 73    | [6-13-4-1] | 152                         | 0.0422                              | 0.0747                                    | 0.0548                            |
| 74    | [6-14-4-1] | 163                         | 0.0325                              | 0.0619                                    | 0.0590                            |
| 75    | [6-15-4-1] | 174                         | 0.0324                              | 0.0666                                    | 0.0977                            |
| 76    | [6-1-5-1]  | 23                          | 0.0435                              | 0.1097                                    | 0.0500                            |
| 77    | [6-2-5-1]  | 35                          | 0.0658                              | 0.0645                                    | 0.0696                            |
| 78    | [6-3-5-1]  | 47                          | 0.0371                              | 0.0708                                    | 0.0270                            |
| 79    | [6-4-5-1]  | 59                          | 0.0200                              | 0.0742                                    | 0.0174                            |
| 80    | [6-5-5-1]  | 71                          | 0.0382                              | 0.0797                                    | 0.0683                            |
| 81    | [6-6-5-1]  | 83                          | 0.0163                              | 0.0649                                    | 0.0298                            |
| 82    | [6-7-5-1]  | 95                          | 0.0792                              | 0.1129                                    | 0.0806                            |
| 83    | [6-8-5-1]  | 107                         | 0.1132                              | 0.1467                                    | 0.0806                            |
| 84    | [6-9-5-1]  | 119                         | 0.0143                              | 0.0790                                    | 0.0378                            |
| 85    | [6-10-5-1] | 131                         | 0.1094                              | 0.1129                                    | 0.0806                            |
| 86    | [6-11-5-1] | 143                         | 0.0894                              | 0.1240                                    | 0.0702                            |
| 87    | [6-12-5-1] | 155                         | 0.0531                              | 0.0880                                    | 0.0540                            |
| 88    | [6-13-5-1] | 167                         | 0.0182                              | 0.0740                                    | 0.0295                            |
| 89    | [6-14-5-1] | 179                         | 0.0283                              | 0.0742                                    | 0.0851                            |
| 90    | [6-15-5-1] | 191                         | 0.0149                              | 0.0852                                    | 0.0672                            |
| 91    | [6-1-6-1]  | 26                          | 0.0658                              | 0.1118                                    | 0.0639                            |
| 92    | [6-2-6-1]  | 39                          | 0.1049                              | 0.1409                                    | 0.0969                            |
| 93    | [6-3-6-1]  | 52                          | 0.0258                              | 0.0696                                    | 0.0483                            |
| 94    | [6-4-6-1]  | 65                          | 0.0471                              | 0.0674                                    | 0.0472                            |
| 95    | [6-5-6-1]  | 78                          | 0.0420                              | 0.0789                                    | 0.0521                            |
| 96    | [6-6-6-1]  | 91                          | 0.0239                              | 0.0650                                    | 0.0325                            |
| 97    | [6-7-6-1]  | 104                         | 0.0189                              | 0.0650                                    | 0.0331                            |
| 98    | [6-8-6-1]  | 117                         | 0.0477                              | 0.0696                                    | 0.0633                            |
| 99    | [6-9-6-1]  | 130                         | 0.0792                              | 0.1129                                    | 0.0645                            |

Çizelge 6.2. Devam ediyor.


| Ağ No      | Ağ yapısı         | Bağlantı<br>ağırlığı sayısı | Eğitim veri seti<br>için hata oranı | Doğrulama<br>veri seti için<br>hata oranı | Test veri seti<br>için hata oranı |
|------------|-------------------|-----------------------------|-------------------------------------|-------------------------------------------|-----------------------------------|
| 100        | [6-10-6-1]        | 143                         | 0.0126                              | 0.0659                                    | 0.0504                            |
| <b>101</b> | <b>[6-11-6-1]</b> | <b>156</b>                  | <b>0.0151</b>                       | <b>0.0498</b>                             | <b>0.0161</b>                     |
| 102        | [6-12-6-1]        | 169                         | 0.0231                              | 0.0669                                    | 0.0463                            |
| 103        | [6-13-6-1]        | 182                         | 0.0115                              | 0.0605                                    | 0.0363                            |
| 104        | [6-14-6-1]        | 195                         | 0.0391                              | 0.0820                                    | 0.0488                            |
| 105        | [6-15-6-1]        | 208                         | 0.0455                              | 0.0688                                    | 0.0447                            |
| 106        | [6-1-7-1]         | 29                          | 0.0830                              | 0.1128                                    | 0.0853                            |
| 107        | [6-2-7-1]         | 43                          | 0.0392                              | 0.1079                                    | 0.0484                            |
| 108        | [6-3-7-1]         | 57                          | 0.0254                              | 0.0657                                    | 0.0247                            |
| 109        | [6-4-7-1]         | 71                          | 0.0265                              | 0.0968                                    | 0.0485                            |
| 110        | [6-5-7-1]         | 85                          | 0.0376                              | 0.0602                                    | 0.0451                            |
| 111        | [6-6-7-1]         | 99                          | 0.0212                              | 0.0561                                    | 0.0329                            |
| 112        | [6-7-7-1]         | 113                         | 0.0113                              | 0.0647                                    | 0.0476                            |
| 113        | [6-8-7-1]         | 127                         | 0.0427                              | 0.0899                                    | 0.0548                            |
| 114        | [6-9-7-1]         | 141                         | 0.1132                              | 0.1290                                    | 0.0806                            |
| 115        | [6-10-7-1]        | 155                         | 0.0830                              | 0.1290                                    | 0.0968                            |
| 116        | [6-11-7-1]        | 169                         | 0.0476                              | 0.0856                                    | 0.0463                            |
| 117        | [6-12-7-1]        | 183                         | 0.0566                              | 0.0968                                    | 0.0806                            |
| 118        | [6-13-7-1]        | 197                         | 0.0280                              | 0.0794                                    | 0.0555                            |
| 119        | [6-14-7-1]        | 211                         | 0.0452                              | 0.0716                                    | 0.0672                            |
| 120        | [6-15-7-1]        | 225                         | 0.0304                              | 0.0807                                    | 0.0484                            |
| 121        | [6-1-8-1]         | 32                          | 0.0738                              | 0.1148                                    | 0.0730                            |
| 122        | [6-2-8-1]         | 47                          | 0.0499                              | 0.0876                                    | 0.0659                            |
| 123        | [6-3-8-1]         | 62                          | 0.1124                              | 0.1290                                    | 0.0806                            |
| 124        | [6-4-8-1]         | 77                          | 0.0281                              | 0.0804                                    | 0.0515                            |
| 125        | [6-5-8-1]         | 92                          | 0.0265                              | 0.0807                                    | 0.0484                            |
| 126        | [6-6-8-1]         | 107                         | 0.0546                              | 0.0896                                    | 0.0655                            |
| 127        | [6-7-8-1]         | 122                         | 0.0238                              | 0.0643                                    | 0.0194                            |
| 128        | [6-8-8-1]         | 137                         | 0.0385                              | 0.0809                                    | 0.0484                            |
| 129        | [6-9-8-1]         | 152                         | 0.0250                              | 0.0713                                    | 0.0558                            |
| 130        | [6-10-8-1]        | 167                         | 0.0981                              | 0.1290                                    | 0.0968                            |
| 131        | [6-11-8-1]        | 182                         | 0.0267                              | 0.0807                                    | 0.0484                            |
| 132        | [6-12-8-1]        | 197                         | 0.0346                              | 0.0452                                    | 0.0592                            |
| 133        | [6-13-8-1]        | 212                         | 0.0184                              | 0.0853                                    | 0.0719                            |

Çizelge 6.2. Devam ediyor.

| Ağ No | Ağ yapısı   | Bağlantı<br>ağırlığı sayısı | Eğitim veri seti<br>için hata oranı | Doğrulama<br>veri seti için<br>hata oranı | Test veri seti<br>için hata oranı |
|-------|-------------|-----------------------------|-------------------------------------|-------------------------------------------|-----------------------------------|
| 134   | [6-14-8-1]  | 227                         | 0.0276                              | 0.0803                                    | 0.0481                            |
| 135   | [6-15-8-1]  | 242                         | 0.0265                              | 0.0809                                    | 0.0482                            |
| 136   | [6-1-9-1]   | 35                          | 0.1094                              | 0.1290                                    | 0.0806                            |
| 137   | [6-2-9-1]   | 51                          | 0.0767                              | 0.1105                                    | 0.0666                            |
| 138   | [6-3-9-1]   | 67                          | 0.0272                              | 0.0600                                    | 0.0465                            |
| 139   | [6-4-9-1]   | 83                          | 0.0121                              | 0.0562                                    | 0.0560                            |
| 140   | [6-5-9-1]   | 99                          | 0.0171                              | 0.0709                                    | 0.0212                            |
| 141   | [6-6-9-1]   | 115                         | 0.0189                              | 0.0646                                    | 0.0169                            |
| 142   | [6-7-9-1]   | 131                         | 0.0146                              | 0.0845                                    | 0.0190                            |
| 143   | [6-8-9-1]   | 147                         | 0.0238                              | 0.0854                                    | 0.0341                            |
| 144   | [6-9-9-1]   | 163                         | 0.0303                              | 0.0701                                    | 0.0283                            |
| 145   | [6-10-9-1]  | 179                         | 0.0295                              | 0.0805                                    | 0.0356                            |
| 146   | [6-11-9-1]  | 195                         | 0.0234                              | 0.0688                                    | 0.0364                            |
| 147   | [6-12-9-1]  | 211                         | 0.0291                              | 0.0659                                    | 0.0191                            |
| 148   | [6-13-9-1]  | 227                         | 0.0163                              | 0.0826                                    | 0.0327                            |
| 149   | [6-14-9-1]  | 243                         | 0.0353                              | 0.0650                                    | 0.0494                            |
| 150   | [6-15-9-1]  | 259                         | 0.0487                              | 0.0684                                    | 0.0562                            |
| 151   | [6-1-10-1]  | 38                          | 0.0601                              | 0.1081                                    | 0.0595                            |
| 152   | [6-2-10-1]  | 55                          | 0.0564                              | 0.0972                                    | 0.0667                            |
| 153   | [6-3-10-1]  | 72                          | 0.0245                              | 0.0789                                    | 0.0463                            |
| 154   | [6-4-10-1]  | 89                          | 0.0438                              | 0.0907                                    | 0.0502                            |
| 155   | [6-5-10-1]  | 106                         | 0.0198                              | 0.0532                                    | 0.0447                            |
| 156   | [6-6-10-1]  | 123                         | 0.0202                              | 0.0762                                    | 0.0520                            |
| 157   | [6-7-10-1]  | 140                         | 0.0125                              | 0.0648                                    | 0.0331                            |
| 158   | [6-8-10-1]  | 157                         | 0.0151                              | 0.0914                                    | 0.0330                            |
| 159   | [6-9-10-1]  | 174                         | 0.0453                              | 0.0814                                    | 0.0645                            |
| 160   | [6-10-10-1] | 191                         | 0.0115                              | 0.0460                                    | 0.0527                            |
| 161   | [6-11-10-1] | 208                         | 0.0189                              | 0.0584                                    | 0.0323                            |
| 162   | [6-12-10-1] | 225                         | 0.0264                              | 0.0806                                    | 0.0481                            |
| 163   | [6-13-10-1] | 242                         | 0.0295                              | 0.0784                                    | 0.0443                            |
| 164   | [6-14-10-1] | 259                         | 0.0289                              | 0.0604                                    | 0.0687                            |
| 165   | [6-15-10-1] | 276                         | 0.0126                              | 0.0646                                    | 0.0324                            |



Şekil 6.2. Tek gizli tabakalı ANN tasarımı (6-13-1).



Şekil 6.3. İki gizli tabakalı ANN tasarımı (6-11-6-1).

### 6.1.3. Aktivasyon Fonksiyonu

Bir ANN'nin tasarımında, doğrusal, eşik değer, sinüs, hiperbolik tanjant ve sigmoid (lojistik) gibi birçok aktivasyon fonksiyonu kullanılabilir. Ancak, yapılan çalışmaların büyük bir kısmında araştırmacılar, girdi değerlerinin her biri için sıfır ile bir arasında bir değer üreten sigmoid fonksiyonunu kullanmaktadır (Bkz. Şekil 3.3). Bu tez çalışmasında, aktivasyon fonksiyonu olarak sigmoid (lojistik) fonksiyonu kullanılmıştır.

### 6.1.4. Öğrenme ve Momentum Katsayısı

Öğrenme katsayısı, ANN'da ağırlıkların değişim miktarını belirlemektedir. Öğrenme katsayısının çok küçük olması durumunda aşırı öğrenme gerçekleşebilir ve ağ öğrenme süreci fazla zaman alıcı olabilir, büyük bir değer ise yetersiz öğrenmeye neden olur. Momentum Katsayısı ise geri yayımlı ağırlıklarda öğrenme katsayısını artırarak öğrenme sürecinin hızlandırılmasını sağlamaktadır. Öğrenme katsayısı için genel olarak 0.1 - 0.2 değerleri önerilmektedir. Buna karşın, Lee vd. [19], Lee vd. [20], Choi vd. [37], Garcia-Rodriguez ve Malpica [38], Choi vd. [32], ve Li vd. [39] yaptıkları çalışmalarda öğrenme katsayısını 0.01 gibi küçük bir değer olarak; Zare vd. [40] ise 0.9 gibi nispeten yüksek bir değer olarak dikkate almışlardır.

Bu çalışmada, BBP ve QP eğitim algoritmalarını kullanan ağlarda, öğrenme katsayısı için 0.1 değeri kullanılmıştır. BBP algoritması için momentum katsayısı, 0.1 ve QP için hızlı yayılım katsayısı, 1.75 olarak seçilmiştir. CGD ve LM eğitim algoritmaları öğrenme oranı ve momentum katsayılarını dikkate almamaktadır.

### 6.1.5. İterasyon Sayısı

ANN'nin öğrenme aşamasının tamamlanma süreci, iterasyon (tekrarlama) sayısı ile belirlenir. İterasyon sayısının belirlenmesinde farklı yaklaşımlar bulunmaktadır. Ağın öğrenme aşaması, ya hata oranı en küçük değere indirildiği zaman tamamlanmakta, ya da önceden belirlenen iterasyon sayısına ulaşıldığında öğrenme süreci durur.

Bu çalışmada, ANN'nin öğrenme sürecinin tamamlanması için tüm eğitim algoritmaları için maksimum iterasyon sayısı 30000 olarak belirlenmiştir.

#### 6.1.6. MSE (Ortalama Karesel Hata)

MSE (Ortalama Karesel Hata) değeri eğitim verileri için belirlenen MSE değerinin altına düştüğü zaman eğitimi durdurmak için kullanılır. MSE değerinin sıfıra olan yakınlığı, hedeflenen ve tahmin edilen değerler arasında iyi bir ilişki olduğunu gösterir. Belirlenen MSE değeri elde edilinceye kadar ağı eğitim aşaması devam eder.

MSE değeri aşağıdaki eşitlikle ifade edilir;

$$MSE = \left(\frac{1}{N}\right) * \sum_{i=1}^N (y - y')^2 \quad (6.3)$$

Bu eşitlikte; y hedef çıktı, y' tahmin edilen çıktı ve N veri sayısıdır.

Bu çalışmada, MSE değeri 0,001 olarak alınmıştır.

#### 6.1.7. ANN'da Aşırı Öğrenmenin Kontrol Edilmesi

Yapay sinir ağlarının çok fazla eğitilmesi durumunda, ağ performansında düşme yaşandığından aşırı öğrenmenin kontrol edilmesi gerekmektedir. Aşırı öğrenme (overtraining), doğrulama seti kullanılarak belirlenir. Eğitim aşamasında iterasyon devam ederken doğrulama veri seti üzerinde ağ hatasının artması sırasında eğitim veri setinde hatanın azalması aşırı öğrenmenin başlangıç noktası olarak tanımlanır. Aşırı öğrenmenin kontrol edilmesi için Alyuda NeuroIntelligence 2.3. programında aşağıda açıklanan aşırı öğrenme kontrol seçenekleri kullanılmıştır.


✓ **En iyi ağı muhafaza edilmesi ve geri yüklenmesi;** bu seçenekte aşırı eğitimi önlemek için ağ hatası azaltılır. Bir sinir ağı aşırı öğrenmeye başladığında doğrulama hatası yükselirken, eğitim hataları azalmaya devam eder. Doğrulama hatasındaki bu artış kolayca tespit edilebilmesine rağmen, ağı eğitiminin derhal durdurulması gereklidir, çünkü eğitim ve doğrulama hataları iterasyonlar sırasında sık sık dalgalanma göstermektedir. Bu durumun üstesinden gelmek için, NeuroIntelligence programı, ağ eğitilirken iterasyonlar sırasında elde edilen en

düşük doğrulama hatasına sahip ağı (en iyi ağı) kopyasını saklar ve bu kopya, ağı eğitimi tamamlandıktan sonra geri yüklenir.


✓ **Erken durdurma;** bu seçenek, doğrulama hatası sürekli artmaya başladığı zaman ağı eğitimi durdurur. Bu seçenek aynı zamanda ağı eğitimi aşamasında, zamandan tasarruf edilmesi açısından da önemlidir. NeuroIntelligence programı erken durdurma seçeneği için 1 ile 10 arasında seviyeler sunar. Düşük seviyeler daha hassas olabildiği gibi bazı durumlarda aşırı öğrenmenin önüne geçemeyebilir, yüksek seviyelerin seçilmesi ise ağı eğitiminin gereğinden erken durdurmasına neden olabilir. Bu durumlar göz önünde bulundurularak, aşırı öğrenmenin önüne geçilmesi adına programda önerilen ve ortalama değer olan 5 seviyesi tercih edilmiştir.

✓ **Girdilere titreşim (jitter) ekleme;** eğitim sırasında girdi değerlerine rastgele titreşim eklenerek, aşırı eğitimin önlenmesidir. Çok az titreşim eklenmesi önemsiz bir etkiye sahip olurken, büyük bir titreşim ağı performansını bozabilir. Aşırı öğrenmenin kontrol edilmesi için titreşim boyutu programda önerildiği gibi % 10 olarak seçilmiştir.

Şekil 6.4'de oluşturulan ANN modellerinin doğrulama ve eğitim veri setleri arasındaki ilişki ve geri yüklemede kullanılacak en iyi ağı yakalandığı anı gösteren grafikler yer almaktadır.




(a)




(b)

Şekil 6.4. ANN modellerinin eğitim performans grafikleri; (a):BBP1, (b):BBP2, (c):QP1, (d):QP2, (e):CGD1, (f):CGD2, (g):LM1 ve (h):LM2.




(c)




(d)

Şekil 6.4. (Devam ediyor).




(e)




(f)

Şekil 6.4. (Devam ediyor).



(g)



(h)

Şekil 6.4. (Devam ediyor).

## 6.2. Heyelan Duyarlılık Haritalarının Oluşturulması

ANN yönteminde farklı eğitim algoritmalarının performanslarının değerlendirilmesini amaçlayan bu tez çalışmasında, gizli tabaka sayısı, gizli tabakadaki nöron sayısı, aktivasyon fonksiyonu, iterasyon sayısı ve MSE gibi ANN tasarım parametreleri, her eğitim algoritması için sabit tutularak toplamda 8 adet ANN modeli oluşturulmuştur. Bu modeller gizli tabaka sayısı ve eğitim algoritmasına göre; tek gizli tabakalı ANN modeli için; BBP1, QP1, CGD1, LM1 olarak ve iki gizli tabakalı ANN modeli için; BBP2, QP2, CGD2 ve LM2 olarak adlandırılmıştır.

Bu modellerin eğitim aşamasında kullanılması için, heyelanlı bölgelerin taç noktalarından seçilen 196 adet heyelanlı nokta veri ve heyelan olmayan bölgeleri temsil eden 196 adet nokta verisi seçilmiştir. Toplamda 392 adet nokta verinin, heyelan oluşumunda etkin olabileceği ortaya konan ve ayrıntısı Bölüm 5.2’de verilerek seçilmiş olan, topoğrafik yükseklik, yamaç eğimi, bakı, TWI, litoloji ve NDVI değerleri belirlenerek Alyuda NeuroIntelligence 2.3. programına ham veri olarak sunulmuştur. Programda, söz konusu 6 adet değişkene ait değerlerin normalleştirilmesi işleminden sonra, her model için veri setleri; % 68’i eğitim, % 16’sı test ve % 16’sı doğrulama veri seti olacak şekilde program tarafından gelişmiş güzel ayrılır ve tasarım özellikleri belirlenmiş olan modellerin eğitim aşamasına geçilir. Oluşturulan 8 adet model için aynı işlemler tekrar uygulanarak tüm ANN modelleri eğitilmiştir. Her bir modelin eğitimi tamamlandıktan sonra heyelan duyarlılık haritalarının oluşturulabilmesi için, Alyuda NeuroIntelligence 2.3. programının “Sorgulama” (Query) aracı kullanılarak, her bir değişkenin 320.000 adet piksel değerleri, ANN modellerine girdi verisi olarak sunulmuştur. Bu girdi değerlerine karşı, elde edilen 320.000 adet çıktı değeri, IBM SPSS Statistics (Version 20) programında ascii verisi olarak düzenlenmiş ve ArcGIS 10 programı kullanılarak harita haline getirilmiştir. Tüm bu işlemler tekrarlanarak, iki farklı ağ yapısında söz konusu eğitim algoritmaları kullanılarak, toplam 8 farklı ağ modelinden itibaren heyelan duyarlılık haritaları elde edilmiştir.

Duyarlılık sınıflarının belirlenmesi, oluşturulan heyelan duyarlılık haritasının doğruluğunu ve güvenilirliğini etkileyen önemli bir faktördür. Bu nedenle, üretilen haritalar en küçük ve en büyük değer arasında eşit aralıklarda, standart sapma


yöntemi temel alınarak, “çok düşük”, “düşük”, “orta”, “yüksek” ve “çok yüksek” heyelan duyarlılığı olmak üzere beş farklı heyelan duyarlılık grubunda (0-1 aralığında değişen duyarlılık değeri 0.2’lik artışlar yapılarak ve 5’e bölünerek) sınıflandırılmıştır. Bu haritalara aşağıda ayrı başlıklar altında yer verilmiştir.

#### **6.2.1. BBP1 Modeli**


Çok tabakalı yapay sinir ağlarının eğitilmesinde en çok kullanılan algoritma olarak bilinen geri yayılım algoritmasıyla eğitilen ve tek gizli tabakaya sahip BBP1 modeli kullanılarak oluşturulan heyelan duyarlılık haritasına göre çalışma alanının; yaklaşık, % 17’si çok düşük, % 18’i düşük, % 22’si orta, % 21’i yüksek ve % 22’si çok yüksek heyelan duyarlılığı sınıfında yer almaktadır. Üretilen heyelan duyarlılık haritası, mevcut heyelan envanter haritası ile karşılaştırıldığında, mevcut heyelanların yaklaşık % 5’nin çok düşük, % 14’ünün düşük, % 25’nin orta, % 26’sinin yüksek ve % 30’nun çok yüksek heyelan duyarlılık sınıfında yer aldığı belirlenmiştir (Şekil 6.5).

BBP1 modelinde, heyelan oluşumunda en etkin olan parametre yamaç eğimi olup bunu sırasıyla; TWI, litoloji, topoğrafik yükseklik, bakı ve NDVI parametreleri takip etmektedir (Şekil 6.6).


BBP1 modelinden üretilen ve 5 farklı duyarlılık sınıfından oluşan sonuç duyarlılık haritası Şekil 6.7’de sunulmuştur.



Şekil 6.5. BBP1 modeline göre duyarlılık dağılımları.




Şekil 6.6. BBP1 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.



Şekil 6.7. BBP1 Modelinden elde edilen heyelan duyarlılık haritası.


### 6.2.2. BBP2 Modeli

İki gizli tabakaya sahip BBP2 modeli kullanılarak oluşturulan heyelan duyarlılık haritasına göre inceleme alanının; yaklaşık, % 17'si çok düşük, % 12'si düşük, % 27'si orta, % 25'i yüksek ve % 20'si çok yüksek heyelan duyarlılığı sınıfında yer almaktadır. Mevcut heyelanların bu haritadaki dağılımlarına bakıldığında ise; % 6'sının çok düşük, % 8'nin düşük, % 30'nun orta, yine % 30'nun yüksek ve % 26'sının çok yüksek heyelan duyarlılığı sınıfında yer aldığı belirlenmiştir (Şekil 6.8).




Şekil 6.8. BBP2 modeline göre duyarlılık dağılımları.

BBP2 modelinde, heyelan oluşumunda en etkin olan parametre yamaç eğimi olup bunu sırasıyla; litoloji, topoğrafik yükseklik, TWI, bakı ve NDVI parametreleri takip etmektedir (Şekil 6.9).



Şekil 6.9. BBP2 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.


BBP2 modelinden üretilen ve 5 farklı duyarlılık sınıfından oluşan sonuç duyarlılık haritası Şekil 6.10'de sunulmuştur.



Şekil 6.10. BBP2 Modelinden elde edilen heyelan duyarlılık haritası.


### 6.2.3. QP1 Modeli

Problem çözme yeteneğinin, geri yayılım algoritmasından daha hızlı olduğu bilenen hızlı yayılım algoritmasıyla eğitilen ve tek gizli tabakaya sahip, QP1 modeliyle elde edilen heyelan duyarlılık haritasına göre inceleme alanının; yaklaşık, % 19'u çok düşük, % 13'ü düşük, % 22'si orta, % 25'i yüksek ve % 20'si çok yüksek heyelan duyarlılığı sınıfında yer almaktadır. QP1 modeli ile üretilen heyelan duyarlılık haritası, mevcut heyelan envanter haritası ile karşılaştırıldığında, mevcut heyelanların bu haritadaki dağılımları; % 6'si çok düşük, % 10'unu düşük, % 26'sı orta, % 31'i yüksek ve % 26'sının çok yüksek heyelan duyarlılık sınıfında olarak belirlenmiştir (Şekil 6.11).




Şekil 6.11. QP1 modeline göre duyarlılık dağılımları.

QP1 modelinde, heyelan oluşumunda en etkin olan parametre yamaç eğimi olup bunu sırasıyla; litoloji, TWI, topoğrafik yükseklik, bakı ve NDVI parametreleri takip etmektedir (Şekil 6.12).



Şekil 6.12. QP1 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.


QP1 modelinden üretilen ve 5 farklı duyarlılık sınıfından oluşan sonuç duyarlılık haritası Şekil 6.13'de yer almaktadır.



Şekil 6.13. QP1 Modelinden elde edilen heyelan duyarlılık haritası.


#### 6.2.4. QP2 Modeli

İki adet gizli tabakaya sahip ve hızlı yayılım algoritmasıyla eğitilen QP2 modeli kullanılarak üretilen heyelan duyarlılık haritasına göre inceleme alanının; yaklaşık, % 13'u çok düşük, % 17'si düşük, % 23'ü orta, % 23'ü yüksek ve yine % 23'ü çok yüksek heyelan duyarlılığı sınıfında yer almaktadır. Mevcut heyelanların bu haritadaki dağılımları; % 4'ü çok düşük, % 11'i düşük, % 24'ü orta, % 28'i yüksek ve % 33'ü çok yüksek heyelan duyarlılığında yer almaktadır (Şekil 6.14).




Şekil 6.14. QP2 modeline göre duyarlılık dağılımları.

QP2 modelinde, heyelan oluşumunda en etkin olan parametre yamaç eğimi olup bunu sırasıyla; litoloji, TWI, topoğrafik yükseklik, NDVI ve bakı parametreleri takip etmektedir (Şekil 6.15).



Şekil 6.15. QP2 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.


QP2 modelinden üretilen ve 5 farklı duyarlılık sınıfından oluşan sonuç duyarlılık haritası Şekil 6.16'da yer almaktadır.



Şekil 6.16. QP2 Modelinden elde edilen heyelan duyarlılık haritası.


### 6.2.5. CGD1 Modeli

Büyük ölçekli ANN'ların eğitiminde hızlı ve güvenilir sonuçlar verdiği bilinen eşlenik eğim algoritması kullanılarak eğitilen ve tek gizli tabakaya sahip CGD1 modeli kullanılarak elde edilen heyelan duyarlılık haritasına göre inceleme alanının; yaklaşık, % 15'i çok düşük, % 16'sı düşük, % 22'si orta, % 40'ı yüksek ve % 7'si çok yüksek heyelan duyarlılığı sınıfında yer almaktadır. Mevcut heyelanların bu haritadaki dağılımları; % 4'ü çok düşük, % 12'si düşük, % 24'ü orta, % 49'u yüksek ve % 11'i çok yüksek heyelan duyarlılığında yer almaktadır (Şekil 6.17).




Şekil 6.17. CGD1 modeline göre duyarlılık dağılımları.

Şekil 6.18'e göre, CGD1 modelinde, heyelan oluşumunda en etkin olan parametre yamaç eğimi olup bunu sırasıyla; litoloji, TWI, bakı, topoğrafik yükseklik ve NDVI parametreleri takip etmektedir.



Şekil 6.18. CGD1 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.


CGD1 modelinden üretilen ve 5 farklı duyarlılık sınıfından oluşan sonuç duyarlılık haritası Şekil 6.19'da yer almaktadır.



Şekil 6.19. CGD1 Modelinden elde edilen heyelan duyarlılık haritası.


#### 6.2.6. CGD2 Modeli

Eşlenik eğim algoritması kullanılarak eğitilen ve iki gizli tabakaya sahip CGD2 modeli kullanılarak oluşturulan heyelan duyarlılık haritasına göre inceleme alanının; yaklaşık, % 19'u çok düşük, % 13'ü düşük, % 22'si orta, % 25'i yüksek ve % 21'i çok yüksek yüksek heyelan duyarlılığı sınıfında yer almaktadır. CGD2 modeli ile üretilen heyelan duyarlılık haritası, mevcut heyelan envanter haritası ile karşılaştırıldığında, mevcut heyelanların bu haritadaki dağılımlarının; % 5'i çok düşük, % 10'u düşük, % 25'i orta, % 36'sı yüksek ve % 24'ü çok yüksek heyelan duyarlılık sınıfında yer aldığı şeklinde belirlenmiştir (Şekil 6.20).




Şekil 6.20. CGD2 modeline göre duyarlılık dağılımları.

CGD1 modelinde, heyelan oluşumunda en etkin olan parametre yamaç eğimi olup bunu sırasıyla; litoloji, topoğrafik yükseklik, bakı, NDVI ve TWI parametreleri takip etmektedir (Şekil 6.21).



Şekil 6.21. CGD2 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.


CGD2 modelinden üretilen ve 5 farklı duyarlılık sınıfından oluşan sonuç duyarlılık haritası Şekil 6.22’de yer almaktadır.



Şekil 6.22. CGD2 Modelinden elde edilen heyelan duyarlılık haritası.


### 6.2.7. LM1 Modeli

Literatürde, eğitim süresi açısından iyi ve hızlı bir performans sağladığı bilinen, buna karşın bellek problemi sebebiyle küçük ve orta ölçekteki ağlar için önerilen Levenberg–Marquardt algoritması ile eğitilen ve tek gizli tabakaya sahip LM1 modeliyle elde edilen heyelan duyarlılık haritasına göre inceleme alanının; yaklaşık, % 18'i çok düşük, % 15'i düşük, % 22'si orta, % 25'i yüksek ve % 21'i çok yüksek heyelan duyarlılığı sınıfında yer almaktadır. Mevcut heyelanların bu haritadaki dağılımları; % 6'si çok düşük, % 12'si düşük, % 22'si orta, % 32'si yüksek ve % 28'i çok yüksek heyelan duyarlılığında yer almaktadır (Şekil 6.23).




Şekil 6.23. LM1 modeline göre duyarlılık dağılımları.

LM1 modelinde, heyelan oluşumunda en etkin olan parametre yamaç eğimi olup bunu sırasıyla; TWI, topoğrafik yükseklik, litoloji, bakı ve NDVI parametreleri takip etmektedir (Şekil 6.24).



Şekil 6.24. LM1 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.


LM1 modelinden üretilen ve 5 farklı duyarlılık sınıfından oluşan sonuç duyarlılık haritası Şekil 6.25’de sunulmuştur.



Şekil 6.25. LM1 modelinden elde edilen heyelan duyarlılık haritası.


#### 6.2.8. LM2 Modeli

Levenberg–Marquardt algoritması ile eğitilen ve iki gizli tabakaya sahip LM2 modeliyle elde edilen heyelan duyarlılık haritasına göre ise inceleme alanının; yaklaşık, % 16'sı çok düşük, % 9'u düşük, % 25'i orta, % 28'i yüksek ve % 22'si çok yüksek heyelan duyarlılığı sınıfında yer almaktadır. Mevcut heyelanların, üretilen bu haritadaki dağılımları ise; % 4'ü çok düşük, % 7'si düşük, % 26'si orta, % 34'ü yüksek ve % 29'unun çok yüksek heyelan duyarlılık sınıfında yer aldığı şeklinde belirlenmiştir (Şekil 6.26).




Şekil 6.26. LM2 modeline göre duyarlılık dağılımları.

LM2 modelinde, heyelan oluşumunda en etkin olan parametre yamaç eğimi olup bunu sırasıyla; litoloji, bakı, TWI, topoğrafik yükseklik ve NDVI parametreleri takip etmektedir (Şekil 6.27).



Şekil 6.27. LM2 modeline göre parametrelerin heyelan oluşumunda önem dereceleri.

LM2 modelinden üretilen ve 5 farklı duyarlılık sınıfından oluşan sonuç duyarlılık haritası Şekil 6.28’de sunulmuştur.



Şekil 6.28. LM2 modelinden elde edilen heyelan duyarlılık haritası.

### 6.3. Heyelan Duyarlılık Haritalarının Performans Değerlendirmesi





Farklı eğitim algoritmalarının ANN modelleri üzerindeki performanslarının değerlendirilmesini amaçlayan bu tez çalışması kapsamında, oluşturulan 8 adet ANN modelinin doğrulanmasında ROC yöntemi uygulanmıştır. ROC yöntemi, AUC (Eğri Altında Kalan Alan) olarak adlandırılan değerin hesaplanması temeline dayanmaktadır. TP (Doğru Pozitif) ve FP (Yanlış Pozitif) olarak sınıflandırılan alanlardaki oransal karşılaştırmalar sonucunda elde edilen eğrinin altında kalan alan AUC değeri olarak ifade edilir. ROC eğrisinde, (0,0) ile (1,1) noktalarını birleştiren köşegen çizgi referans çizgisi olarak kabul edilir. Eğri altında kalan alanın (AUC) olası değerleri, 0.5'ten 1'e kadar değişim gösterir. Bu değerinin 1 olması görüntü çiftleri arasındaki ilişkinin %100 olduğunu ifade eder. ROC eğrisi altında kalan alan (AUC) değerinin referans çizgisine, yani 0.5'e yakın bir değer olması ise söz konusu modelin doğruluğunun az olduğunu işaret etmektedir.

Eğri altında kalan alanın (AUC) hesaplanmasında Eş. 6.4 kullanılır;





$$\text{Alan} = \sum_{i=1}^n [x_{i+1} - x_i] \times \left[ y_i + \frac{(y_{i+1} - y_i)}{2} \right] \quad (6.4)$$

Burada  $x_i$ ,  $i$  eşik değeri için, heyelansız alanlarda heyelan varlığı gösteren piksellerin, FP değerlerinin oranı;  $y_i$  değeri,  $i$  eşik değeri için heyelanlı alanlarda heyelan varlığı gösteren piksellerin, TP değerlerinin oranı,  $n$  ise, eşik değerlerinin sayısını ifade etmektedir.

Farklı eğitim algoritmalarının kullandığı 8 adet ANN modelinden üretilmiş olan haritaların performanslarının denetlenebilmesi için, çalışma alanındaki mevcut heyelanlara karşılık üretilen heyelan duyarlılık haritalarının, 320.000 adet piksel değerleri karşılaştırılarak, IBM SPSS Statistics (Version 20) programında ROC analizleri yapılmış ve her modelin ROC eğrileri çizilmiştir. Her bir ANN model için çizilen ROC eğrilerinin 0.5 referans çizgisine uzak olduğu görülmektedir (Şekil 6.29; 6.30).



Şekil 6.29. BBP1; BBP2; QP1 ve QP2 modellerine ait ROC eğrileri.



Şekil 6.30. CGD1; CGD2; LM1 ve LM2 modellerine ait ROC eğrileri.

ANN modellerinin performanslarını değerlendirmek amacıyla ikinci olarak, çalışma alanındaki mevcut heyelanlarla üretilen heyelan duyarlılık haritaları arasındaki ilişkiyi ifade eden katsayı ( $r_{ij}$ ) değerleri hesaplanmıştır.  $r_{ij}$  değeri, iki grup veri arasındaki ilişkiyi ifade eden bir katsayıdır. Değişim aralığı 0 ile 1 arasında olup, 0'a yakın değerler incelenen iki grup arasındaki ilişkinin zayıf, 1'e yakın olan değerler de iki grup arasındaki ilişkinin kuvvetli olduğunu göstermektedir.


İki veri arasındaki ilişki katsayısı ( $r_{ij}$ ),  $m=2$  boyutlu bir uzayda ikili üyelik ( $x_i$  ve  $x_j$ ) derecelerinin kosinüs genliği fonksiyonunda değerlendirilmesi ile bulunur. Bu durumda ilişki,  $\mu_R(x_i, x_j)$  şeklinde ifade edilir ve  $r_{ij}$ 'nin alabileceği değerler ( $0 \leq r_{ij} \leq 1$ ) Eş. 6.5'de yer alan formüle göre hesaplanır.

$$r_{ij} = \left[ \sum_{k=1}^m x_{ik} \times x_{jk} \right] / \sqrt{\sum_{k=1}^m x_{ik}^2 \times \sum_{k=1}^m x_{jk}^2} \quad (6.5)$$

ANN modellerinden üretilen duyarlılık haritaları ile mevcut heyelanlar arasındaki  $r_{ij}$  değeri, Ercanoğlu [72] 'de yer alan, Q-Basic programlama dili kullanılarak geliştirilen FULLSA programının “ $r_{ij}$ ” modülü yardımıyla hesaplanmıştır (Şekil 6.31). Çizelge 6.2'de ANN modelleriyle oluşturulan heyelan duyarlılık haritalarının  $r_{ij}$  değerlerinin 1'e oldukça yakın olduğu görülmektedir. Bu anlamda tüm ANN modellerinin mevcut heyelanlı alanları yansıtmadaki başarısının yüksek olduğu ortaya çıkmaktadır.

Çizelge 6.3. ANN modellerine ilişkin  $r_{ij}$  değerleri.

| YSA Modeli | $r_{ij}$ |
|------------|----------|
| BBP1       | 0.967    |
| BBP2       | 0.937    |
| QP1        | 0.967    |
| QP2        | 0.965    |
| CGD1       | 0.972    |
| CGD2       | 0.969    |
| LM1        | 0.966    |
| LM2        | 0.954    |



Şekil 6.31. "Rij" modülünün akış şeması (Ercanoğlu [72]'dan değiştirilerek alınmıştır.)

## 7. SONUÇLAR VE TARTIŞMA

Heyelanların sıkça geliştiği Batı Karadeniz bölgesinde seçilen bir alanın, heyelan envanter ve ANN yöntemiyle duyarlılık haritalarının oluşturulması ile farklı eğitim algoritmalarının ANN modelleri üzerindeki etkilerinin araştırılmasını amaçlayan bu tez çalışması kapsamında elde edilen genel sonuçlar ve bunlara bağlı olarak gerçekleştirilen tartışmalar aşağıda verilmiştir.

Batı Karadeniz bölgesinde, Karabük iline bağlı Ovacık ilçesi içinde kalan 200 km<sup>2</sup>'lik çalışma alanında meydana gelmiş toplam 196 adet heyelan, arazi çalışmalarından, Google Earth uydu görüntülerinden, CBS ortamında Sayısal yükseklik modelinden (SYM) üretilen kabartma (hillshade) haritasından ve hava fotoğraflarından yararlanılarak haritalanarak sahaya ait güncel heyelan envanteri çıkarılmıştır. Söz konusu heyelanlar, alansal olarak 200 km<sup>2</sup>'lik çalışma alanının, % 9.95'ini kapsamaktadır. Çalışma alanı içerisindeki bu yenilmeler, Varnes [42] sınıflamasına göre kütleli dairesel toprak kaymaları olarak sınıflandırılmıştır.

Çalışmanın konusu ile ilgili olarak, yaklaşık son 15 yılı kapsayan, ayrıntılı bir literatür araştırması yapılmıştır ve ANN yönteminin yüksek performans sergileyen haritalar ürettiği belirlenmiştir. Bu çalışmalarda kullanılan parametreler ve kullanılan ANN yönteminin özellikleri değerlendirilmiştir. Bu değerlendirmeler sonucunda, heyelan duyarlılık haritalarının üretilmesinde, yamaç eğimi, bakı, litoloji ve bitki örtüsü indeksi parametrelerinin sıkça tercih edilen parametreler olduğu ortaya çıkmıştır. Buna karşın, bu tür değerlendirmelerde kullanılan parametreler üzerinde araştırmacılar arasında bir görüş birliği olmadığı görülmüştür. Bu durumun temel nedeni, heyelan oluşumunda etkin olabilecek parametrelerin önem derecelerinin çalışma alanının koşullarına göre değişiklik göstermesi şeklinde yorumlanabilir. Tez çalışmasında, jeolojik, topoğrafik ve çevresel faktörler gruplarında yer alan, tüm çalışmalar içinde kullanımında en çok öne çıkan ve eldeki mevcut veriler dikkate alınarak; topoğrafik yükseklik, yamaç eğimi, bakı, nemlilik indeksi, litoloji ve bitki örtüsü indeksi duyarlılık analizlerinde kullanılmıştır. Çalışma alanında haritalanan heyelanların hazırlayıcı parametreleri incelendiğinde, heyelanların saha içerisinde genel olarak; Ulus formasyonu içerisinde, yaklaşık 900 ila 1000 m yükseklikte, 15° ile 20° yamaç eğiminde, yaklaşık doğuya bakan yamaçlarda, nemlilik indeksi değerinin 4 ile 8 arasında

değiştirdiği arazi birimlerinde ve bitki örtüsü indeksi değerinin 0 ile 0.3 arasında kaldığı alanlarda geliştiği belirlenmiştir.

Yapay sinir ağı yöntemi ile heyelan duyarlılık haritalarının oluşturulması ve farklı eğitim algoritmaları kullanılarak eğitilen ANN modellerinin, sonuç haritaları üzerindeki etkilerinin karşılaştırılması amacıyla, öncelikle uygun yapay sinir ağını karakterize etmek için bir dizi eğitim işlemi yapılarak, tek ve iki gizli tabakalı olmak üzere iki farklı ağın topolojik yapısı tasarlanmıştır. ANN tasarımı, bir adet gizli tabaka kullanılması durumunda test veri seti hata oranı en düşük olan ağı topolojisi 6-13-1 olarak, iki adet gizli tabaka kullanılması durumunda ise test veri seti hata oranı en düşük olan ağı topolojisi 6-11-6-1 olarak saptanmıştır. Bu ağların eğitiminde BBP (geri yayılım), QP (hızlı yayılım), CGD (eşlenik eğitim) ve LM (Levenberg-Marquart) olmak üzere dört farklı eğitim algoritması kullanılarak toplamda 8 adet ANN modeli oluşturulmuştur. Bu modeller gizli tabaka sayısı ve eğitim algoritmasına göre; tek gizli tabakalı ANN modeli için; BBP1, QP1, CGD1, LM1 olarak ve iki gizli tabakalı ANN modeli için; BBP2, QP2, CGD2 ve LM2 olarak adlandırılmıştır. Ayrıca, ANN tasarımı, öğrenme ve momentum katsayısı, aktivasyon fonksiyonu, iterasyon sayısı, MSE değeri gibi ağın performansını doğrudan etkileyen parametreler tüm modeller için sabit tutularak, eğitim algoritmalarının ağı performansı üzerindeki net etkileri belirlenmeye çalışılmıştır. Ayrıca ağı aşırı eğitilmesi durumunda performansta düşme yaşandığından, “en iyi ağı muhafaza edilmesi ve geri yüklenmesi”, “erken durdurma” ve “girdilere titreşim (jitter) ekleme” araçları kullanılarak ağı eğitim setini ezberlemesinin önüne geçilmeye çalışılmıştır.

ANN modellerinde kullanılan eğitim algoritmalarının performanslarını karşılaştırmak amacı ile analiz sonuçları Çizelge 7.1’de özetlenmiştir. Tekrarlama sayıları ve MSE değerleri aynı olmakla birlikte gizli tabaka sayılarına göre farklı ağı yapısında kullanılan eğitim algoritmalarında, eğitim sürecinin durma nedeni farklılık göstermiştir. Çizelge 7.1’e bakıldığında, Levenberg-Marquart algoritmasıyla eğitilen LM1 ve LM2 ve CGD algoritmasıyla eğitilen CGD2 modellerinin, amaçlanan MSE değerine daha önce ulaştığında, eğitim aşamasında maksimum iterasyona ulaşılmadan sonlandığı görülmektedir. Buradan, eğitim süresi bakımından en iyi performans gösteren eğitim algoritmasının Levenberg-

Marquardt algoritması olduğu söylenebilir. Eğitim süresi bakımından en yavaş algoritmanın ise CGD1 algoritması olduğu sonucuna varılmıştır. Ayrıca, 2 gizli tabakalı ağ topolojisine sahip CGD2 dışında kalan modellerin, eğitim hızlarındaki düşüşe bağlı olarak eğitim sürelerinin arttığı gözlenmiştir. Bunun sebebi, CGD2 modelinin istenilen MSE değerine kısa sürede ulaşmasıdır.


Çizelge 7.1. ANN modellerinin analiz sonuçları.

| Ağ topolojisi         | 6-13-1    |           |           |       | 6-11-6-1  |           |       |       |
|-----------------------|-----------|-----------|-----------|-------|-----------|-----------|-------|-------|
| Eğitim Algoritması    | BBP       | QP        | CGD       | LM    | BBP       | QP        | CGD   | LM    |
| İterasyon             | 30001     | 30001     | 30001     | 19    | 30001     | 30001     | 17502 | 17    |
| Eğitim Hızı (iter/sn) | 392.68    | 383.64    | 55.35     | 31.66 | 290.7     | 264.09    | 66.04 | 11.33 |
| Eğitim Süresi (sn)    | 76        | 78        | 542       | 0.6   | 103       | 114       | 265   | 1.5   |
| Eğitimin Durması      | iterasyon | iterasyon | iterasyon | MSE   | iterasyon | iterasyon | MSE   | MSE   |

Söz konusu haritaların oluşturulmasında kullanılan girdi parametrelerinin her bir ANN modeli için önem derecelerinin farklılık gösterdiği, bununla birlikte heyelan oluşumunda en etkin olan parametrenin yamaç eğimi olduğu ve bunu sırasıyla; litoloji, topoğrafik yükseklik ve TWI parametrelerinin takip ettiği belirlenmiştir. Buna karşın bakı ve NDVI parametreleri hemen tüm modellerde en az etkiyi gösteren parametrelerdir (Şekil 7.1). Girdi parametrelerinin her ANN modelinde farklı önem derecesi göstermesi, (örneğin, TWI parametresinin BBP1 ve LM1 modellerinde yüksek önem derecesine sahipken, QP2 ve LM2 modellerinde düşük önem derecesine sahip olması) farklı ağ yapısı ve eğitim algoritması kullanılarak oluşturulan ANN modellerinin, veri gruplarındaki ayrıntıları değerlendirebilme yeteneğindeki farklılardan kaynaklandığı düşünülmektedir.

ANN analizlerinde, kategorik veri olarak kullanılan litoloji parametresinin ve sürekli veri olarak kullanılan diğer girdi parametrelerinin, ANN modellerine göre değer dağılımlarındaki etkinliği gösteren sonuç grafikleri (Bkz. Ek-1, 2, 3, 4, 5, 6, 7 ve 8 ) incelendiğinde, “0” (heyelan olmayan alan) ve “1” (heyelanlı alan) arasında değişen değer dağılımlarında tüm modeller için yine en etkin parametrenin yamaç eğimi olduğu ve bunu etkinlik sırasına göre TWI, litoloji ve topoğrafik yükseklik parametrelerinin izlediği gözlenmiştir. Bakı ve NDVI parametrelerinin ise, hemen


hemen tüm değerlerinin, heyelan olmayan ve heyelanlı alanlar için homojen bir dağılım göstermesi, bu çalışmada bakı ve NDVI parametrelerinin heyelan duyarlılık değerlendirmesinde göreceli olarak daha az etkiye sahip oldukları şeklinde yorumlanabilir.



Şekil 7.1. Girdi parametrelerinin önem dereceleri.

Söz konusu ANN modellerinden, toplam 8 farklı heyelan duyarlılık haritaları elde edilmiştir. Elde edilen haritalar “çok düşük”, “düşük”, “orta”, “yüksek” ve “çok yüksek” heyelan duyarlılığı olmak üzere beş farklı heyelan duyarlılık grubunda sınıflandırılmıştır. Bu sınıflandırmaya göre, BBP1 modeli kullanılarak oluşturulan heyelan duyarlılık haritasına göre inceleme alanının; yaklaşık, % 17’si çok düşük, % 18’i düşük, % 22’si orta, % 21’i yüksek ve % 22’si çok yüksek; BBP2 modeli kullanılarak oluşturulan heyelan duyarlılık haritasına göre; yaklaşık, % 17’si çok düşük, % 12’si düşük, % 27’si orta, % 25’i yüksek ve % 20’si çok yüksek; QP1 modeliyle elde edilen heyelan duyarlılık haritasına göre; yaklaşık, % 19’u çok düşük, % 13’ü düşük, % 22’si orta, % 25’i yüksek ve % 20’si çok yüksek; QP2 modeli kullanılarak elde edilen heyelan duyarlılık haritasına göre; yaklaşık, % 13’u

çok düşük, % 17'si düşük, % 23'ü orta, % 23'ü yüksek ve yine % 23'ü çok yüksek; CGD1 modeli kullanılarak elde edilen heyelan duyarlılık haritasına göre; yaklaşık, % 15'i çok düşük, % 16'sı düşük, % 22'si orta, % 40'ı yüksek ve % 7'si çok yüksek; CGD2 modeli kullanılarak oluşturulan heyelan duyarlılık haritasına göre; yaklaşık, % 19'u çok düşük, % 13'ü düşük, % 22'si orta, % 25'i yüksek ve % 21'i çok yüksek; LM1 modeliyle elde edilen heyelan duyarlılık haritasına göre; yaklaşık, % 18'i çok düşük, % 15'i düşük, % 22'si orta, % 25'i yüksek ve % 21'i çok yüksek ve LM2 modeliyle elde edilen heyelan duyarlılık haritasına göre ise inceleme alanının; yaklaşık, % 16'sı çok düşük, % 9'u düşük, % 25'i orta, % 28'i yüksek ve % 22'si çok yüksek heyelan duyarlılığı sınıfında yer aldığı sonucuna varılmıştır. ANN modellerinden elde edilen haritaların, duyarlılık sınıflarına göre yüzdelerinin karşılaştırmalı olarak yer aldığı grafik Şekil 7.2'de verilmiştir.




Şekil 7.2. ANN modellerinden üretilen haritaların duyarlılık dağılımları.

Üretilen heyelan duyarlılık haritalarının performanslarının değerlendirilmesi amacıyla mevcut heyelan envanteri, söz konusu haritalarla karşılaştırılmıştır. Buna göre, BBP1 modelinden üretilen haritada mevcut heyelanların yaklaşık % 5'nin çok düşük, % 14'ünün düşük, % 25'nin orta, % 26'sinin yüksek ve % 30'nun çok

yüksek; BBP2 modelinden üretilen haritada, % 6'sının çok düşük, % 8'nin düşük, % 30'nun orta, yine % 30'nun yüksek ve % 26'sının çok yüksek; QP1 modelinden üretilen haritada,; % 6'sinin çok düşük, % 10'nunun düşük, % 26'sının orta, % 31'inin yüksek ve % 26'sının çok yüksek; QP2 modelinden üretilen haritada, % 4'ünün çok düşük, % 11'inin düşük, % 24'ünün orta, % 28'inin yüksek ve % 33'ünün çok yüksek; CGD1 modelinden üretilen haritada, 4'ünün çok düşük, % 12'sinin düşük, % 24'ünün orta, % 49'unun yüksek ve % 11'inin çok yüksek; CGD2 modelinden üretilen haritada, % 5'inin çok düşük, % 10'unun düşük, % 25'inin orta, % 36'sının yüksek ve % 24'ünün çok yüksek; LM1 modelinden üretilen haritada, % 6'sinin çok düşük, % 12'sinin düşük, % 22'sinin orta, % 32'sinin yüksek ve % 28'inin çok yüksek ve LM2 modelinden üretilen haritada ise; % 4'nün çok düşük, % 7'sinin düşük, % 26'sinin orta, % 34'ünün yüksek ve % 29'unun çok yüksek heyelan duyarlılığında yer aldığı belirlenmiştir. Mevcut heyelanların, ANN modellerine göre duyarlılık sınıfları içindeki dağılımlarını gösteren grafik Şekil 7.3'te verilmiştir.

ANN kullanılarak oluşturulan heyelan duyarlılık haritaları, mevcut heyelanların dağılımı dikkate alınarak karşılaştırıldığında, “yüksek heyelan duyarlılığı”nı temsil eden alanları en iyi yansıtan haritanın CGD1 modeliyle üretilen ve “çok yüksek heyelan duyarlılığı”nı temsil eden alanları en iyi yansıtan haritanın ise QP2 modeliyle üretilen heyelan duyarlılık haritası olduğu sonucuna varılmıştır. CGD1 ile üretilen heyelan duyarlılık haritasında yüksek duyarlılık ile çok yüksek duyarlılık ayrımı, diğer haritalar kadar net değildir. Bununla birlikte, yüksek duyarlılık sınıfını alansal yayılımı ile çok yüksek sınıfının toplam değeri sonucunda, performans değerinin daha yüksek çıkmasına yol açtığı düşünülmektedir.



Şekil 7.3. Mevcut haritalanmış heyelanların duyarlılık sınıfları içindeki dağılımları.

Tez çalışması kapsamında ANN yöntemi ile üretilen haritaların performanslarının karşılaştırılması için, AUC ve  $r_{ij}$  değerleri hesaplanmıştır. Bu amaç doğrultusunda, IBM SPSS Statistics (Version 20) programında ROC analizleri yapılmış ve her modelin ROC eğrileri çizilerek ROC eğrisi altında kalan alan (AUC) değerleri ve Ercanoğlu [72] 'de geliştirilen FULLSA programının " $r_{ij}$ " modülü kullanılarak da  $r_{ij}$  değerleri hesaplanmıştır (Çizelge 7.2). Elde edilen sonuçlara göre, ANN modellerinin AUC ve  $r_{ij}$  değerlerinin oldukça yakın olduğu sonucuna varılmıştır. Bu sonuç üretilen duyarlılık haritalarının güvenilirliğinin tatmin edici nitelikte olduğunu göstermektedir. Bununla birlikte, söz konusu performans indekslerine bakılarak mevcut heyelanları temsil etmekte en yüksek performansa sahip haritanın, CGD1 modeliyle üretilen heyelan duyarlılık haritası olduğu belirlenmiştir.

Çizelge 7.2. ANN modellerinin AUC ve  $r_{ij}$  değerleri.

| YSA Modeli  | AUC          | $r_{ij}$     |
|-------------|--------------|--------------|
| BBP1        | 0,812        | 0.967        |
| BBP2        | 0,804        | 0.937        |
| QP1         | 0,805        | 0.967        |
| QP2         | 0,813        | 0.965        |
| <b>CGD1</b> | <b>0,817</b> | <b>0.972</b> |
| CGD2        | 0,804        | 0.969        |
| LM1         | 0,810        | 0.966        |
| LM2         | 0,805        | 0.954        |

Tek ve iki gizli tabaka kullanılarak oluşturulan ANN modelleri arasında, AUC değerlerine göre kıyaslama yapılacak olursa, BBP1 modelinin, BBP2'den; QP2'nin QP1'den; CGD1'nin CGD2'den ve LM1'in LM2 modelinden daha iyi olduğu görülmektedir. Aynı şekilde,  $r_{ij}$  değerleri kıyaslanacak olursa, tüm algoritmalar için tek gizli tabakaya sahip modellerin, iki gizli tabakaya sahip ağ modellerinden daha iyi performans gösterdiği sonucuna varılmıştır.

Eğitim algoritmalarının ANN modelleri üzerindeki etkilerinin ve performanslarının değerlendirmesini amaçlayan bu tez çalışmasına göre; eşlenik eğitim algoritması, geri yayılım, hızlı yayılım ve Levenberg-Marquardt algoritmalarından daha yavaş olmasına karşın, tahmin sonuçları bakımından en iyi sonuç üreteni olarak yorumlanmıştır. Levenberg-Marquardt algoritması ise, test edilen algoritmalar arasında en hızlı olanı olup, tahmin performansına bakıldığında, geri yayılım, hızlı yayılım algoritmaları kadar iyi olduğu görülmektedir. Buradan yola çıkarak, küçük ölçekteki ANN ağlarının eğitiminde, zamandan tasarruf etmek adına Levenberg-Marquardt algoritması tercih edilebilir. Geri yayılım ve hızlı yayılım algoritmaları arasında ise, hız ve tahmin performansı açısından belirgin bir farklılık bulunmaktadır.

Genel olarak bakıldığında ise, tüm modellerin performansları arasında belirgin bir farklılık bulunmamaktadır. Bu nedenle, ANN yönteminin, heyelan duyarlılığı değerlendirilmesinde etkin bir şekilde kullanılabilmesinin, en iyi performansa sahip

ağ özelliklerinin belirlendiği çalışma sayısının artması ile mümkün olabileceği düşünülmektedir. Ayrıca, haritaların üretilmesinde dikkate alınan parametrelerin, heyelanlı alanları yeterli derecede karakterize etmesinde saha özelliklerinin etkin olduğu düşünülmektedir.

Bu çalışma, seçilmiş bir alanının heyelan duyarlılığının değerlendirilmesi sırasında eğitim algoritmalarının ANN modelleri üzerindeki etkilerinin karşılaştırılması amacıyla yapılmıştır. Bu nedenle, elde edilen tüm bulguların, bu karşılaştırmalar temelinde değerlendirilmesi gerekliliği unutulmamalıdır. Diğer bir deyişle, mevcut olanaklar dahilinde (yazılım kapasitesi, parametre sayısı vb.) üretilen harita algoritmaların karşılaştırılması için dikkate alınmış olup, daha fazla sayıda parametre uygulamaya sokularak, daha anlamlı ve güvenilir heyelan duyarlılık haritaları elde edilebilir.

## KAYNAKLAR

- [1] Guha-Sapir D., Vos F., Below R., and Ponserre S., *Annual Disaster Statistical Review 2010*, Centre for Research on the Epidemiology of Disasters (CRED), **2011**.
- [2] Peduzzi P., Chatenoux B., and Dao Q., "The global risk analysis for the 2009 global assessment report on disaster risk reduction," 1–6, **2010**.
- [3] Guzzetti F., Carrara A., Cardinali M. and Reichenbach P., Landslide hazard evaluation : a review of current techniques and their application in a multi-scale study , Central Italy, *Geomorphology*, 31, 181–216, **1999**.
- [4] EMDAT, Natural disasters reported 1900–2011, <http://www.emdat.be/natural-disasters-trends>, (Haziran, **2014**).
- [5] Cruden D., and Fell R., *Landslide risk assessment*, Proceedings of the International Workshop on Landslide Risk Assessment, 19-21 February, Balkema, Rotterdam, **1997**.
- [6] Nadim F., Kjekstad O., Peduzzi P., Herold C. and Jaedicke C., Global landslide and avalanche hotspots, *Landslides*, 3, 159–173, Feb. **2006**.
- [7] Van Westen C. J., Castellanos E. and Kuriakose S. L., Spatial data for landslide susceptibility, hazard, and vulnerability assessment: An overview, *Engineering Geology*, 102, 112–131, **2008**.
- [8] Fell R., Corominas J., Bonnard C., Cascini L., Leroi E. and Savage W. Z., Guidelines for landslide susceptibility, hazard and risk zoning for land-use planning, *Engineering Geology*, 102, 99–111, **2008**.
- [9] USGS, <http://landslides.usgs.gov/learning/majorls.php>, (Haziran, **2014**)
- [10] OvacıkKaymakamlığı, [http://www.ovacik.gov.tr/default\\_B1.aspx?content=111](http://www.ovacik.gov.tr/default_B1.aspx?content=111), (Haziran, **2014**).
- [11] Duman T. Y., Çan T., Emre Ö., Keçer M., Doğan A., Ateş Ş., and Durmaz S., Landslide inventory of northwestern Anatolia, Turkey, *Engineering Geology*, 77, 99–114, **2005**.
- [12] Yergök A., Akman Ü., İplikçi E., ve Karabalık N., Batı Karadeniz Bölgesinin Jeolojisi (I), *MTA Raporu*, 8273, 255, **1987**.
- [13] Timur E., Aksay A., "Türkiye Jeoloji Haritaları Zonguldak F29 Paftası." MTA Yayınları, No.3, Ankara, **2002**.
- [14] Duman T.Y., Emre Ö., Akçay A.E., Uysal Ş., Özmutaf M., Bozbay E., Tongal O. ve Sönmez M., Arazi kullanım kapasitesi çalışmalarında yerbilim verilerinin uygulanmasına bir örnek: Aşağı Filyos vadisi (Zonguldak, B.Karadeniz), *Türkiye Jeoloji Bülteni*, 41, 117-129, **1998**.
- [15] İsmailoğlu Ş., Özcan Ü., Küçük İ., Çağlan D., Bayrak D., Aşağı Filyos Vadisi Bartın Karabük Alaplı (Batı Karadeniz) Yörelerindeki Seller ve Heyelanlara İlişkin Rapor," *TMMOB*, Ankara, **1999**.
- [16] Aksoy Y., Karabük ili Yerleşim Alanının Jeolojik İncelenmesi ve Olası Yerleşim Alanlarının Belirlenmesi, Yayınlanmamış Yüksek Mühendislik Tezi, Zonguldak Karaelmas Üniversitesi, Fen Bilimleri Enstitüsü, Zonguldak, **2005**.

- [17] Aleotti P., and Chowdhury R., Landslide hazard assessment: summary review and new perspectives, *Bulletin of Engineering Geology of the Environment*, 58, 21–44, **1999**.
- [18] Lee C., Ye H., Yeung M., Shan X., and Chen G., AIGIS-based methodology for natural terrain landslide susceptibility mapping in Hong Kong, *Episodes*, 24, 150–159, **2001**.
- [19] Lee S., Ryu J., Min, K. and Won J., Landslide susceptibility analysis using GIS and artificial neural network, *Earth Surface Process and Landforms*, 28, 1361–1376, **2003**.
- [20] Lee S., Ryu J., Won J., and Park H., Determination and application of the weights for landslide susceptibility mapping using an artificial neural network, *Engineering Geology*, 71, 289–302, **2004**.
- [21] Ermini L., Catani F., and Casagli N., Artificial neural networks applied to landslide susceptibility assessment, *Geomorphology*, 66, 327–343, **2005**.
- [22] Ercanoglu M., Landslide susceptibility assessment of SE Bartın (West Black Sea region, Turkey) by artificial neural networks, *Natural Hazards Earth System Sciences*, 5, 979–992, **2005**.
- [23] Gomez H. and Kavzoglu T., Assessment of shallow landslide susceptibility using artificial neural networks in Jabonosa River Basin, Venezuela, *Engineering Geology*, 78, 11–27, **2005**.
- [24] Yesilnacar E. and Topal T., Landslide susceptibility mapping: a comparison of logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey), *Engineering Geology*, 79, 251–266, **2005**.
- [25] Kanungo D., Arora M., Sarkar S., and Gupta R., A comparative study of conventional, ANN black box, fuzzy and combined neural and fuzzy weighting procedures for landslide susceptibility zonation in Darjeeling, *Engineering Geology*, 85, 347–366, **2006**.
- [26] Pradhan B. and Lee S., Utilization of Optical Remote Sensing Data and GIS Tools for Regional Landslide Hazard Analysis Using an Artificial Neural Network Model, 14, 6, **2007**.
- [27] Yilmaz I., Landslide susceptibility mapping using frequency ratio, logistic regression, artificial neural networks and their comparison: A case study from Kat landslides (Tokat-Turkey), *Computers & Geosciences*, 35, 1125–1138, **2009**.
- [28] Yilmaz I., Comparison of landslide susceptibility mapping methodologies for Koyulhisar, Turkey: conditional probability, logistic regression, artificial neural networks, and support vector machine, *Environmental Earth Sciences*, 61, 821–836, **2009**.
- [29] Kawabata D. and Bandibas J., Landslide susceptibility mapping using geological data, a DEM from ASTER images and an Artificial Neural Network (ANN), *Geomorphology*, 113, 97–109, **2009**.
- [30] Pradhan B. and Lee S., Delineation of landslide hazard areas on Penang Island, Malaysia, by using frequency ratio, logistic regression, and artificial neural network models, *Environmental Earth Sciences*, 60, 1037–1054, **2010**.







- [31] Bui D.T., Pradhan B., Lofman O., Revhaug I. and Dick O., Landslide susceptibility assessment in the Hoa Binh province of Vietnam: a comparison of the Levenberg–Marquardt and Bayesian regularized neural networks, *Geomorphology*, 171–172, 12–29, **2012**.
- [32] Choi J., Oh H., Lee H., Lee C. and Lee S., Combining landslide susceptibility maps obtained from frequency ratio, logistic regression, and artificial neural network models using ASTER images and GIS, *Engineering Geology*, 124, 12–23, **2012**.
- [33] Lee S. and Min K., Statistical analysis of landslide susceptibility at Yongin, Korea, *Environmental Geology*, 40, 1095–1113, **2001**.
- [34] Yüksel N., Coğrafi Bilgi Sistemleri Tabanlı Heyelan Duyarlılık Haritalarının Oluşturulmasında İstatiksel Yöntemlerin Ve Yapay Sinir Ağlarının Kullanılması: Kumluca-Ulus (Bartın) Bölgesi, Doktora Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, Ankara, **2007**.
- [35] Yilmaz I., The effect of the sampling strategies on the landslide susceptibility mapping by conditional probability and artificial neural networks., *Environmental Earth Sciences*, 60, 505–519, **2009**.
- [36] Pradhan B., Lee S. and Buchroithner M., A GIS-based back-propagation neural network model and its cross-application and validation for landslide susceptibility analyses, *Computers, Environment and Urban Systems*, 34, 216–235, **2010**.
- [37] Choi J., Oh H., Won J. and Lee S., Validation of an artificial neural network model for landslide susceptibility mapping, *Environmental Earth Sciences*, 60, 473–483, **2010**.
- [38] García-Rodríguez M.J. and Malpica J. A., Assessment of earthquake-triggered landslide susceptibility in El Salvador based on an artificial neural network model, *Natural Hazards and Earth System Sciences*, 10, 1307–1315, **2010**.
- [39] Li Y., Chen G., Tang C., Zhou G. and Zheng L., Rainfall and earthquake-induced landslide susceptibility assessment using GIS and Artificial Neural Network., *Natural Hazards and Earth System Sciences*, 12, 2719–2729, **2012**.
- [40] Zare M. and Pourghasemi H., Landslide susceptibility mapping at Vaz Watershed (Iran) using an artificial neural network model: a comparison between multilayer perceptron (MLP) and radial basic., *Arabian Journal of Geosciences*, 6, 2873–2888, **2013**.
- [41] Cruden D.M. and Varnes D.J., Landslide types and processes., *Highway Research Board Special Report*, No: 1982, 36–75, **1996**.
- [42] Varnes D.J., Slope movement types and processes, *Transportation Research Board Special Report No:176*, 12–33, **1978**.
- [43] Hungr O., Leroueil S. and Picarelli L., The Varnes classification of landslide types, an update., *Landslides*, 11, 167–194, **2013**.
- [44] Varnes D.J., Landslide hazard zonation: a review of principles and practice, Unesco Press, Paris, 63, **1984**.

- [45] Safeland, *Living with landslide risk in Europe: Assessment, effects of global change, and risk management strategies*, April, **2011**.
- [46] Konar A., *Computational Intelligence: Principles, Techniques and Applications*, Springer, **2005**.
- [47] McCulloch W.S., and Pitts W., A logical calculus of the ideas immanent in nervous activity," *Bull. Math. Biophys.*, 5, 115–133, **1943**.
- [48] Hebb D., *The organization of behavior: a neuropsychological theory*, Willey, N.Y., **1949**.
- [49] Rosenblatt F., The perceptron: a probabilistic model for information storage and organization in the brain., *Psychological Review*, 62, 386–407, **1958**.
- [50] Widrow B. and Hoff M., Adaptive switching circuits., IRE (Institute of Radio Engineers), WESCON (Western Electronic Show and Convention) Part 4, 96–104, **1960**.
- [51] Kohonen T., Correlation matrix memories, *Comput. IEEE Trans.*, C-21., 353–359, **1972**.
- [52] Hopfield J.J., Neural networks and physical systems with emergent collective computational abilities, *Proc. Natl. Acad. Sci. USA*, 79, 2554–2558, **1982**.
- [53] T. Kohonen, "Analysis of a simple self-organizing process," *Biol. Cybern.*, vol. 44, pp. 135–140, 1982.
- [54] J. Hopfield and D. Tank, "'Neural' computation of decisions in optimization problems," *Biol. Cybern.*, vol. 52, pp. 141–152, 1985.
- [55] Rumelhart D., Hinton G. and Williams R., Learning internal representations by error propagation, *ICS Report 8506*, **1985**.
- [56] Sejnowski T. and Rosenberg C., Parallel networks that learn to pronounce English text, *Complex Syst.*, 145–168, **1987**.
- [57] S. Grossberg, *Neural networks and natural intelligence*, MIT Press, Cambridge, MA, **1988**.
- [58] Carpenter G. and Grossberg S., Fuzzy Artmap: A neural network architecture for incremental supervised learning of analog multidimensional maps," *IEEE Transactions on Neural Networks*, **1991**.
- [59] Peretto P., *An introduction to the modeling of neural networks*, Cambridge University Press, **1992**.
- [60] Lippmann R., An introduction to computing with neural nets, *ASSP Mag. IEEE*, **1987**.
- [61] Alba E. and Chicano J., Training neural networks with GA hybrid algorithms, *Genetic Evolutionary Computation*, 3102,852-863, **2004**.
- [62] Yu H. and Wilamowski B, Levenberg-marquardt training, *The Industrial Electronics Handbook*, 1–16, **2011**.
- [63] Ding L. and Matthews J., A contemporary study into the application of neural network techniques employed to automate CAD/CAM integration for







- die manufacture, *Computers & Industrial Engineering*, 57, 1457–1471, **2009**.
- [64] Shanthi D., Sahoo G., Saravanan N., Comparison of Neural Network Training Algorithms for the prediction of the patient's post-operative recovery area, *Journal of Convergence Information Technology*, 24–32, **2009**.
  - [65] Yu H. and Wilamowski B., Neural network training with second order algorithms, *Human – Computer Systems Interaction: Backgrounds and Applications 2*, 99,463-476, **2012**.
  - [66] Looney C.G., Stabilization and speedup of convergence in training feedforward neural networks, *Neurocomputing*, 10, 7–31, **1996**.
  - [67] Fahlman S. and Lebiere C., The cascade-correlation learning architecture, *Carnegie Mellon University*, **1989**.
  - [68] Ghaffari A., Abdollahi H., Khoshayand M.R., Bozchalooi I.S., Dadgar A. and Rafiee-tehrani M., Performance comparison of neural network training algorithms in modeling of bimodal drug delivery, *International Journal of Pharmaceutics*, 327, 126–138, **2006**.
  - [69] Wilamowski B, “Understanding of Neural Networks,” Auburn University, **2010**.
  - [70] Ercanoglu M. and Gokceoglu C., Use of fuzzy relations to produce landslide susceptibility map of a landslide prone area (West Black Sea Region, Turkey), *Engineering Geology*, 75, 229–250, **2004**.
  - [71] Wilson J. and Gallant J., *Terrain analysis: principles and applications*, John Wiley and Sons, Inc., Canada, 479, **2000**.
  - [72] Ercanoğlu M., “Bulanık mantık ve istatistiksel yöntemlerle heyelan duyarlılık haritalarının üretilmesi: Batı karadeniz bölgesi (Kumluca Güneyi-Yenice Kuzeyi)”, Doktora Tezi, Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, 2003.

## **EKLER**







## EK-1. BBP1 modeline göre parametre etki grafikleri









## EK-2. BBP2 modeline göre parametre etki grafikleri









### EK-3. QP1 modeline göre parametre etki grafikleri









#### EK-4. QP2 modeline göre parametre etki grafikleri









## EK-5. CGD1 modeline göre parametre etki grafikleri









## EK-6. CGD2 modeline göre parametre etki grafikleri



## EK-7. LM1 modeline göre parametre etki grafikleri



## EK-8. LM2 modeline göre parametre etki grafikleri



## ÖZGEÇMİŞ

### Kimlik Bilgileri

Adı Soyadı : Aslı Can

Doğum Yeri : Ankara

Medeni Hali : Bekar

E-posta : [aslican.geo@gmail.com](mailto:aslican.geo@gmail.com)

Adresi: Burcu Sitesi 4. Blok No:9 Çayyolu, Ankara

### Eğitim

Lise: Keçioren Süper Lisesi (1999-2003)

Lisans : Hacettepe Üniversitesi Jeoloji Mühendisliği (2004-2009)

Yüksek Lisans : Hacettepe Üniversitesi Jeoloji Mühendisliği (2010-2014)

### Yabancı Dil ve Düzeyi

İngilizce (İleri Seviye), Almanca (Orta Seviye)

### İş Deneyimi

İksa Mühendislik, Proje Departmanı Jeoloji Mühendisi (2010-devam ediyor)

### Deneyim Alanları

Heyelan Duyarlılığı, Şev Analizleri, Zemin İyileştirme, ArcGS, Plaxis, Slide

### Tezden Üretilmiş Projeler ve Bütçesi

-

### Tezden Üretilmiş Yayınlar

-

### Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

-