



**İSTANBUL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**

**GÜNEYDOĞU ANADOLU BÖLGESİNDE BAZI KUŞ  
TÜRLERİNİN ÜREME BİYOLOJİLERİNİN YAPAY  
NÖRON AĞI MODELİYLE İNCELENMESİ**

**Bahtiyar KURT**

**Biyoloji Anabilim Dalı**

**Zooloji Programı**

**Danışman**

**Yrd. Doç. Dr. Cüneyt KUBANÇ**

**Haziran, 2004**

**İSTANBUL**



**İSTANBUL ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**YÜKSEK LİSANS TEZİ**

**GÜNEYDOĞU ANADOLU BÖLGESİNDE BAZI KUŞ  
TÜRLERİNİN ÜREME BİYOLOJİLERİNİN YAPAY  
NÖRON AĞI MODELİYLE İNCELENMESİ**

**Bahtiyar KURT**

**Biyoloji Anabilim Dalı**

**Zooloji Programı**

**Danışman**

**Yrd. Doç. Dr. Cüneyt KUBANÇ**

**Haziran, 2004**

**İSTANBUL**

## **ÖNSÖZ**

Lisans ve yüksek lisans öğrenimim sırasında ve tez çalışmalarım boyunca gösterdiği her türlü destek ve yardımdan dolayı çok değerli hocam Yrd. Doç. Dr. Cüneyt KUBANÇ'a en içten dileklerle teşekkür ederim. Çalışmalarımın her aşamasında beni destekleyen ve yol gösteren Yrd. Doç. Dr. Uygur ÖZESMİ'ye de tüm katkılarından dolayı teşekkür ederim.

Tez çalışmalarım kapsamında bana yardımlarını ve desteklerini esirgemeyen başta Ayşegül DOMAÇ olmak üzere Mert ALTINTAŞ'a, Nilüfer NORMAN'a, Stacy ÖZESMİ'ye, Ferda PERÇİN'e, Can Ozan TAN'a, Hilary WELCH'e, Türkiye Doğal Hayatı Koruma Derneği'ne ve fotoğraflarını benimle paylaşan Uz. Dr. Okan BİLGE ve Doç. Dr. Kazım ÇAPACI'ya teşekkürü borç bilirim.

**Haziran, 2004**

**Bahtiyar KURT**

## İÇİNDEKİLER

|                                                                                          |      |
|------------------------------------------------------------------------------------------|------|
| ÖNSÖZ .....                                                                              | i    |
| İÇİNDEKİLER .....                                                                        | ii   |
| ŞEKİL LİSTESİ.....                                                                       | iv   |
| TABLO LİSTESİ .....                                                                      | v    |
| SEMBOL LİSTESİ .....                                                                     | vi   |
| ÖZET .....                                                                               | vii  |
| SUMMARY .....                                                                            | viii |
| 1. GİRİŞ .....                                                                           | 1    |
| 2. GENEL KISIMLAR .....                                                                  | 3    |
| 2.1. Yapay Nöron Ağları Yaklaşımı .....                                                  | 3    |
| 2.2. Yapay Nöron Ağlarının Çalışma Prensipleri .....                                     | 4    |
| 2.3. Güneydoğu Anadolu Bölgesi Üreyen Kuşlar Araştırması Ve Çevresel Faktör Verileri...9 |      |
| 2.3.1. Girdi Verileri Hakkında Detaylı Bilgiler .....                                    | 11   |
| 3. MALZEME VE YÖNTEM .....                                                               | 15   |
| 3.1. Veriler .....                                                                       | 15   |
| 3.2. Verilerin İşlenmesi.....                                                            | 16   |
| 3.3. Modelleme .....                                                                     | 16   |
| 3.4. Model Sonuçlarının Analiz Yöntemi .....                                             | 18   |
| 4. BULGULAR .....                                                                        | 19   |
| 4.1. Kızıl Başlı Örümcekkuşu <i>Lanius senator</i> (Linnaeus, 1758) Modeli .....         | 19   |
| 4.1.1. Sinirsel Yorumlama Diyagramları .....                                             | 21   |
| 4.1.2. Duyarlılık Analizi .....                                                          | 24   |

|                                                                                  |           |
|----------------------------------------------------------------------------------|-----------|
| 4.2. Ak Mukallit <i>Hippolais pallida</i> (Ehrenberg, 1833) Modeli .....         | 26        |
| 4.2.1. Sinirsel Yorumlama Diyagramları .....                                     | 28        |
| 4.2.2. Duyarlılık Analizi .....                                                  | 31        |
| 4.3. Bozkır Toygarı <i>Calandrella brachydactyla</i> (Leisler, 1814) Modeli..... | 32        |
| 4.3.1. Sinirsel Yorumlama Diyagramları .....                                     | 34        |
| 4.3.2. Duyarlılık Analizi .....                                                  | 37        |
| <b>5. TARTIŞMA VE SONUÇ.....</b>                                                 | <b>39</b> |
| 5.1. Yapay Nöron Ağları Yönteminin Başarısı .....                                | 39        |
| 5.2. Güney Doğu Anadolu Bölgesinde Kuş Habitat Seçimi .....                      | 41        |
| 5.2.1. Kızıl Başlı Örümcekkuşu <i>Lanius senator</i> (Linnaeus, 1758).....       | 41        |
| 5.2.2. Ak Mukallit <i>Hippolais pallida</i> (Ehrenberg, 1833).....               | 44        |
| 5.2.3. Bozkır Toygarı <i>Calandrella brachydactyla</i> (Leisler, 1814) .....     | 46        |
| 5.3. YNA Modellerinin Pratik Uygulamaları Ve Öneriler.....                       | 48        |
| <b>KAYNAKLAR .....</b>                                                           | <b>51</b> |
| <b>EKLER.....</b>                                                                | <b>53</b> |
| <b>ÖZGEÇMİŞ.....</b>                                                             | <b>62</b> |

## ŞEKİL LİSTESİ

|            |                                                                         |    |
|------------|-------------------------------------------------------------------------|----|
| Şekil 2.1  | : YNA Çalışma Prensibi .....                                            | 5  |
| Şekil 3.1  | : Kızıl başlı örümcekkuşu.....                                          | 15 |
| Şekil 3.2  | : Ak mukallit ve bozkır toygari.....                                    | 16 |
| Şekil 4.1  | : Kızılbaşlı örümcekkuşu için düzeltilmiş c-indeksi .....               | 20 |
| Şekil 4.2  | : Kızıl başlı örümcekkuşu için sinirsel yorumlama diyagramları .....    | 21 |
| Şekil 4.3  | : Kızıl başlı örümcekkuşu için sinirsel yorumlama diyagramları .....    | 22 |
| Şekil 4.4  | : Kızıl başlı örümcekkuşu için sinirsel yorumlama diyagramları .....    | 23 |
| Şekil 4.5  | : Kızıl başlı örümcekkuşu için sinirsel yorumlama diyagramları .....    | 23 |
| Şekil 4.6  | : Kızıl başlı örümcekkuşu için duyarlılık analizleri sonuçları.....     | 25 |
| Şekil 4.7  | : Ak mukallit için düzeltilmiş c-indeksleri.. ..                        | 27 |
| Şekil 4.8  | : Ak mukallit için sinirsel yorumlama diyagramları .....                | 28 |
| Şekil 4.9  | : Ak mukallit için sinirsel yorumlama diyagramları .....                | 29 |
| Şekil 4.10 | : Ak mukallit için sinirsel yorumlama diyagramları .....                | 29 |
| Şekil 4.11 | : Ak mukallit için sinirsel yorumlama diyagramları .....                | 30 |
| Şekil 4.12 | : Ak mukallit için duyarlılık analizleri sonuçları .....                | 31 |
| Şekil 4.13 | : Bozkır toygari için düzeltilmiş c-indeksleri.. ..                     | 33 |
| Şekil 4.14 | : Bozkır toygari için sinirsel yorumlama diyagramları .....             | 34 |
| Şekil 4.15 | : Bozkır toygari için sinirsel yorumlama diyagramları .....             | 35 |
| Şekil 4.16 | : Bozkır toygari için sinirsel yorumlama diyagramları .....             | 35 |
| Şekil 4.17 | : Bozkır toygari için sinirsel yorumlama diyagramları .....             | 36 |
| Şekil 4.18 | : Bozkır toygari için duyarlılık analizleri sonuçları.....              | 37 |
| Şekil 5.1  | : Lineer regresyon ve YNA modellerinin üç tür için karşılaştırılması .. | 40 |
| Şekil 5.2  | : Kızıl başlı örümcekkuşu budanmış sinirsel yorumlama diyagramı ...     | 43 |
| Şekil 5.3  | : Ak mukallit için budanmış sinirsel yorumlama diyagramı ..             | 45 |
| Şekil 5.4  | : Bozkır toygari için budanmış sinirsel yorumlama diyagramı ..          | 47 |

## TABLO LİSTESİ

|                  |                                                                                                 |           |
|------------------|-------------------------------------------------------------------------------------------------|-----------|
| <b>Tablo 2.1</b> | : Uydu verilerinin kaynağı ve verilerin yılları.....                                            | <b>13</b> |
| <b>Tablo 2.2</b> | : Uydu görüntülerindeki 6 bant değerinin tanımları ve özellikleri.....                          | <b>13</b> |
| <b>Tablo 2.3</b> | : Çevresel faktör verilerinin açıklamaları.....                                                 | <b>14</b> |
| <b>Tablo 2.4</b> | : Güneydoğu Anadolu Bölgesi vejetasyon sınıflandırma grupları .....                             | <b>14</b> |
| <b>Tablo 4.1</b> | : Kızıl başlı örümcekkuşu YNA modelinde çevresel faktörlerin sonuca yüzde olarak etkileri ..... | <b>24</b> |
| <b>Tablo 4.2</b> | : Ak mukallit YNA modelinde çevresel faktörlerin sonuca yüzde olarak etkileri.....              | <b>30</b> |
| <b>Tablo 4.3</b> | : Bozkır toygarı YNA modelinde çevresel faktörlerin sonuca yüzde olarak etkileri.....           | <b>36</b> |

## SEMBOL LİSTESİ

|                 |                                                                           |
|-----------------|---------------------------------------------------------------------------|
| <b>YNA</b>      | : Yapay Nöron Ağları                                                      |
| <b>NevProp3</b> | : Nevada Üniversitesi yapay nöron ağları programı                         |
| <b>DHKD</b>     | : Türkiye Doğal Hayatı Koruma Derneği                                     |
| <b>UTM</b>      | : Universal Transversery Mercator koordinat sistemi                       |
| <b>GPS</b>      | : Coğrafik koordinatlama sistemi                                          |
| <b>TM1</b>      | :LandSat uydularından alınan bant değerleri; 1, birinci bandı göstermekte |
| <b>CBS</b>      | : Coğrafi Bilgi Sistemleri                                                |

## ÖZET

### GÜNEYDOĞU ANADOLU BÖLGESİNDE BAZI KUŞ TÜRLERİNİN ÜREME BİYOLOJİLERİNİN YAPAY NÖRON AĞI MODELİYLE İNCELENMESİ

Bu çalışmada Güney Doğu Anadolu Bölgesinde üreyen kızıl başlı örümcekkuşu *Lanius senator* (Linnaeus, 1758), ak mukallit *Hippolais pallida* (Ehrenberg, 1833) ve bozkır toygarı *Calandrella brachydactyla* (Leisler, 1814) türlerinin bilinen üreme dağılımları ve üreme noktalarına ait çevresel faktör verileri kullanılarak türlerin üreme tercihleri modellenmiştir.

Çalışma kapsamında Güney Doğu Anadolu Bölgesinde gerçekleştirilen kuş araştırmalarının sonuçları ve araştırmanın yapıldığı tüm noktalara ait 12 çevresel faktöre ait değerler kullanılarak modeller oluşturulmuştur. Modeller yapay nöron ağı yöntemiyle belirlenmiştir. Yapay nöron ağı son dönemlerde ekoloji alanında kullanılmaya başlanan ve doğrusal olmayan olayları tahmin güçleriyle ekolojik süreçleri anlamlandırmada güçlü bir yöntemdir.

Çalışmada ilk olarak her bir tür için en uygun modeller belirlenmiş ardından bu modellerle birlikte çevresel faktörlerin türün üreme tercihlerine etkileri analiz edilmiştir. Analizler Sinirsel Yorumlama Diyagramları, Girdi İlişkilendirme Tabloları ve Duyarlılık Analizleriyle yapılmıştır.

Çalışma kapsamında bulgular ortaya konmuş ve son bölümde yapay nöron ağlarının başarıları, kuş türlerinde habitat seçim analizleri tartışılmış ve geleceğe yönelik öneriler okuyuculara sunulmuştur.

## **SUMMARY**

### **STUDY ON BREEDING BIOLOGIES OF SOME BIRD SPECIES IN SOUTHEASTERN TURKEY WITH ARTIFICIAL NEURAL NETWORK MODELS**

In this study, habitat selection preferences of Woodchat Shrike *Lanius senator* (Linnaeus, 1758), Olivecous Warbler *Hippolais pallida* (Ehrenberg, 1833) and Short-toed Lark *Calandrella brachydactyla* (Leisler, 1814) have been modeled that are the bird species breeding in South-Eastern Anatolia. For the models, data on existence of breeding and environmental factors have been used as input variables.

The breeding data has been gathered from the surveys that were carried out in South Eastern Anatolian Region and also data on 12 different environmental factors have been gathered for breeding bird survey points. Models were generated by using Artificial Neural Networks method. Being rather a new technique for ecological studies, Artificial Neural Networks are powerful tools for predicting nonlinear processes indeed.

As a first step, the best model have been determined for each species, and following that the analyses were conducted in order to measure the effect of environmental factors on the breeding preferences. For the analyses, neural interpretation diagrams, relevances and sensitivity analyse have been used.

Eventually, the outputs have been described and in the last chapter the success of artificial neural networks and habitat selection by these birds have been discussed. Lastly, a few suggestions have been listed for those that are interested in further work on the subject.

## 1. GİRİŞ

Bu tez çalışması kapsamında Güneydoğu Anadolu Bölgesinde üreyen kızıl başlı örümcekkuşu *Lanius senator* (Linnaeus, 1758), ak mukallit *Hippolais pallida* (Ehrenberg, 1833) ve bozkır toygarı *Calandrella brachydactyla* (Leisler, 1814) türlerinin bilinen üreme dağılımları ve üreme noktalarına ait çevresel faktör verileri kullanılarak bu türlerin üreme bölgesi seçim tercihleri modellenmiştir. Modelleme yöntemi olarak yapay nöron ağları (YNA) kullanılmıştır.

Çalışmanın birincil amacı kızıl başlı örümcekkuşu, ak mukallit ve bozkır toygarının habitat tercihlerini etkileyen bazı çevresel değişkenleri ortaya koymaktır. Bu amaçla kurulan modeller ile gelecekteki diğer benzer kuş üreme dağılım tahminleri için genelleme imkanı verecek bir örnek yaratılmaktadır. Bu çalışma ile YNA modellerinin Türkiye'deki üreyen kuş verilerinin genellenmesinde kullanılabilecek uygun ve kullanışlı bir araç olduğu gösterilmektedir. Bu amaç doğrultusunda çalışma kapsamında modellerin literatürdeki bilgiler ışığında ne kadar doğru tahminler yaptığı karşılaştırılmaktadır. Modelleme ile türlerinin yaşam alanı ve çevresel faktör ihtiyaçlarının belirlenmesi gelecekte bölgesel olarak yok olabilecek türler için uygulanabilecek olası restorasyon ve doğaya yeniden yerleştirme çalışmalarına ışık tutmaktadır. Çalışmada bu amaçla YNA modellerinin kullanılabilirliği ve uygunluğu tartışılmaktadır.

Genel Kısımlar bölümünde tez kapsamında kullanılan yöntem ve bu yöntemle yapılan çalışmaların tarihsel gelişimine değinilmiş ve konuyla ilgili kaynaklar derlenmiştir. Çalışma kapsamında modelleme yöntemi olarak kullanılan yapay nöron ağları yaklaşımı Malzeme ve Yöntem bölümünde yakından incelenmiş, modelin çalıştırıldığı NevProp3 programının çalışma prensipleri anlatılmıştır. Yine tez kapsamında kullanılan ornitolojik ve çevresel veriler bu bölümde yakından incelenmiştir. Bulgular bölümünde modelin ürettiği sonuçlar ve her bir çevresel faktörün tez kapsamında değerlendirilen 3 ayrı kuş türünü nasıl etkilediği ortaya konulmuştur. Son olarak modelin başarısı ve

evresel faktrlerin kuřlarda remeye olan etkileri literatr bilgileri de gz nne alınarak Tartıřma ve Sonu Blmnde deęerlendirilmiřtir.

Tez kapsamında yapılan alıřma  ayrı ařamadan oluřmaktadır. İlk ařamada modelleme kapsamında kullanılacak veriler toplanmıř ve derlenmiřtir. Bu kapsamda Gneydoęu Anadolu Blgesinde yapılan reyen kuřlar arařtırmasından elde edilen sonular kapsamında blgede reyen 3 ayrı kuř tr seilmiřtir. Bununla birlikte trlerde remeyi etkileyebilecek 12 ayrı evresel faktrle ilgili veriler de ilgili kurumlardan temin edilmiřtir. İkinci ařamada tm veriler NevProp3 bilgisayar programı kullanılarak her bir tr iin en uygun YNA modeli retilmiřtir. Son olarak da belirlenen modeller yakından incelenerek evresel faktrlerin her bir trn reme seimlerini nasıl etkiledięi Sinirsel Yorumlama Diyagramları, Girdi İliřkilendirme Tabloları ve Duyarlılık Analizi yntemleriyle belirlenmiřtir.

## 2. GENEL KISIMLAR

### 2.1. YAPAY NÖRON AĞLARI YAKLAŞIMI

Çalışma bünyesinde oluşturulacak model için yapay nöron ağları yaklaşımının kullanılmasının en önemli nedeni yapay nöron ağlarının verilerin sınıflandırılmasında doğrusal olmayan terimleri de sınıflandırabilmesi özelliğidir. Bir başka deyişle yapay nöron ağları “ve”, “veya”, “değil”, “harici veya” gibi mantık terimlerini de modelleyebilmektedir. Kuşların üreme dönemlerinde yaşam alanı seçimlerinin dinamik ve doğrusal olmadığını belirten Verner ve diğ. (1996) kuş – yaşam alanı ilişkilerinin parametrik istatistiksel tahminlerle ölçülmesinin uygun olmayacağını belirtmektedir. Yapay nöron ağları kuşlar ve yaşam alanlarındaki ilişkileri söz konusu olduğunda doğrusal olmayan ilişkileri diğer doğrusal istatistik modellerinden daha iyi tahmin edebilmektedir (doğrusal regresyon vb.), üstelik parametrik olmayan veri dağılımlarını da kullanabilmektedir (Fielding, 1999, Özesmi ve Özesmi 1999). Bu çalışma kapsamında da kuş türlerinin üreme tercihleri konu olarak ele alınmış ve yukarıda belirtilen nedenlerden dolayı da YNA yaklaşımı uygun modelleme yöntemi olarak tercih edilmiştir.

YNA yaklaşımı tarihte ilk olarak yapay zeka çalışmaları kapsamında kullanılmaya başlanmıştır. Bu yöntem günümüzde yaygınlaşarak pek çok alanda uygulanmaktadır. Müşteriyi tanıyan otomatik benzin pompaları, mekanik yardımcılı tekerlekli sandalyeler, tıbbi uygulamalar için kullanılan görüntüleme sistemleri, taşımacılık işlemlerinde kullanılan robotlar ve evlerde kullanılan servis robotları YNA’ların uygulama alanlarına verilebilecek örneklerden yalnızca birkaç tanesidir (Efe ve Kaynak, 2000). YNA fikri ve çalışmaları ilk olarak Rashevsky, McCulloch, Pitts ve Hebb tarafından 1940’lı yıllarda ortaya atılmıştır. Bu alandaki ilk çalışmalar insan beyninde bulunan nöronların çalışma prensipleri taklit edilerek geliştirilmiştir. Bunu takiben gerçekleşen çalışmalar kapsamında gelişen YNA günümüzde “makine öğrenme” alanında kendine önemli bir yer edinmiştir. YNA’nın ekoloji alanındaki kullanımıysa


oldukça yenidir. Chon ve diğ. (1996) YNA yaklaşımını bentik makro invertebrat verilerinin sınıflandırılmasında kullanırken Levine ve diğ. (1996) toprak verileriyle toprak sınıflandırması gerçekleştirmek için ileri sürümlü bir YNA modeli oluşturmuştur. Boudjema ve Chau (1996) YNA ile huş ağaçları üzerinde yaşayan bir parazitin yoğun olarak ortaya çıktığı dönemleri belirlemiştir. Tan ve Smeins (1996) iklimsel verilere dayalı olarak bir çayır komünitesindeki baskın tür değişikliklerini yine YNA ile tahmin etmiştir. Bunların yanında YNA'nın ekoloji alanında kullanımları için önerilecek diğer çalışmalar ise şöyle sıralanabilir: Guan ve diğ. (1997), Poff ve diğ. (1996), Recknagel ve diğ. (1997), Paruelo ve Tomasel (1997), Baran ve diğ. (1996), Lek ve diğ. (1996a,b), Scardi (1996), Özesmi ve Özesmi (1999). Bunların yanında YNA ile ilgili olarak daha genel bilgiler için Weiss ve Kulikowski (1991), Anderson (1995), Bishop (1995) ve Ripley (1996) önerilebilir.

## **2.2. YAPAY NÖRON AĞLARININ ÇALIŞMA PRENSİPLERİ**

YNA yöntemi ilk olarak insan beyninin çalışmasını modellemek için geliştirilmiştir. YNA ve beyin işleyiş şekilleri benzeşmekteyse de YNA'ların yapısı beyne göre çok daha basit düzeydedir. Beyne benzer şekilde, YNA'lar da nodlar (beyinde nöronlar), girdiler (beyinde dendritler) ve çıktılar (beyinde aksonlar) birleşiminden oluşmaktadırlar. Beyindeki gibi nodlar birbirlerine bağlıdırlar. Buradaki bağlantılar belli katmanlar altında sınıflandırılmışlardır. YNA ile yapılan modellemelerin gücü, sistemin tüm nodlarının aynı anda çalışmasından kaynaklanan bir bütün olmasından ve bundan dolayı herhangi bir nod işlemese dahi bu eksikliğin tüm sistemdeki toplam etkisinin göreceli olarak asgari seviyede kalmasından kaynaklanmaktadır. Sistemin diğer bir özelliği de bir bütün olarak doğrusal olmayan karakterde olmasıdır.

Bu çalışma kapsamında ileri sürümlü yapay nöron ağları kullanılmıştır. İleri sürümlü yapay nöron ağları Girdi, Çıktı ve Gizli katmanlardan oluşmaktadır. Sistemdeki tüm nodlar bu katmanlar altında sınıflandırılmıştır. Tüm sistem, katmanlar ve bu katmanlardaki nodların birbirleriyle tamamen bağlantılı bir halde bulunmalarından oluşmaktadırlar (Şekil 2.1.). Girdi katmanındaki nodlar elde bulunan verilerin sisteme giriş noktalarını oluşturmakta ve çıktı katmanındaki nodlar da sonucu yansıtmaktadırlar.

Gizli katmanlar, sonuç modelinin doğrusal olmama özelliğini sağlamakta ve YNA yaklaşımının diğer modelleme yöntemlerinden farklı ve avantajlı kılmaktadır. Bununla birlikte birden çok gizli katmanın varlığı çoğunlukla sonucu çok fazla değiştirmemekte, aksine yapılan çalışmada harcanan zamanı artırmaktadır (Özesmi ve diğ., 2002).



Şekil 2.1: YNA çalışma prensibi – elimizde bulunan veriler ağırlıklarla çarpılarak nodlara girilmektedir (sağ alt köşe). Çarpımların sonucunda ortaya çıkan bu değerlerin toplamı özel bir aktivasyon fonksiyonuna sokularak o nod için çıkış değeri hesaplanmaktadır. Girdi katmanındaki tüm nodlar için aynı uygulama gerçekleştirildikten sonra her bir noddan çıkan bu değerler de ağırlıklarla çarpılarak toplanır ve gizli katman nodlarında bulunan aktivasyon fonksiyonuna tabi tutulur. Son olarak aynı işlem çıktı katmanında bulunan nod için uygulanır ve bu nod için elde edilen sonuç bize modelin sonucunu verir. Bu tez çalışmasında girdi verisi olarak toplam 12 çevresel faktör kullanılmıştır. Bundan dolayı girdi katmanında toplam 12 nod bulunmaktadır. Çıktı katmanında ise sadece bir nod bulunmakta ve bu nod türün üreme durumunu göstermektedir (0 – 1 arası değer). İleri sürümlü YNA’da bütün nodlar birbirleriyle bağlantılıdır. Girdi katmanındaki her bir nod gizli katmandaki tüm nodlara, gizli katmandaki tüm nodlar da sonuç katmanındaki noda bağlıdır.

İleri sürümlü bir yapay nöron ağında bulunan nodlar birbirleriyle temas halindedir. Girdi katmanındaki tüm nodlar gizli katmandaki nodlarla, gizli katmanda bulunanlar da çıktı katmanındaki tek nodla bağlantılıdır. Yapay nöron ağlarında bir noddan çıkan bilgi diğer noda geçerken bu bağlantıdaki ağırlıkla çarpılır. Bir sonraki katmanda bulunan tüm nodlar için bütün çarpımların toplamı alınır ve bu değere, bir sabit sayı hata payı

olarak eklenir. Çıkan sonuç bir aktivasyon fonksiyonuna sokulur. Bu fonksiyonun türü kullanılan YNA'daki seçime bağlıdır. Bu çalışmada simetrik lojistik fonksiyon kullanılmıştır. Bu fonksiyonun alacağı çıktı değeri girilen değerden bağımsız olarak  $(-0,5$  ve  $+0,5)$  aralığında değişmektedir. Böylece bir sonraki noda ulaşacak değer belli bir aralıkta tutulabilmektedir. Çıktı katmanında bulunan nod dışında tüm nodlarda bu fonksiyon kullanılırken çıktı nodunda sonuç değeri her zaman  $0 - 1$  arasında değişen asimetrik lojistik fonksiyon kullanılmıştır. Bu da bize türün üreme olasılığını vermektedir. 0 değeri bir noktada üremenin olmadığını işaret ederken 1 değeri başarılı bir üremeyi göstermektedir.

Yukarıdaki şekilde de gösterildiği gibi tüm girdiler ilk adımda kullanıcının girdiği rasgele başlangıç tohumu sayılarına (başlangıç ağırlıklarının belirlenmesi için sisteme girilen sayı) bağlı olarak NevProp3 tarafından belirlenen rasgele ağırlıklarla çarpılarak toplanmaktadırlar (Denklem 2.1). Bu toplam yukarıda belirtilen aktivasyon fonksiyonuna ( $\Phi$ ) uygulanarak o nod için çıktı ( $\Ç$ ) hesaplanmaktadır (Denklem 2.2). Her bir girdinin çarpıldığı ağırlık doğal olarak o noddaki çıktıda bir rol oynamaktadır.

$$D = W_1.U_1 + W_2.U_2 + \dots + W_n.U_n - \theta = \sum W_i.U_i - \theta \quad (2.1)$$

D : her bir noda etki edecek toplam değer

W : her bir bağlantıyı temsil eden katsayı

U: girdi değerler (çevresel faktör değerleri)

$\theta$ : hata payı

$$\Phi(D) = \Ç \quad (2.2)$$

$\Phi$  : Aktivasyon fonksiyonu

$\Ç$  : Çıktı

Bu işlem tüm katmanlar arasında her bir nod için yapılmaktadır. Ağırlıkların büyüklükleri artıkça sonuca olan etkileri de doğru orantılı olarak artmaktadır. İdeal modellerde bu ağırlıklar o çevresel faktörün sonuç üzerine olan etkisini yansıtmak için kullanılmaktadır. Bu kapsamda üreme ihtimalinde en önemli olan faktörler en yüksek ağırlıkları, en az etki edenler de en küçük değerdeki ağırlıkları alacaklardır. Ağırlıkların ilk adımda aldıkları rasgele değerler bu anlamda sonucu etkileyeceklerinden bu rasgele

seçimden kaynaklanabilecek olası hatalar NevProp3 tarafından farklı yöntemlerle çözülmektedir. Bunlar YNA sistemlerinde kullanılan öğrenme ve düzeltme mekanizmalarıdır. Bu çalışma kapsamında kullanılan *Hata Geriye Yayma Yöntemi* her bir ağırlığın tekrar tekrar hesaplanmasıyla modeldeki ağırlıklara en son halini vermektedir ve sonuçta elde edilecek ideal modeldeki bağlantı katsayılarının gerçekçi olmasını sağlamaktadır. Böylece ideal modeldeki bağlantılar, hangi çevresel faktörün, sonucu ne kadar etkilediğini bizlere gösterebilmektedir (Girdi İlişkilendirme Tabloları).

Hata Geriye Yayma Yöntemi aslında matematikte kullanılan en küçük kareler eğitiminin geliştirilmiş halidir. Bu yöntemin amacı bağlantılardaki ağırlıkları adım adım değiştirmek ve bu vesileyle hedef çıktıdaki hata payını düşürmektedir. Yani bir anlamda, modelin çıktı değerini gerçek verilerdeki çıktıya yaklaştırmak vasıtasıyla elimizde bulunan yapay nöron ağını eğitmektedir. Verilerin girdi katmanından girilmesiyle başlayan ve çıktı katmanında ilk sonucun alınmasıyla sonuçlanan işlem eğitimin birinci adımını oluşturmaktadır. İlk ağırlıklar, eğitimin başında kullanıcı tarafından girilen rasgele bir başlangıç tohumu rakamına göre NevProp3 tarafından belirlenir. Bu değerler  $(-0,1$  ve  $+0,1)$  aralığında yer alır. İlk ağırlıklar eğitimin birinci adımının ardından düzeltme değeri adı verilen küçük bir değer eklenerek biraz değiştirilirler. Bu düzeltme değeri hem eğitim sürecini kısaltacak hem de ağırlıkların bir an önce yakınsamasını sağlayacak büyüklükte seçilir. Bu çalışma kapsamında dünya çapında YNA için standart öğrenme oranı olarak kabul edilen 0,01 değeri kullanılmıştır (Goodman 1996). Bu öğrenme oranı değeri kullanılarak ağırlıklar eğitimin her adımında tekrar düzeltilerek modelin çıktısının gerçek hayattaki çıktıya yaklaşması sağlanır. Bu yakınsama eğitim kapsamında sağlanırken bir yandan da bağlantılardaki ağırlıklar da gerçek değerlerini bulmakta ve her bir faktörün sonuca etkisi de belirlenmektedir. Model çıktısındaki değer istenilen değere yakınsayana kadar eğitim devam ettirilir. Bu yakınsama yöntemi Hata Geriye Yayma Yöntemi yaklaşımıyla sağlanmaktadır.

NevProp3 yukarıda belirtilen eğitimi bünyesinde barındırdığı otomatik eğitim işlevi ile gerçekleştirmektedir. Otomatik Eğitim ile her bir iterasyonda modelin hata oranı da azalmaktadır. Yani iterasyon sayısı artıkcı sistem eldeki veriyi daha iyi tanımakta ve hata payı da azalmaktadır (yakınsama). Ancak iterasyonun uzun süre devam etmesi durumunda ortaya çıkacak bir tehlike NevProp3'de doğrulama yöntemiyle

çözümlemektedir. Eğitimin uzun süre devam etmesi ve hatanın azalması modelin elimizde bulunan veriler özelliğinde iyileşmesini ve özelleşmesini sağlarken modelin diğer uygulamalar için genelleme özelliğinin azalmasına neden olmaktadır (aşırı uyumlaşma). Bu durumun üstesinden gelmek için hali hazırda var olan verilerin bir kısmı modelin eğitiminde kullanılmadan bir kenara ayrılmakta ve modelin başarısını ölçmek için kullanılmaktadır. Bu çalışma kapsamında doğrulama verileri tüm verilerin % 40'ını oluşturmaktadır. NevProp3 elimizdeki verilerin bir kısmıyla eğitimi gerçekleştirirken bir yandan da her bir hata düzeltme adımında modeli doğrulama kümesindeki verilere de uygulayarak hatayı sürekli ölçmektedir. Böylece NevProp3 her bir hata düzeltme adımında hem eğitimdeki veri kümesinin hatasını ölçmekte hem de doğrulama verilerinin hatasını ölçerek her iki hatayı karşılaştırmaktadır. Eğitim verilerini değerlendiren modelin buradaki hata payı devamlı düşerken (yakınsama) doğrulama verilerindeki hata payı önce eğitim verilerine benzer şekilde azalır sonra da belli bir noktadan sonra tekrar yükselmeye başlar. Model, eğitimin yapıldığı verilere aşırı uyumlaştığı için bağımsız veriler üzerindeki başarı (genelleme başarısı) belli bir noktadan sonra azalmaya başlar (Ek 1). İşte bu an modelin artık elimizdeki eğitim verilerine özelleşmeye ve genelleme gücünü kaybetmeye başladığı andır. Otomatik eğitim sürecinde iki hata payını da ölçen NevProp3 doğrulama kümesindeki hata payının artmaya başladığı noktada eğitimi otomatik olarak durdurur. Bu durma noktasında eğitim verilerindeki hata değeri hedef hata değeri olarak belirlenir. Başka bir deyişle modelin bundan daha iyi bir sonuç elde etmesi istenmemektedir. Bu eğitim işlemi birkaç kez tekrar edilerek (rasgele başlangıç ağırlıkları farklı modeller oluşturabileceğinden) her bir seferinde hedef hata değerleri ayrı ayrı belirlenir. Bu çalışmada NevProp3 tarafından önerilen 5 eğitim tekrarı kullanılmıştır. Yani eğitim tam 5 kere tekrar edilmiş ve 5 ayrı hedef hata değeri elde edilmiştir. Son olarak bu 5 hedef hata toplanır ve ortalamaları alınarak nihai hedef hata değeri hesaplanır. Sistem bu kez tüm verilerle, kenarda doğrulama verileri ayrılmadan belirlenen hedef hata değerine ulaşılan kadar çalıştırılır ve eğitim bu hata payına gelindiğinde kesilir. Böylece hem tüm verilerin kullanılması sağlanır hem de modelin genelleme özelliği garanti altına alınır. Bu son eğitimin ardından modeldeki tüm nodlar arasındaki ağırlıklar belirlenmiş olur.

Bu çalışma kapsamında model için seçilebilecek değişik konfigürasyonlar arasındaki hata paylarını değerlendirebilmek için c-indeksi kullanılmıştır (uyum indeksi). NevProp3 kapsamında kullanıcı tarafından girilecek her bir başlangıç tohum değerinin sonuca etkisi farklı olacağından tüm eğitim birkaç defa farklı başlangıç tohumuyla denenmelidir. Bu çalışma kapsamında 3 ayrı başlangıç tohumu kullanılmıştır ve her birinden elde edilen modeller c-indekslerine bakılarak ideal model seçilmiştir. C-indeksi bir modelin gerçek durumu 1 olan olayı gerçek durumu 0 olan diğer bir olaya göre daha yüksek bir yüzdeyle tarif etme olasılığıdır. Yani c-indeksinin değeri 1'e yaklaştıkça modelimizin başarısı da artar. C-indeksinin 0,5 olması durumunda ise modelimizin elde ettiği sonuç rasgele bir modelin elde edeceği sonuçtan farklı değildir, yani model başarısızdır.

Model konfigürasyonuna son şekli vermek için NevProp3 kapsamında Tekrar Yükleme yöntemi kullanılmaktadır. Hangi modelin daha iyi işleyeceğine karar vermek için yapılan bu işlemin sonucunda düzeltilmiş c-indeksi saptanmaktadır. Her bir tekrar yükleme, veri kümesinden N adet veri alır ve modeli bu yeni kümede ve orijinal veri kümesiyle aynı anda çalıştırarak c-indekslerini belirler. Bu işlem kullanıcı tarafından tekrar yükleme için belirlenen rakam kadar tekrar edilir. Her bir tekrar yükleme için her iki kümenin c-indeksleri arasındaki farka bakılır ve bu farkların ortalaması alınır. Düzeltilmiş c-indeksi ana modelin c-indeksinden bu ortalama değerin çıkarılması ile elde edilir. Düzeltilmiş c-indeksi maksimum hata payını göstereceğinden yapılan çalışmaya kesinlik kazandırır. Düzeltilmiş c-indekslerine bakılarak ideal model seçimi tamamlanır.

### **2.3. GÜNEYDOĞU ANADOLU BÖLGESİ ÜREYEN KUŞLAR ARAŞTIRMASI VE ÇEVRESEL FAKTÖR VERİLERİ**

Bu tez çalışmasında kullanılan ornitolojik veriler Türkiye Doğal Hayatı Koruma Derneği'nin (DHKD) Başbakanlık GAP idaresiyle 2001 – 2003 yılları arasında ortaklaşa yürüttüğü Güneydoğu Anadolu Bölgesi Biyolojik Çeşitlilik Projesinden elde edilmiştir (Welch, 2004).

Bu bölümde tez kapsamında kullanılan ornitolojik verilerin niteliği ortaya konulmaktadır. Proje kapsamındaki kuş araştırmaları 2001 ve 2002 yıllarının bahar aylarında gerçekleştirilmiştir. Arazi çalışmalarının yapılması için her iki yılda da üreyen kuşların en aktif oldukları üreme dönemi olan 15 Nisan – 15 Haziran tarihleri seçilmiştir. Üreyen kuş araştırması için tüm bölge (50 X 50) km’lik ana karelere ve bu ana kareler de (10X10) km’lik çalışma karelerine (alt kareler) ayrılmıştır. Uygun kareleme için UTM koordinat sistemi kullanılmıştır. UTM koordinat sistemi fauna ve flora araştırmalarında koordinat bölgelerinin karesel ve aynı büyüklükte olması nedeniyle tercih edilen bir sistemdir. Güneydoğu Anadolu Bölgesinde her bir ana kare içerisindeki alt kareler çalışma kapsamında tek tek ele alınmış ve araştırmalar bu alt kareler ölçeğinde yapılmıştır. Kuş araştırmaları kapsamında toplamda 356 alt kutuda çalışmalar gerçekleştirilmiştir. Çalışmalar sabahları güneşin doğuşunu takiben başlamış ve kuşların ötüşlerinin sıcaklığa bağlı olarak azalmasıyla sona erdirilmiştir. Sıcaklıkların kısmen düşük olduğu 15 Mayıs öncesinde sabah çalışmaları 06:30 – 11:00 saatleri arasında öğleden sonra çalışmaları da 15:00 – 19:30 saatleri arasında, sıcaklıkların yüksek seviyelere çıktığı 15 Mayıs sonrasındaysa sabah çalışmaları 05:30 – 09:00 öğleden sonra çalışmaları da 17:00 – 19:30 saatleri arasında gerçekleştirilmiştir.

Çalışmanın yapıldığı her alt karede iki kuş araştırma uzmanı, her biri yarımşar saat olmak üzere iki ayrı gözlemde bulunmuşlardır. Bundan dolayı her bir alt kare için toplam 4 adet yarım saat birimlik kuş verisi seti elde edilmiştir. Kuş verileri bu yarım saat içerisinde transekt metodu ile yürüyerek toplanmış ve kuşlara ait üreme verileri Avrupa Kuş Sayım Konseyi’nin belirlediği yöntemlerle standart formlara girilerek saklanmıştır. Her bir yarım saatlik çalışmanın başlama ve bitiş noktalarının koordinatları uzmanlar tarafından GPS (Coğrafik Koordinatlama Sistemi) aletleriyle kaydedilmiştir. Tez çalışması kapsamında her bir yarım saatlik veri, başlangıç noktaları baz alınarak değerlendirilmiştir. Yani modellemede kullanılan tüm veri girdileri başlangıç koordinatları baz alınarak belirlenmiştir. Her bir yarım saatlik çalışmada kuş türlerinin bir çoğunun çalışmanın başlangıç kısmında yoğun olarak kaydedilmesi bu tercihin nedenidir. Çalışmanın ilk dakikalarındaki tür kaydetme yoğunluğunun doğallığı her bir yarım saatte bir kez görülen kuş türünün, o yarım saatlik çalışma kapsamında bir kere daha kaydedilmemesinden kaynaklanmaktadır. Çalışma yöntemiyle ilgili detaylı bilgiler proje raporunda bulunabilir (Welch, 2004).

İki yıllık çalışmanın sonucunda toplamda 1592 yarım saatlik çalışma gerçekleştirilmiştir. Diğer bir deyişle modelimiz için tam olarak 1592 adet nokta ve bu noktalara ait veriler ve üreme bilgileri kullanılmıştır. Bu tez kapsamında türlere ait tüm üreme kayıtları “var” ya da “yok” şeklinde değerlendirilmiş ve NevProp3’e her bir nokta için üreme durumunda 1 ve üreme kaydının bulunmaması durumunda 0 değerleriyle girilmiştir.

Tez kapsamında kuşların üremesine etkisi olacağı düşünülen çevresel faktörler modele girdi olarak eklenmiş ve model bu girdiler üzerine yapılandırılmıştır. Modelde kullanılan çevresel faktör verileri şunlardır: uzaktan algılama verileri, yıllık ortalama sıcaklık değerleri, yıllık ortalama nispi nem değerleri, noktaların en yakın yola uzaklıkları, noktaların en yakın suya uzaklıkları (nehir, dere, baraj, göl vb.), yükseklik değerleri ve vejetasyon sınıflandırması grupları.

Güneydoğu Anadolu Bölgesi Türkiye’de kuşlar hakkında en kapsamlı verinin toplandığı bölgedir. Ülkemizde yapılan ornitolojik çalışmalar sayı olarak azdır ve genelde küçük bölgelerle sınırlıdır. Bölgesel çapta toplanmış standart verinin varlığı nedeniyle, Güneydoğu Anadolu Bölgesindeki araştırmanın sonuçları bu tez kapsamında kullanılmıştır.

### **2.3.1. Girdi Verileri Hakkında Detaylı Bilgiler**

Yukarıdaki bölümde belirtildiği üzere tez çalışmasında modele girdi olarak sunulan veriler 12 ayrı çevresel faktör değerinden oluşmaktadırlar. Bu verilerin yarısı uydu görüntülerinden elde edilmiştir. 7 ayrı bant değerinden oluşan uydu görüntülerinden 30x30 metre çözünürlükteki 6 tanesi tez çalışmaları kapsamında kullanılmıştır (Tablo 2.1). Uydu görüntüleri ve diğer çevresel faktör değerleri Türkiye Doğal Hayatı Koruma Derneğinden elde edilmiştir. Çevresel faktörlerle ilgili detaylar şöyledir:

*1 – 6 Uzaktan algılama verileri:* Uydu görüntülerinden elde edilen 6 ayrı banttaki nümerik değerler ham veri olarak doğrudan modele girilmiştir. Uzaktan algılama verisi

değerlerinin her birisi ayrı bir parametreyi ölçmektedir. Bu parametrelerin açıklamaları Tablo 2.2 de belirtilmiştir.

7 – *Yükseklik*: Her bir noktanın metre cinsinden yükseklik değeri.

8 – *Yola olan uzaklık*: Her bir noktanın en yakın otoyola uzaklığının metre cinsinden değeri.

9 – *Suya olan uzaklık*: Her bir noktanın en yakın su gövdesine (baraj, göl, nehir, vb.) olan uzaklığının metre cinsinden değeri.

10 – *Vejetasyon sınıflandırması*: Proje kapsamında Türkiye Doğal Hayatı Koruma Derneğinin yaptığı sınıflandırmalardan elde edilen değerler. Bu değerler tez kapsamında yeniden değerlendirilerek vejetasyon gruplarının numaraları değiştirilmiş ve en kısa boylu vejetasyon 1 en yüksek boylu vejetasyon 9 olacak şekilde numaralandırılmış ve böylece vejetasyon sınıflandırmasına doğrusallık kazandırılmıştır.

11 – *Nispi nem*: Meteoroloji Genel Müdürlüğü tarafından ölçülen yıllık ortalama nem değeri.

12 – *Sıcaklık*: Meteoroloji Genel Müdürlüğü tarafından ölçülen yıllık ortalama sıcaklık değeri.

Tez kapsamında kullanılan diğer çevresel faktörlerle ilgili bilgiler Tablo 2.3’de, bu faktörlerden Güneydoğu Anadolu Bölgesi vejetasyon sınıflandırması gruplarına ait detaylar ayrıca Tablo 2.4’de verilmiştir.

Tablo 2.1 : Çalışma kapsamında kullanılan uydu verilerinin kaynağı ve verilerin yılları.

| Uydu      | Görüntü Kodu      | Tarih        |
|-----------|-------------------|--------------|
| LandSat 7 | 171-34-02-08-1999 | 1999 Ağustos |
| LandSat 7 | 172-34-24-06-2000 | 2000 Haziran |
| LandSat 5 | 172-33-16-06-2000 | 2000 Haziran |
| LandSat 7 | 174-34-0-07-2000  | 2000 Temmuz  |
| LandSat 7 | 170-34-13-06-2001 | 2001 Haziran |
| LandSat 7 | 171-33-04-06-2001 | 2001 Haziran |
| LandSat 7 | 172-33-17-07-2001 | 2001 Temmuz  |
| LandSat 7 | 173-34-20-07-2001 | 2001 Temmuz  |

Tablo 2.2 : Uydu Görüntülerindeki 6 ayrı bant değerinin tanımları ve özellikleri (Per, 2003).

| Bant | Dalgaboyu<br>(milimetre) | Tanımlama                | Çözünürlülük<br>(metre) | Yorumlar                                                                                                                                                                                                               |
|------|--------------------------|--------------------------|-------------------------|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| TM1  | 0,45 – 0,52              | Mavi                     | 30                      | Vejetasyon ve toprak arasındaki farklılıkları algılar. Su, göl, deniz, şehir, orman ve tarım arazi haritalarının yapılmasında kullanılır                                                                               |
| TM2  | 0,52 – 0,60              | Yeşil                    | 30                      | Vejetasyonun sağlıklılığını gösterir.                                                                                                                                                                                  |
| TM3  | 0,63 – 0,69              | Kırmızı                  | 30                      | Bitki türleri arasındaki farklara duyarlıdır.                                                                                                                                                                          |
| TM4  | 0,76 – 0,90              | Yansıtıcı kızıl<br>ötesi | 30                      | Tarım ürünü ve vejetasyon tiplerine hassastır. Biomas (canlı kütlesi) ve ürün verecek olan tarım arazilerini haritalamak için uygundur. Toprak ile ürün veya su ile sert zemin bu bantta birbirinden ayırt edilebilir. |
| TM5  | 1,55 – 1,75              | Orta-kızıl<br>ötesi      | 30                      | Bitkilerdeki su içeriğine duyarlıdır. Kuraklık tanımlamalarında kullanılır. Kuru bir yer ile ıslak bir yerin ayrımı yapılarak burada ne kadar su olduğunu tanımlayabilir.                                              |
| TM7  | 2,08 – 2,35              | Orta-kızıl<br>ötesi      | 30                      | Jeolojik kullanım amaçlıdır. Toprak yapısındaki değişikliklere duyarlı, kaya ve jeolojik yapıları haritalamak için uygundur.                                                                                           |

Tablo 2.3 : Tüm çevresel faktör verilerinin açıklamaları (Uydu görüntüsü bant değerleri hariç)

| Veri Adı                   | Açıklama                                                                                                       | Kaynak |
|----------------------------|----------------------------------------------------------------------------------------------------------------|--------|
| Yükseklik                  | Her bir noktanın irtifası                                                                                      | GAP    |
| Yola olan uzaklık          | Her bir noktanın en yakın ana yola olan uzaklığı                                                               | GAP    |
| Suya olan uzaklık          | Her bir noktanın en yakın su yüzeyine uzaklığı<br>(dere, nehir, göl, baraj)                                    | GAP    |
| Vejetasyon sınıflandırması | Her bir noktanın Güneydoğu Anadolu Bölgesi<br>vejetasyon sınıflandırması kapsamında hangi<br>bölgede bulunduğu | DHKD   |
| Nispi nem                  | Yıllık ortalama nem                                                                                            | GAP    |
| Sıcaklık                   | Yıllık ortalama sıcaklık                                                                                       | GAP    |

Tablo 2.4 : Güneydoğu Anadolu Bölgesi vejetasyon sınıflandırması grupları (Welch, 2004)

| Sınıflandırma grubu | Vejetasyon grubu           |
|---------------------|----------------------------|
| 1                   | Çıplak Alan                |
| 2                   | Çayır                      |
| 3                   | Yastıksı çalı              |
| 4                   | Tarım alanı                |
| 5                   | Doğu Anadolu meşe çalılığı |
| 6                   | Kermes meşesi              |
| 7                   | Fıstık ve meyve bahçesi    |
| 8                   | Kızılçam ormanı            |
| 9                   | Galeri ormanı              |

### 3. MALZEME VE YÖNTEM

#### 3.1. VERİLER

Çalışma kapsamındaki ilk adım Güneydoğu Anadolu Bölgesinde yapılan araştırmanın sonucunda her bir kuş türünün kaç ayrı noktada ürediğinin belirlenmesi olmuştur. Modellemenin yapılacağı kuşların seçilmesinde ilk olarak diğerlerine göre çok daha yaygın olarak üreyen kuşlar dikkate alınmıştır. Bunun nedeni YNA eğitiminin başarılı şekilde yapılabilmesi için kullanılacak veri sayısının yeterli düzeyde olması gerekliliğidir. Verilerin az olması durumunda bir önceki bölümde anlatıldığı gibi aşırı uyumlaşma çok çabuk biçimde gerçekleşecek ve modelin başarısı düşecektir. Tür seçiminde aynı zamanda türlerin çok yaygın ve fırsatçı türlerden olmamasına da dikkat edilmiştir. Özellikle şehirler, köyler, tarım alanları gibi bir çok alanda üreyebilecek fırsatçı türlerin eldeki çevresel faktör verileriyle tanınmasının olası güçlüğünden kaçınılmıştır (ev serçesi *Passer domesticus* (Linnaeus, 1758) ya da kumru *Streptopelia decaocto* (Frisvaldszky, 1838) gibi). Bu yaklaşımın sonucunda kızıl başlı örümcekkuşu *Lanius senator* (Linnaeus, 1758) (Şekil 3.1), bozkır toygarı *Calandrella brachydactyla* (Leisler, 1814) (Şekil 3.2) ve ak mukallit *Hippolais pallida* (Ehrenberg, 1833) (Şekil 3.2) türleri çalışmada modellerin üretilmesi için seçilmiştir.



Kızıl başlı örümcekkuşu, Kazım Çapacı

Şekil 3.1 – Kızıl başlı örümcekkuşu



Ak mukallit, Okan Bilge



Bozkır toygarı, Okan Bilge

Şekil 3.2 – Ak mukallit ve bozkır toygarı

### 3.2. VERİLERİN İŞLENMESİ

Bir sonraki adımda, her bir türün ürettiği nokta sayısı kadar üremediği noktaya ait bilgiler de rasgele seçilerek eldeki veri kümelerine eklenmiştir. Böylece modele girilecek veri kümeleri oluşturulmuştur. Örnek olarak, 243 noktada üremekte olan ak mukallit veri kümesine 243 adet üremediği nokta eklenmiştir. Bu eklemedeki amaç programa girilecek veri setinde üreme ve ürememe noktalarının sayısını eşitlemektir. Eldeki verilerin tümünün programa girilmesi durumunda 243 nokta üreme kaydı bulunan ak mukallit setinde 1349 adet ürememe noktası bulunacaktı (toplamda 1592 bulunmakta) ve YNA eğitimi kapsamında modelin ürememeye olan eğilimi artacaktı. Bundan dolayı verilerin eşitlenmesine her bir tür için dikkat edilmiştir.

Her bir tür için veri kümelerinin belirlenmesinin ardından her bir nokta için 12 ayrı çevresel faktör verisi bir Microsoft Excel dosyasında toplanmış ve NevProp3 programına yüklenecek veri seti son halini almıştır.

### 3.3. MODELLEME

Çalışma kapsamında YNA modellerinin üretilmesi için NevProp3 isimli bilgisayar programı kullanılmıştır (Goodman, 1996) ve tüm işlemler 256 RAM ve Pentium III işlemci içeren bilgisayar kullanılarak gerçekleştirilmiştir.

Hazırlanan veri seti NevProp3 programına girilmek üzere bir \*.NET uzantılı metin dosyası içerisinde depolanmıştır (Ek 2). Her bir model için \*.NET dosyasında belirtilen ve NevProp3'e verilen komutlar aynıdır. Tüm türler için düzeltilmiş c-indekslerinin belirlenmesi amacıyla 150 tekrar yükleme yapılmıştır. Bunun yanında eğitim sırasında verilerin bir kısmının kenarda tutulmasıyla oluşturulan doğrulama kümesinin tüm datanın %40'lık bölümünden oluşması için NevProp3'e girilen \*.NET dosyasındaki "HoldOutSet" komutu 40 olarak belirlenmiştir (Ek 2).

NevProp3'e yapması gerektiği işleri anlatan \*.NET dosyasının oluşturulmasının ardından rasgele sayı üreten bir programdan modellemelerin başında NevProp3'e girilen ve ilk ağırlıkların belirlenmesinde kullanılan üç ayrı dört basamaklı başlangıç tohumu belirlenmiştir. Bu üç sayı her bir tür için yapılan modellemelerde kullanılmış ve modelin belirlenmesi süreci her bir tür için 3 ayrı kez tekrarlanmıştır. Tüm türler için modelin en iyi performansı her bir başlangıç tohumu için düzeltilmiş c-indekslerine bakılarak belirlenmiştir. Bununla birlikte YNA'ların hangi model yapısında daha iyi sonuç verdiğini görebilmek için her bir tür için değişik model yapıları tek tek belirlenmiştir. Öncelikle gizli katmandaki nod sayısı 12 olacak şekilde 3 ayrı başlangıç tohumu için tüm model yapıları denenmiştir. Bu eğitimlerin ardından her bir yapı ve tohum için düzeltilmiş c-indeksleri kaydedilmiştir. Ardından aynı işlem YNA'nın gizli katmanında 11 nod bırakılarak denenmiş ve düzeltilmiş c-indeksleri her bir başlangıç tohumu değeri için kaydedilmiştir. Bu işlem gizli katmanda 10, 9, 8, 7, 6, 5, 4, 3, 2 ve 0 nod bırakılarak tekrar edilmiştir. Gizli katmanda 1 nod bırakmakla 0 nod bırakmak arasında bir yapısal fark olmadığından 1 nodlu model yapısı denenmemiştir. Bununla birlikte 0 nodlu yapıda, yani gizli katmanda nod bulunmayan yapıda, girdi katmanındaki nodlar doğrudan çıktı katmanına bağlanmıştır. Gizli katmanda nod bulundurmeyen YNA'lar doğrudan genel doğrusal regresyon modelini oluşturmaktadır. Bu da bize tez kapsamında YNA'yı her bir tür için genel doğrusal modellerle karşılaştırma fırsatını vermiştir (bkz. Tartışma ve Sonuç bölümü).

Sonuçta her bir tür için 12 ayrı YNA model yapısı 3 ayrı başlangıç tohumuyla NevProp3'te eğitilmiştir. Her bir tür için 36 farklı eğitimin düzeltilmiş c-indekslerine bakılarak en iyi YNA model yapısı her bir tür için kararlaştırılmıştır (Bkz. Bulgular Bölümü).

### 3.4. MODEL SONUÇLARININ ANALİZ YÖNTEMİ

Her bir tür için ideal modelin bulunmasının ardından çevresel faktörlerin sonucu nasıl etkilediklerini belirlemek üzerine 3 ayrı çalışma yapılmıştır: Sinirsel Yorumlama Diyagramları, Girdi İlişkilendirme Tabloları ve Duyarlılık Analizleri.


Sinirsel Yorumlama Diyagramları ideal modeldeki ağırlıklar dikkate alınarak belirlenmektedir. Bir önceki bölümde YNA'ların yapıları anlatılırken belirtildiği gibi YNA'larda her bir noddan diğerine olan bağlantılar ağırlıklarla çarpılarak yapılmakta ve bu ağırlığın rakamsal büyüklüğü o çevresel faktörün sonuca olan etkisinin de büyük olduğu şeklinde yorumlanmaktaydı. Bu kapsamda her bir tür için Sinirsel Yorumlama Diyagramları çizilmiş ve Bulgular Bölümünde ilgili diyagramlar sunulmuştur. Sinirsel Yorumlama Diyagramlarına benzer bir mantıkla NevProp3 tarafından doğrudan üretilen Girdi İlişkilendirme Tabloları da aynı bölümde işlenmiştir.

Diğer bir yöntem olarak değerlendirilen Duyarlılık Analizi yine her bir çevresel faktörün incelenmesiyle gerçekleştirilmiştir. Bunun için ilk olarak 12 ayrı çevresel faktör için tüm noktalardaki değerlerden oluşan Excel dosyasından ayrı bir ortalama değer dosyası oluşturulmuştur. Bu kapsamda her bir çevresel faktör için tüm noktalardaki değerlerin aritmetik ortalaması alınmıştır. Tüm çevresel faktörler için tekrarlanan bu işlemten sonra sadece ortalama değerlerden oluşan bir veri seti elde edilmiştir. Bunu takiben her bir çevresel faktörün duyarlılık analizi için o faktörün maksimum ve minimum değerleri arasında bir dağılım yapılarak tüm noktalardaki değerler eşit bir oranda dağıtılmıştır. Bununla birlikte diğer tüm çevresel faktör değerleri ortalama değerlerde sabit tutulmuştur. Bu yeni veri seti ideal modele girilerek o çevresel faktördeki maksimum ve minimum değerler arasında modelin sonucunun nasıl değiştiği NevProp3 çalıştırılarak takip edilmiştir. Bu kapsamda duyarlılık grafikleri her bir tür için o türü etkileyen tüm çevresel faktörler kapsamında verilmiştir. Duyarlılık analizi her bir faktörün göreceli etkisini tahmin eden Sinirsel Yorumlandırma Diyagramları ve Girdi İlişkilendirmelerine nispeten her bir çevresel faktördeki değişikliğin üreme ihtimalini nasıl etkilediğini ölçmektedir. Bu anlamda Duyarlılık Analizleri ve diğer iki yöntem birbirlerini tamamlamaktadırlar.

## 4. BULGULAR

### 4.1. KIZIL BAŞLI ÖRÜMCEKKUŞU *Lanius senator* (Linnaeus, 1758) MODELİ

Güneydoğu Anadolu Bölgesinde yapılan araştırmalarda kızıl başlı örümcekkuşunun 274 ayrı noktada ürediği tespit edilmiştir. Model kapsamında değerlendirilen bu noktalara çalışmanın yapıldığı ve türün üremediği diğer noktalardan 274 tanesi daha rasgele seçilerek eklenmiş ve modelleme için kullanılacak 548 nokta belirlenmiştir. Bu 548 ayrı noktadan ve her bir noktadaki 12 çevresel faktör değerinden oluşan eğitim verileri NevProp3'e aktarılmıştır. 9017, 3492, ve 5964 rakamlarından oluşan başlangıç tohumları ayrı ayrı denenmiş ve her bir tohumla 0 – 12 arası gizli katman nodu kullanılarak 12 ayrı modelleme eğitimi yapılmıştır (1 gizli nodu 0 gizli nodla yapılacak olan denemeye aynı mantıkta olduğundan kullanılmamıştır). Tüm bu eğitimlerin ardından düzeltilmiş c-indeksleri hesaplanmıştır. Elde edilen bütün değerler ve her bir model yapısındaki 3 ayrı düzeltilmiş c-indeksin ortalaması grafiğe işlenerek en ideal model belirlenmiştir (Şekil 4.1).




Şekil 4.1 : Kızıl başlı örümcekkuşu için düzeltilmiş c-indekslerinin her bir başlangıç tohumu ve ortalama değerleri açısından kıyaslanması. X koordinatı YNA modeli gizli katmanındaki nod sayısını, Y koordinatı düzeltilmiş c-indeksi değerini göstermektedir.

Şekil 4.1'e bakılarak tüm değerlerin ortalamasının 8 nodlu gizli katman yapılı YNA modelinde en yüksek olduğu görülmektedir. 8 gizli nodlu YNA'nın tüm veriler ışığında en ideal model yapısını içerdiği ve bu yapıdaki her bir başlangıç tohumunun ortaya çıkardığı sonuçlara bakılarak 9017 tohumu ile elde edilen sonucun en yüksek üreme ihtimali tahminini gerçekleştirdiği görülmüştür. Sonuç olarak ideal model için 9017 başlangıç tohumunun belirlediği başlangıç ağırlıklarıyla oluşturulan 8 gizli katmanlı YNA modeli kızıl başlı örümcekkuşu için en ideal model olarak belirlenmiştir. İdeal modelde 12 girdi nodu, 8 gizli katman nodu ve 1 çıktı nodu bulunmaktadır. Bu model kapsamında kızıl başlı örümcekkuşunun üremesine etki edecek 104 bağlantı bulunduğu belirlenmiştir.

Modelin c-indeksi 0,935 ve düzeltilmiş c-indeksi 0,891 olarak belirlenmiştir. Başka bir deyişle kızıl başlı örümcekkuşu Modeli her 100 olaydan 93,5 tanesini başarıyla tahmin edebilmektedir. Bunun yanında aynı modelin 150 defa tekrar yükleme yapılarak tekrarlanması ardından en kötü ihtimalle her 100 olaydan 89,1 tanesini doğru tahmin ettiği belirlenmiştir. Yani model % 90 oranında bir başarı elde etmektedir.

#### 4.1.1. Sinirsel Yorumlama Diyagramları


Kızıl başlı örümcekkuşu için çevresel faktörlerden her birinin sonuca etkisinin ölçüldüğü Sinirsel Yorumlama Diyagramları Şekil 4.2, Şekil 4.3, Şekil 4.4. ve Şekil 4.5’de verilmiştir. Şekiller, ideal modeldeki her bir bağlantının (toplamda 104 bağlantı bulunmakta) ağırlığına bakılarak üretilmiştir. Şekiller tek bir grafik üzerinde çok karışık olacağından bölünerek ayrı olarak verilmiştir.




Şekil 4.2 : Kızıl başlı örümcekkuşu için Sinirsel Yorumlandırma Diyagramları: TM1, TM2, TM3 ve TM4 faktörlerinin gizli katmandaki nodlara etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.

Modeldeki her bir bağlantı, şekilde ağırlığın büyüklüğüne göre kalın çizgiler kullanılarak gösterilmiştir. Bununla birlikte pozitif (+) katsayılı ağırlıklar siyah renkle negatif (-) katsayılı ağırlıklar gri renkte gösterilmiştir. Bağlantı çizgilerindeki kalınlık o bağlantının ulaştığı noddaki etkisinin güçlü olduğunu göstermekte, benzer şekilde incelik de o bağlantının ulaştığı noddaki etkisinin güçsüz olduğunu göstermektedir. Sinirsel Yorumlama Diyagramlarının yanı sıra NevProp3 tarafından doğrudan yapılan


Girdi İlişkilendirme Hesaplamaları da Tablo 4.1’de verilmiştir. Girdi İlişkilendirmesi, YNA modelinin girdi katmanındaki nodların çıktı katmanındaki nod üzerinde ne kadar etkili olduğunu yüzde olarak belirler. Bu işlem Sinirsel Yorumlama Diyagramlarındaki mantıkla paralel olarak her bir bağlantının ağırlığı baz alınarak hesaplanmaktadır.



Şekil 4.3 : Kızıl başlı örümcekkuşu için Sinirsel Yorumlandırma Diyagramları: TM5, TM7, yükseklik ve yola olan uzaklık faktörlerinin gizli katmandaki nodlara etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.



Şekil 4.4 : Kızıl başlı örümcekkuşu için Sinirsel Yorumlandırma Diyagramları: Vejetasyon sınıflandırma, suya olan uzaklık, nispi nem ve sıcaklık faktörlerinin gizli katmandaki nodlara etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.




Şekil 4.5 : Kızıl başlı örümcekkuşu için Sinirsel Yorumlandırma Diyagramları: gizli katmandaki nodların çıktı katmanındaki noda etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.

Tablo 4.1 : Kızıl başlı örümcekkuşu YNA modelinde çevresel faktörlerin sonuca (üreme ihtimali) yüzde olarak etkileri: Girdi İlişkilendirme.

| Çevresel Faktör                | Üreme ihtimaline yüzde olarak etkisi |
|--------------------------------|--------------------------------------|
| TM1                            | 2,56%                                |
| TM2                            | 0,78%                                |
| TM3                            | 0,87%                                |
| TM4                            | 5,49%                                |
| TM5                            | 3,14%                                |
| TM7                            | 2,19%                                |
| Yükseklik                      | 4,82%                                |
| En yakın otoyola uzaklık       | 6,01%                                |
| Vejetasyon sınıflandırma grubu | 6,23%                                |
| Suya olan uzaklık              | 11,09%                               |
| Nispi nem                      | 52,17%                               |
| Sıcaklık                       | 4,64%                                |

#### 4.1.2. Duyarlılık Analizi

Çevresel faktörlerin kızıl başlı örümcekkuşunda üremeye nasıl etki ettiklerini ölçen başka bir yöntem de duyarlılık analizidir. Duyarlılık Analizi her bir faktörün göreceli etkisini tahmin eden Sinirsel Yorumlandırma Diyagramları ve Girdi İlişkilendirme Tablolarına nispeten her bir çevresel faktördeki değişikliğin, üreme ihtimalini nasıl etkilediğini ölçmektedir. Bu anlamda Duyarlılık Analizleri diğer iki yöntemin tamamlayıcı unsurudur. Yöntemin detayları Malzeme ve Metod bölümünde verilmiştir. Bu yaklaşımla her bir çevresel faktör için hazırlanan test verileri ideal modelde işlenerek her bir çevresel faktörde maksimum ve minimum değerler arasında sonuçların nasıl değiştiği izlenmiştir. Kızıl başlı örümcekkuşu için yapılan duyarlılık analizi sonuçları Şekil 4.3’de verilmiştir.



Şekil 4.6 : Kızıl başlı örümcekkuşu için duyarlılık analizleri sonuçları. X eksenini her bir faktörün aldığı değerleri Y eksenini üreme ihtimalini göstermektedir.


Kızıl Başlı Örümcekkuşu YNA Modelinin hem Sinirsel Yorumlama Diyagramları hem de Girdi İlişkilendirme Tabloları benzer sonuçlar üretmiştir. Her ikisinden de elde edilen sonuçlara göre üreme ihtimaline en büyük etkiyi nispi nem çevresel faktörü

oluşturmaktadır. Nispi nemin sonuca olan etkisini sırasıyla suya olan uzaklık, vejetasyon sınıflandırma grubu ve en yakın otoyola olan uzaklık çevresel faktörleri takip etmektedir (Tablo 4.1).

Kızıl başlı örümcekkuşu nispi nem duyarlılık analizinde nemin artmasıyla birlikte türün üreme ihtimalinin de düştüğü görülmektedir (Şekil 4.6). Suyu uzaklık arttıkça üreme ihtimali de doğru orantılı olarak artmaktadır. Vejetasyon sınıflandırmasına bakıldığında vejetasyon yapısının boyu arttıkça kızıl başlı örümcekkuşunun üreme ihtimalinin düştüğü görülmektedir. Son olarak otoyola uzaklığa bakıldığında grafikte çok büyük oynamalar olmasa da otoyola yakın bölgelerde üreme ihtimalinin arttığı görülmektedir.

#### **4.2. AK MUKALLİT *Hippolais pallida* (Ehrenberg, 1833) MODELİ**

Güneydoğu Anadolu Bölgesinde yapılan araştırmalarda ak mukallidin 245 ayrı noktada ürediği tespit edilmiştir. Kızıl başlı örümcekkuşu modeline benzer şekilde, bu üreme noktalarına, çalışmanın yapıldığı ve türün üremediği diğer noktalardan 245 tanesi daha rasgele seçilerek eklenmiş ve modelleme için kullanılacak 490 ayrı noktadan ve her bir noktadaki 12 çevresel faktör değerinden oluşan eğitim verileri NevProp3'e aktarılmıştır. 9017, 3492, ve 5964 rakamlarından oluşan başlangıç tohumları ayrı ayrı denenmiş ve her bir tohumla 0 – 12 arası gizli katman nodu kullanılarak 12 ayrı modelleme eğitimi yapılmıştır. Tüm bu eğitimlerin ardından düzeltilmiş c-indeksleri hesaplanmıştır. Tüm bu değerler ve her bir model yapısındaki 3 ayrı düzeltilmiş c-indeksinin ortalaması grafiğe işlenerek en ideal model belirlenmiştir (Şekil 4.7).




Şekil 4.7 : Ak mukallit için düzeltilmiş c-indekslerinin her bir başlangıç tohumu ve ortalama değerleri açısından kıyaslanması. X koordinatı YNA modeli gizli katmanındaki nod sayısını, Y koordinatı düzeltilmiş c-indeksi değerini göstermektedir.

Şekil 4.6'ya bakılarak tüm değerlerin ortalamasının 3 nodlu gizli katman yapılı YNA modelinde en yüksek olduğu görülmektedir. 3 gizli nodlu YNA'nın tüm veriler ışığında en ideal model yapısını içerdiği ve bu yapıdaki her bir başlangıç tohumunun ortaya çıkardığı sonuçlara bakılarak 9017 tohumu ile elde edilen sonucun diğerleri arasında en ideali olduğu görülmüştür. 9017 başlangıç tohumunun belirlediği başlangıç ağırlıklarıyla oluşturulan 3 gizli katmanlı YNA modeli kıvılcık başlı örümcekkuşu için en ideal model olarak belirlenmiştir. İdeal modelde 12 girdi nodu, 3 gizli katman nodu ve bir çıktı nodu bulunmaktadır. Bu model kapsamında kıvılcık başlı örümcekkuşunun üremesine etki edecek 39 bağlantı bulunduğu belirlenmiştir.


Ak mukallit için ideal modeldeki c-indeksi 0,792, düzeltilmiş c-indeksi de 0,752 olarak hesaplanmıştır. Ak Mukallit Modeli her 100 olaydan 79,2 tanesini başarıyla sınıflandırabilmektedir. 150 ayrı tekrar yükleme ardından belirlenen düzeltilmiş c-indeksine göre de model bütün hata payları göz önünde alınarak en kötü ihtimalle her 100 olaydan 75,2 tanesini başarıyla tahmin edebilmektedir.

#### 4.2.1. Sinirsel Yorumlama Diyagramları


Ak mukallit için çevresel faktörlerden her birinin sonuca etkisinin ölçüldüğü Sinirsel Yorumlama Diyagramları Şekil 4.8, Şekil 4.9, Şekil 4.10,. ve Şekil 4.11’de verilmiştir. Şekillerdeki özellikler yukarıdaki bölümde kızıl başlı örümcekkuşu için anlatılan özelliklerin aynısıdır. Yine benzer şekilde Sinirsel Yorumlama Diyagramlarının yanı sıra NevProp3 tarafından doğrudan yapılan Girdi İlişkilendirme Hesaplamaları da Tablo 4.2’de verilmiştir.




Şekil 4.8 : Ak mukallit için Sinirsel Yorumlandırma Diyagramları: TM1, TM2, TM3 ve TM4 faktörlerinin gizli katmandaki nodlara etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.



Şekil 4.9 : Ak mukallit için Sinirsel Yorumlandırma Diyagramları: TM5, TM7, yükseklik ve yola olan uzaklık faktörlerinin gizli katmandaki nodlara etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.



Şekil 4.10 : Ak mukallit için Sinirsel Yorumlandırma Diyagramları: Vejetasyon sınıflandırması, suya olan uzaklık, nispi nem ve sıcaklık faktörlerinin gizli katmandaki nodlara etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.




Şekil 4.11 : Ak mukallit için Sinirsel Yorumlandırma Diyagramları: gizli katmandaki nodların çıktı katmanındaki noda etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.

Tablo 4.2 : Ak mukallit YNA modelinde çevresel faktörlerin sonuca (üreme ihtimali) yüzde olarak etkileri: Girdi ilişkilendirme.

| Çevresel Faktör                | Üreme ihtimaline yüzde olarak etkisi |
|--------------------------------|--------------------------------------|
| TM1                            | 6,72%                                |
| TM2                            | 0,16%                                |
| TM3                            | 0,06%                                |
| TM4                            | 6,06%                                |
| TM5                            | 0,01%                                |
| TM7                            | 0,40%                                |
| Yükseklik                      | 5,71%                                |
| En yakın otoyola uzaklık       | 1,27%                                |
| Vejetasyon sınıflandırma grubu | 10,32%                               |
| Suya olan uzaklık              | 68,80%                               |
| Nispi nem                      | 0,11%                                |
| Sıcaklık                       | 0,38%                                |

#### 4.2.2. Duyarlılık Analizi




Şekil 4.12 : Ak mukallit için duyarlılık analizleri sonuçları. X ekseni her bir faktörün aldığı değerleri Y ekseni üreme ihtimalini göstermektedir.

Ak Mukallit YNA Modelinin hem Sinirsel Yorumlama Diyagramında hem de Girdi İlişkilendirme Tablolarında birbirine benzer sonuçlar üretmiştir. Her ikisinden de elde edilen sonuçlara göre üreme ihtimaline en büyük etkiyi suya olan uzaklık faktörü oluşturmaktadır. Suya olan uzaklık faktörünü vejetasyon sınıflandırma grubu faktörü , TM1 ve TM4 faktörleri takip etmektedir.

Ak mukallit için suya olan uzaklık duyarlılık analizi grafiğine bakıldığında türün suya olan yüksek bağlılığı görülmektedir. Sudan uzaklaşıldıkça üreme ihtimali hızlı bir şekilde azalmaktadır. Bunun yanında vejetasyon sınıflandırma grubu faktörünün duyarlılık analizine bakıldığında vejetasyon boyunun artmasıyla üreme ihtimali de doğru orantılı olarak ama yavaş bir eğimle arttığı görülmektedir.

#### **4.3. BOZKIR TOYGARI *Calandrella brachydactyla* (Leisler, 1814) MODELİ**

Güneydoğu Anadolu Bölgesinde yapılan araştırmalarda bozkır toygarının 294 ayrı noktada ürediği tespit edilmiştir. Diğer türlerin modellemelerine paralel şekilde bu noktalara çalışmanın yapıldığı ve türün üremediği diğer noktalardan 294 tanesi daha rasgele seçilerek eklenmiş ve modelleme için kullanılacak 588 ayrı noktadan ve her bir noktadaki 12 çevresel faktör değerinden oluşan eğitim verileri NevProp3'e aktarılmıştır. 9017, 3492, ve 5964 rakamlarından oluşan başlangıç tohumları ayrı ayrı denenmiş ve her bir tohumla 0 – 12 arası gizli katman nodu kullanılarak 12 ayrı modelleme eğitimi yapılmıştır. Tüm bu eğitimlerin ardından düzeltilmiş c-indeksleri hesaplanmıştır. Tüm bu değerler ve her bir model yapısındaki 3 ayrı düzeltilmiş c-indeksinin ortalaması grafiğe işlenerek en ideal model belirlenmiştir (Şekil 4.13).




Şekil 4.13: Bozkır toygari için düzeltilmiş c-indekslerinin her bir başlangıç tohumu ve ortalama değerleri açısından kıyaslanması. X koordinatı YNA modeli gizli katmanındaki nod sayısını, Y koordinatı düzeltilmiş c-indeksi değerini göstermektedir.

Şekil 4.13'e bakılarak tüm değerlerin ortalamasının 10 nodlu gizli katman yapılı YNA modelinde en yüksek olduğu görülmektedir. 10 gizli nodlu YNA'nın tüm veriler ışığında en ideal model yapısını içerdiği ve bu yapıdaki her bir başlangıç tohumunun ortaya çıkardığı sonuçlara bakılarak 5964 tohumu ile elde edilen sonucun en ideali olduğu görülmüştür. Sonuç olarak ideal model için 5964 başlangıç tohumunun belirlediği başlangıç ağırlıklarıyla oluşturulan 10 gizli katmanlı YNA modeli kızıl başlı örümcekkuşu için en ideal model olarak belirlenmiştir. İdeal modelde 12 girdi nodu, 10 gizli katman nodu ve bir çıktı nodu bulunmaktadır. Bu model kapsamında kızıl başlı örümcekkuşunun üremesine etki edecek 130 bağlantı bulunduğu belirlenmiştir.


Bozkır toygari için c-indeksi 0,930 düzeltilmiş c-indeksi de 0,884 olarak hesaplanmıştır. Bozkır Toygari YNA Modeli her 100 üremeden 93 tanesini başarıyla tahmin edebilmektedir. 150 tekrar yükleme ardından bulunan tüm sonuçlarda modelin en kötü ihtimalle her 100 olaydan 88,4 tanesini başarıyla tahmin ettiği görülmüştür.

#### 4.3.1. Sinirsel Yorumlama Diyagramları


Bozkır toygarı için çevresel faktörlerden her birinin sonuca etkisinin ölçüldüğü Sinirsel Yorumlama Diyagramları Şekil 4.14, Şekil 4.15, Şekil 4.16,. ve Şekil 4.17’de verilmiştir. Şekillerdeki özellikler yukarıdaki bölümde kızıl başlı örümcekkuşu için anlatılan özelliklerin aynısıdır. Yine benzer şekilde Sinirsel Yorumlama Diyagramlarının yanı sıra NevProp3 tarafından doğrudan yapılan Girdi İlişkilendirme Hesaplamaları da Tablo 4.3’te verilmiştir.




Şekil 4.14 : Bozkır toygarı için Sinirsel Yorumlandırma Diyagramları: TM1, TM2, TM3 ve TM4 faktörlerinin gizli katmandaki nodlara etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.



Şekil 4.15 : Bozkır toygarı için Sinirsel Yorumlandırma Diyagramları: TM5, TM7, yükseklik ve yola olan uzaklık faktörlerinin gizli katmandaki nodlara etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.



Şekil 4.16 : Bozkır toygarı için Sinirsel Yorumlandırma Diyagramları: Vejetasyon sınıflandırması, suya olan uzaklık, nispi nem ve sıcaklık faktörlerinin gizli katmandaki nodlara etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.




Şekil 4.17 : Bozkır toygarı için Sinirsel Yorumlandırma Diyagramları: gizli katmandaki nodların çıktı katmanındaki noda etkileri. Siyah renkler pozitif (+) katsayıları gri renkler negatif (-) katsayıları işaret etmektedir. Çizgilerin kalınlığı katsayının büyüklüğünü göstermektedir.

Tablo 4.3 : Bozkır toygarı YNA modelinde çevresel faktörlerin sonuca (üreme ihtimali) yüzde olarak etkileri: Girdi İlişkilendirme.

| Çevresel Faktör                | Üreme ihtimaline yüzde olarak etkisi |
|--------------------------------|--------------------------------------|
| TM1                            | 2,36%                                |
| TM2                            | 0,06%                                |
| TM3                            | 6,09%                                |
| TM4                            | 2,12%                                |
| TM5                            | 0,15%                                |
| TM7                            | 0,85%                                |
| Yükseklik                      | 2,15%                                |
| En yakın otoyola uzaklık       | 5,04%                                |
| Vejetasyon sınıflandırma grubu | 0,57%                                |
| Suya olan uzaklık              | 73,69%                               |
| Nispi nem                      | 4,06%                                |
| Sıcaklık                       | 2,86%                                |

### 4.3.2. Duyarlılık Analizi



Şekil 4.18 : Bozkır toygarı için duyarlılık analizleri sonuçları. X eksenı her bir faktörün aldığı değeri Y eksenı üreme ihtimalini göstermektedir.


Diğer türlere paralel şekilde Bozkır Toygarı YNA Modelinin hem Sinirsel Yorumlama Diyagramında hem de Girdi İlişkilendirme Tablolarında birbirine benzer sonuçlar üretmiştir. Her ikisinden de elde edilen sonuçlara göre üreme ihtimaline en büyük etkiyi suya olan uzaklık faktörü göstermektedir. Ancak bu etki ak mukallitte ters orantılıdır. Yani üreme ihtimali suya yaklaştıkça düşmektedir. Suyu olan uzaklık etkisi Girdi İlişkilendirme Tablolarında toplam etkinin %73,69'luk kısmına sahiptir. Bunu sırasıyla TM3, en yakın otoyola uzaklık ve nispi nem faktörleri takip etmektedir. Bozkır toygarı için suya olan uzaklık duyarlılık analizi grafiğine bakıldığında türün suya bağılılığı bir kere daha görülmektedir. 20 km'ye kadar olan uzaklıklarda üreme ihtimali düşükken uzaklık 20 km'yi geçince üreme ihtimali de bir anda artmaktadır.

## 5. TARTIŞMA VE SONUÇ

Yapay Nöron Ağları yukarıdaki bölümlerde de anlatıldığı gibi aslında biyoloji - ekoloji alanında yeni ama hızla gelişen bir modelleme yöntemidir. Özellikle doğrusal olmayan olayları tanımlama gücü YNA'ların doğrusal regresyon modellerine nazaran daha çok tercih edilmesine olanak tanımaktadır. Bu son bölümde YNA'nın doğrusal regresyon modelleriyle kıyaslaması yapılmakta, türlerin habitat seçimleri modeller ve analizler ışığında tartışılmakta ve olası pratik uygulamalar için öneriler sıralanmaktadır.

### 5.1. YAPAY NÖRON AĞLARI YÖNTEMİNİN BAŞARISI

Genel Kısımlar bölümünde YNA'ların genel doğrusal modellerden daha başarılı tahminler gerçekleştirdiğinden bahsetmiştik. Bu karşılaştırma her üç tür için bu tez kapsamında da gerçekleştirilmiştir. Modellerin belirlenmesi sürecinde gizli katmanda 0 nod bulundurularak YNA'ların yanında doğrusal regresyon modelleri de denenmiştir (Şekil 5.1). başka bir deyişle gizli katman kaldırılarak YNA'lar doğrusal modellere dönüştürülmüştür. Çalışma kapsamında çalışılan üç tür için de YNA'lar doğrusal regresyona göre daha başarılı sonuçlar doğurmuşlardır. Kısacası YNA'ların yapılarından kaynaklanan tahmin güçleri, kuşlar gibi doğrusal parametrelerle açıklanamayan canlılarda doğrusal regresyon yaklaşımlarından daha yüksektir.



Şekil 5.1 : Doğrusal regresyon ve YNA modellerinin üç tür için karşılaştırılması. Değerler düzeltilmiş c-indekslerini göstermekte. Bütün türler için YNA, doğrusal regresyon modellerine göre daha başarılı tahminler göstermekte.

Bulgular bölümünde her bir tür için yapılan duyarlılık analizleri ve Sinirsel Yorumlandırma Diyagramları YNA'ların iç çalışma yapılarını da bizlere sunmaktadır. Böylece girdi verilerinden hangilerinin sonucu nasıl etkiledikleri de ortaya konulabilmektedir. Sinirsel Yorumlandırma Grafikleri katmanlar arasındaki işleyişi grafiksel olarak ortaya koymaktadır. Doğrusal modellerde görülemeyecek etkileşimler bu diyagramlarla anlaşılabilir. Tüm faktörün gizli katmandaki her bir noda toplam etkilerinin niteliğini ve gizli katmandakilerin sonuç katmanındaki nodu nasıl etkilediği diyagramlardan görülebilmektedir. Bir faktör gizli katmandaki bir noda pozitif işaretli ve büyük bir etki yapmaktayken, başka faktörlerin aynı noda etkilerinden dolayı sonucun aslında negatif işaretli çıkabildiği diyagramlardan görülebilmektedir. Aslında tek başına değerlendirilecek olduğunda üreme ihtimalini olumlu yönde artıracak bir faktör diğer faktörlerin etkisiyle negatif sonuç doğurabilmektedir. Bu tür analizler kuş habitat seçimi bölümünde detaylandırılmıştır. Sonuç olarak YNA modellerinin hem daha başarılı tahminler yapabildiğini hem de Sinirsel Yorumlandırma Diyagramlarıyla birlikte doğrusal olmayan olayları ve etkileşimleri tanımlayabildiğini söyleyebilmekteyiz.

## 5.2. GÜNEY DOĞU ANADOLU BÖLGESİNDE KUŞ HABİTAT SEÇİMİ

### 5.2.1. Kızıl Başlı Örümcekkuşu *Lanius senator* (Linnaeus, 1758)


Kızıl başlı örümcekkuşu tipik bir Akdeniz Bölgesi kuşudur (Snow ve Perrins, 1998). Batı Palearktik'in Kuşları Ansiklopedisine göre kızıl başlı örümcekkuşu Akdeniz Bölgesi dışında yalnızca İran'a kadar uzanan dağılımıyla yarı açık alanlarda dağılmış bulunan çalimsı ağaçlıklarda, koruluk alanlarda, yaşlı meyve bahçelerinde ve parklarda üremektedir. Ayrıca Türkiye'de ötücü kuşlar üzerine yapılan en kapsamlı literatür çalışması olan Türkiye'nin Ötücü Kuşları kitabı (Roselaar, 1995) kızıl başlı örümcekkuşunun yaşam alanını ve üreme tercihlerini şöyle tanımlamaktadır:

'Yol ve tarım alanlarının kenarlarında bulunan ve geniş yapraklı ağaçların arasına serpilmiş çalimsı ağaçlarda ve çalılıklarda, açık alanlarda bulunan yaşlı ağaçlarda, yine bünyesinde açık alanlar bulunduran ve tek tük ağaçların da bulunduğu makiliklerde, eski meyve bahçelerinde, zeytinliklerde, parklarda ve ormanların kenar bölgelerinde üremekte ve Güney Doğu Anadolu Bölgesinde 500 – 1500 m yüksekliği tercih etmektedir.'

Kızıl başlı örümcekkuşu için belirlenen model baz alınarak yapılan analizlerde türün her bir çevresel faktöre nasıl ve ne kadar duyarlı olduğu belirlenmiştir. Bu analizlerden elde edilen en belirgin özellikler bu bölümde sunulmuştur. Gerek Sinirsel Yorumlandırma Diyagramları gerekse Girdi İlişkilendirme Tabloları tür için en önemli çevresel faktörlerin sırasıyla nispi nem (% 52), suya olan uzaklık (% 11), vejetasyon sınıflandırma grubu (% 6,2) ve en yakın yola olan uzaklık (% 6) olduğunu göstermektedir. Türün üreme tercihiyle nem arasında bir ters orantı bulunmaktadır. Nem arttıkça türün üreme başarısı da düşmektedir. Bu gerçek, suya olan uzaklık faktörüyle de doğrulanmaktadır. Suya olan uzaklık arttıkça üreme ihtimali de artmaktadır. Duyarlılık analizi grafikleri bu orantıları çok keskin biçimde ortaya koymaktadır (Şekil 4.6). Türün suyla arasına koyduğu bu keskin mesafeyle ilgili bilgiye literatür kaynaklarında rastlanmamıştır. Bu ters orantılı ilişki, yapay nöron ağları yöntemiyle ortaya konulmaktadır. Kızıl başlı örümcekkuşu için önemli çevresel faktörlerden birisi de vejetasyon sınıflandırma grubudur. Duyarlılık analizlerine göre vejetasyonun boyu arttıkça türün üreme ihtimali az da olsa düşmektedir. Her ne kadar ürediği bölgede

ağaçlara ya da çalimsı ağaçlara ihtiyaç duysa da kızıl başlı örümcekkuşu yaşam alanı olarak açıklık alanları yani kısa vejetasyonla kaplı alanları tercih etmektedir. Üreme bölgesini açık alanlar olarak seçen kızıl başlı örümcekkuşu için YNA modelinin bu tahmini literatür bilgilerine uyumludur. Son olarak otoyola uzaklık faktörüne bakıldığında duyarlılık analizi grafiğinde çok büyük oynamalar olmasa da otoyola yakın bölgelerde üreme ihtimalinin arttığı görülmektedir. Bu sonuç yine Türkiye'nin Ötücü Kuşları kitabında belirtilen literatür bilgileriyle paraleldir.

Tüm bu bilgilerin yanında faktörler arasındaki doğrusal olmayan ilişkileri ve etkileşimleri incelemek için Sinirsel Yorumlama Diyagramları dikkate alınmıştır. Kızıl başlı örümcekkuşunda gizli nodların sayısı fazla olduğundan bağlantıların bir kısmı budanarak Şekil 5.2'deki budanmış Sinirsel Yorumlama Diyagramı oluşturulmuştur. Bulgular bölümündekinden farklı olarak burada YNA'daki tüm nodlar gösterilmektedir. Nodlar arasındaki bağlantılar kat sayılara göre çizildiğinden katsayı oranı 3 ve bu değerden küçük olan bağlantılar şekilde ortaya çıkacak karışıklığı engellemek için budanmışlardır. Her bir girdi nodundan gizli noda giden bağlantının kalınlığının o bağlantıdaki katsayının büyüklüğüyle, renginin de bağlantının işaretiyle ilgili olduğunu hatırlayalım. Buradaki doğrusal olmama özelliği, her bir faktör için sonuç noduna yapılan bağlantının tam olarak 8 ayrı noddan geçmesiyle oluşmaktadır. Başka bir deyişle her bir gizli noddan buluşan tüm çevresel faktörler, her bir noddan farklı şekilde etkileşebilmektedir. Her bir gizli noddaki farklı etkileşmenin sonucunda da çıktı katmanındaki noddaki toplam sonuç ortaya çıkmaktadır. Bir girdi nodundan gizli noda oradan da sonuç noduna geçen toplam bağlantının etkisi aradaki iki bağlantının işaretlerinin (burada gri ve siyah renk) çarpımıyla belirlenmektedir. Şekil 5.2'de nispi nem faktörüne bakalım. Girdi nodundan üstten dördüncü gizli noda giden kalın bağlantı siyah renkliden bu gizli noddan sonuç noduna giden bağlantı gri renklidir. Yani çarpım bize negatif değer vermektedir. Nispi nemdeki artış negatif sonuç doğurmakta, başka bir deyişle tür nem artışına olumsuz tepki göstermektedir. Kızıl başlı örümcekkuşu için nemin etkisinin zaten böyle olduğunu söylemiştik. Nispi nemin diğer bağlantılarına bakıldığında sekizinci ve ikinci gizli katman nodlarında da negatif etki bulunmakta.



Şekil 5.2 : Kızıl başlı örümcekkuşu için budanmış Sinirsel Yorumlama Diyagramı. Siyah çizgiler pozitif değerli bağlantıları, gri çizgiler negatif renkli bağlantıları göstermektedir. Çizgilerin kalınlığı bağlantıdaki ağırlığın büyüklüğünü ifade etmektedir.

Benzer şekilde suya olan uzaklık faktörüne baktığımızda bu faktörün birinci ve ikinci gizli nod üzerinden yaptığı bağlantılarının çarpımının pozitif değerde olduğunu görmekteyiz. Suya olan uzaklık artıkça türün üreme ihtimali artmakta. Ancak nispi nemin de çok düşük de olsa pozitif değerde etkilediği üçüncü gizli nodda suya olan uzaklık değeri çarpımı negatif değer almakta. Diğer bir deyişle, nem artışının çok az şekilde tolere edilebildiği suya yakın bölgelerde türün üreme ihtimali bulunmaktadır. Benzer şekilde vejetasyon sınıflandırmasına bakacak olursak sınıflandırma faktörünün üç önemli bağlantısı olduğunu görmekteyiz. Sınıflandırma faktörü ikinci gizli nod dışında negatif değer almakta yani vejetasyonun uzaması halinde üreme ihtimali düşmektedir. Ancak ikinci gizli nodda bir ayrıcalık mevcut. Bu noda etki eden nispi


nem faktörüne bakıldığında bağlantının çarpım değerinin negatif işaretli olduğu görülmekte. Diğer bir deyişle nemin düşük olması şartıyla, göreceli olarak vejetasyon boyunda yükselme de kabul edilebilmektedir.

### 5.2.2. Ak Mukallit *Hippolais pallida* (Ehrenberg, 1833)

Ak mukallit Türkiye'nin en yaygın üreyen kuşlarından birisidir. Snow ve Perrins'e göre (1998) ak mukallit, bozkır alanlarındaki akarsu kenarlarında bulunan yüksek boylu çalılarda, aralıklı halde bulunan geniş yapraklı ağaçlarda, zaman zaman ibreli ağaçlarda, ılgınlarda, meyve bahçelerinde, bahçe ve parklarda üremektedir. Roselaar (1995) ak mukallidin yaşam alanını şöyle tanımlamaktadır:

'Her türlü yüksek boylu çalılarda, açık alanlarda bulunan küçük ya da iri ağaçlarda ya da açık ormanlarda, kurak vadilerde ya da kurak tepeliklerde; parklarda, bahçelerde ve su kenarlarındaki karışık çalılıklarda üremekte ve tüm Türkiye'de 0 – 1500 m yükseklik aralığını tercih etmektedir.'

Ak Mukallit YNA Modelinin hem Sinirsel Yorumlama Diyagramları hem de Girdi İlişkilendirme Tabloları birbirine benzer sonuçlar üretmiştir. Her ikisinden de elde edilen sonuçlara göre üreme ihtimaline en büyük etkiyi suya olan uzaklık faktörü oluşturmaktadır (% 68,8). Gerek Snow ve Perrins, gerekse Roselaar, türün suyla olan yakın ilişkisini belirtmiş üreme alanı seçimlerinde akarsu yakınındaki bölgelerin öneminin altını çizmişlerdir. Suyu olan uzaklık faktörünü vejetasyon sınıflandırma grubu faktörü takip etmektedir (% 10,3). Ak mukallit için suya olan uzaklık duyarlılık analizi grafiğine bakıldığında, türün suya bağlılığı bir kere daha görülmektedir. Sudan uzaklaştıkça üreme ihtimali hızlı bir şekilde azalmaktadır. Bunun yanında vejetasyon sınıflandırma grubu faktörünün duyarlılık analizine bakıldığında vejetasyon boyunun artmasıyla üreme ihtimalinin de doğru orantılı olarak ama yavaş bir eğimle arttığı görülmektedir. Bu sonuç, türün ağaçlık alanlarda üremesi ve yine ağaçlık alanlarda beslenmesinin getirisi olarak yorumlanabilir.



Şekil 5.3 : Ak mukallit Sinirsel Yorumlama Diyagramı. Siyah çizgiler pozitif değerli bağlantıları, gri çizgiler negatif renkli bağlantıları göstermektedir. Çizgilerin kalınlığı bağlantıdaki ağırlığın büyüklüğünü ifade etmektedir.

Ak mukallit için çizilen Sinirsel Yorumlama Diyagramı Şekil 5.3’de verilmiştir. Ak mukallit modeli sadece 3 gizli noddan oluştuğundan grafikte herhangi bir budama yapılmamıştır. Şekil 5.3’de tür için en önemli faktör olan suya uzaklığın her bir gizli nod üzerinden yapılan bağlantıda negatif çarpım değeri aldığı görülmektedir. Vejetasyon sınıflandırmasına bakıldığında en kalın bağlantının birinci gizli nod üzerinden yapıldığı ve çarpım değerinin pozitif değerde olduğu görülmektedir. Ak mukallit yüksek vejetasyonu tercih etmektedir. Ancak ikinci ve üçüncü gizli nodlarda suya uzaklığın güçlü ve negatif değerli olduğu durumlarda değerler negatif çıkmaktadır. Diğer bir deyişle ak mukallit suya yakın bölgelerde kısa vejetasyon da tercih edebilmektedir. Literatür bilgileri de bu yargıyı doğrulamaktadır.

### 5.2.3. Bozkır Toygarı *Calandrella brachydactyla* (Leisler, 1814)


Bozkır toygarı genelde çöl ve yarı çöllerde yaşayan toygar ailesinin ekolojik olarak ortasında bulunan bir türdür ve aralarında vejetasyona en iyi adapte olmuş olanıdır. Türkiye’de nispeten yaygın olarak görülen bozkır toygarı adından da anlaşılacağı gibi tipik bir bozkır türüdür. Snow ve Perrins’e göre (1998) bozkır toygarı kuru ve açık ovalarda, eğimli tepelerde, zaman zaman taşlık ve çakıllık alanlarda, alçak garig çalılarında nadasa bırakılmış tarım alanlarına ve 70 cm’ye kadar yükselen tahıl tarlalarına kadar uzanan vejetasyon tiplerinde üreyebilmektedir. Roselaar (1995) bozkır toygarının yaşam alanını şöyle tanımlamaktadır:

‘Kurak düz ya da alçak tepeli araziler, nadasa bırakılmış ya da sürülmüş tarım alanlarını tercih etmekte, kısa boylu tarım ürünlerinin bulunduğu tarlalar ile açık alanların içinde bulunan kısa çalılıklarla kaplı bölgelerde üremekte ve Türkiye’nin doğusunda 1500 m yüksekliğin altında bulunmaktadır.’

Bozkır toygarı için de Girdi İlişkilendirme Tabloları ve Sinirsel Yorumlama Diyagramları benzer sonuçları doğurmuştur. Suyu olan uzaklık etkisi Girdi İlişkilendirme Tablolarında toplam etkinin % 73,69’luk kısmına sahiptir. Bunu sırasıyla TM3 (% 6) ve en yakın otoyola uzaklık faktörleri (% 5) takip etmektedir. Kurak bölgelerde yaşamaya adapte olmuş bozkır toygarı için % 70 üzerinde etkili olan suya olan uzaklık etkisi beklenen bir sonuçtur. Bu değer yanında oldukça düşük kalan TM3 faktörü ise türün vejetasyon değişikliklerine hassasiyetini göstermektedir (Tablo 2.4). Bozkır toygarının yoldan uzaklaştıkça üreme ihtimali de artmaktadır. Duyarlılık analizlerine bakıldığında suya olan uzaklık faktörünün 20 km çizgisine kadar oldukça düşük olduğu ve bu mesafeden sonra üreme ihtimalinin arttığı görülmektedir (Şekil 4.18). Benzer bir sonuç yola olan uzaklık faktöründe de görülmektedir. Yola 20 km mesafedeki alanlarda üreme ihtimali düşükken bu mesafeden sonra üreme ihtimalinde keskin bir artış görülmektedir.

Bozkır toygarı modelindeki etkileşimleri incelemek için Sinirsel Yorumlama Diyagramı tüm girdi faktörlerinin bir arada bulunduğu şekilde budanmış olarak tekrardan çizilmiştir (Şekil 5.4). Şekilde suya olan uzaklık faktörünün sonuca olan büyük etkisi bir kere daha belirlenmiştir. Aynı zamanda bu faktörün en önemli bağlantılarının altıncı

ve yedinci gizli nod üzerinden yapıldığı ve bu bağlantıların çarpım değerlerinin pozitif değerli olduğu da görülmektedir. Bozkır toymarı suya olan uzaklığın artmasından olumlu şekilde etkilenmektedir. Suya olan uzaklığın negatif etkilendiği durumlar yalnızca son iki gizli nod üzerinden olan bağlantılardır. Her iki bağlantıda da TM3 faktörü etkindir. Başka bir deyişle vejetasyon yapısının tür için etkin olduğu bölgelerde suya yakın yerler tercih edilebilmektedir. Benzer şekilde türün yola olan uzaklık ilişkilerine bakıldığında da her iki güçlü bağlantının da pozitif değerler aldığı ve türün yoldan uzak olmayı tercih ettiği görülmektedir.



Şekil 5.4 : Bozkır toymarı için budanmış Sinirsel Yorumlama Diyagramı. Siyah çizgiler pozitif değerli bağlantıları, gri çizgiler negatif renkli bağlantıları göstermektedir. Çizgilerin kalınlığı bağlantıdaki ağırlığın büyüklüğünü ifade etmektedir.

Sonuç olarak;

1. Türlerin habitat seçimleri YNA modelleriyle başarılı bir şekilde irdelenmiştir. Sonuçların bir çoğu literatür bilgileriyle uyumluluk göstermekte ve YNA modellerinin bu üç tür için başarılı birer tahmin ve yorumlama aracı olduğunu göstermektedir.

2. YNA modelleri her bir tür için habitat ve çevresel faktör seçimlerini ortaya koymuştur. Her bir çevresel faktörle türün üreme ihtimalinin nasıl değişeceği duyarlılık analizleriyle gösterilmiştir. YNA'ların doğrusal olmayan etkileşimleri yorumlama güçleri sayesinde literatürde bulunmayan ve türler için yeni sayılacak bilgileri de ortaya koyabildiği gözlemlenmiştir: bu tez kapsamında kıvılcık başlı örümcekkuşunun suyla arasına çok belirgin mesafe koyduğu ve nemin düşük olduğu bölgelerde vejetasyon yüksekliğinde artışa izin verebileceği ortaya konulmuştur; Türkiye'nin bazı bölgelerinde park ve bahçelerde üreyebilen ak mukallidin Güney Doğu Anadolu Bölgesinde suya çok bağımlı olduğu ve üreme için suya yakın bölgeleri seçtiği görülmüştür. Hatta ak mukallit suya yakın olmak şartıyla kısa vejetasyonları da tercih edebilmektedir; bozkır toynak suyla arasında büyük mesafeler bulundurmakta ve ancak vejetasyon yapısının çok özel olması şartıyla suya yaklaşma eğilimi göstermektedir.

### **5.3. YNA MODELLERİNİN PRATİK UYGULAMALARI VE ÖNERİLER**

Günümüzde özellikle gelişmiş ülkelerde bir çok canlı türü için koruma çalışmaları ve belli bölgelerde soyu tükenen canlılar için yeniden doğaya yerleştirme çalışmaları yapılmaktadır. Bu çalışmaların başarıya ulaşması oldukça detaylı ve pahalı ekolojik çalışmaların gerçekleştirilmesine bağlıdır. Bu tez kapsamında üretilen yaklaşım, bu tarz uygulamaları hem kısa sürelerde hem de oldukça az maliyetle gerçekleştirebileceğinden tercih edilebilir niteliktedir. Mevzu bahis canlı türü için yapılacak duyarlılık analizleri kapsamında türün hangi parametreye ne kadar öncelik verdiği ve hangi parametreden nasıl etkilendiği belirlenebilecek ve yeniden doğaya yerleştirme alanlarında bu özellikler aranacak ya da uygun alanlar gerekirse yaratılabilecektir. Buna paralel olarak belli bölgelerde sayıları azalan türlerin hangi çevresel faktörlerden nasıl etkilendiğini açığa çıkarabilmek için de YNA'lar kullanılabilir. Türün hangi parametreden nasıl etkileneceği duyarlılık analizleriyle hızlıca hesaplanabilir ve çalışmanın yapıldığı alanda bu parametrelerin son yıllarda nasıl değiştikleri araştırılarak sorunlar ve çözüm önerileri bilimsel bir şekilde ortaya konulabilir. Elbette küçük ölçekte yapılacak çalışmalarda çalışmanın detayları da artırılmalıdır. Bu tür çalışmalarda çevresel faktör değerleri de çalışmanın kapsamına göre daha detaylıca incelenmelidir.

Ülkemizde yakın zamanlarda artmaya başlayan üreyen kuş araştırmaları gerek ülkenin büyüklüğü gerekse kuş araştırmalarındaki uzman azlığı nedeniyle büyük ölçeklerde yapılmaktadır. Gelecek dönemde yapılacak üreyen kuş atlası çalışmalarından elde edilecek veriler bu tezde uygulanan yöntemle değerlendirilebilir ve çalışmanın yapılmadığı diğer alanlarda YNA modelleri kullanılarak üreme tahminleri gerçekleştirilebilir. Bu tez kapsamında elde edilen ve % 75 ila % 90 arasında değişen üreme ihtimali tahminlerinin yüksek başarısı oldukça umut vericidir. Olası bir üreme tahmini çalışması kapsamında çevresel faktörlerin ulusal çapta ulaşılabilirliği elbette dikkatle değerlendirilmelidir. Örneğin GAP Projesi kapsamında üretilen vejetasyon sınıflandırma verileri ülke çapında henüz bu detayda mevcut değildir. Bu anlamda çalışmalar kapsamında kullanılmak için alternatif, daha düşük detaylı ve ucuz elde edilir veriler aranmalıdır.

Gelecekte yapılacak YNA uygulamalarında verinin elde edilebilirliğine önem verilmelidir. Günümüzde her ne kadar veriler elektronik ortamda bulunabilse de verilerin hangi yıllardan olduğuna dikkat edilmeli ve olabildiğince güncel veriler kullanılmalıdır. Öte yandan çevresel faktör sayısının çok fazla artırılmasından da kaçınılmalıdır. Çevresel faktör sayısı arttıkça verinin elde edilmesi zorlaşacak ve aynı zamanda YNA hesaplama zamanı da artacaktır. Bu tez kapsamında her zaman kolayca elde edilemeyecek uydu görüntüleri kullanılmıştır. Güncel uydu verilerinin elde edilmesi oldukça masraflıdır. Tez kapsamında kullanılan 12 çevresel faktörden 6 tanesi uydu görüntüleridir. Ancak Sinirsel Yorumlama Diyagramları ve Girdi İlişkilendirme Tablolarından görüleceği gibi bu faktörlerin her bir tür için sonuca olan etkileri diğer faktörlere göre göreceli olarak azdır. Bu nedenle gelecekteki uygulamalarda uydu görüntüsü değerleri kullanılmadan da benzer çalışmalar denenebilir ve sonuçların başarıları karşılaştırılabilir.

Son olarak bu tez kapsamında üretilen modellerin coğrafi bilgi sistemleriyle (CBS) birlikte kullanılabilirliğine dikkat çekilmektedir. Tez kapsamında elde edilen her bir model nokta bazlı verileri kullanmaktadır. Başka bir deyişle tüm çevresel faktör verileri belli koordinatlara özgüdür. Belli bir bölgede her bir nokta için bu verilerin elde edilebilir olması durumunda CBS programları yardımıyla her bir çevresel faktör değeri bir altlık olarak alınabilir ve o bölge için tüm çevresel faktörlerin üst üste konulmasıyla

YNA modelleri için bir altlık oluşturulabilir. Ardından YNA modeli her bir nokta için uygulanarak üreme tahmin haritaları oluşturulabilir. Üreme ihtimallerinin renk skalalarıyla belirtilmesi sağlanarak türün o bölgede nasıl bir üreme dağılımı göstereceği grafik diline dökülebilir. Bölgesel çapta üreme dağılımları ve popülasyon tahminleri için uygulanabilecek bu yöntem, verinin ulaşılabilir olmasına bağlı olarak günümüz teknolojisiyle kolayca uygulanabilecek oldukça yararlı bir araç niteliğindedir ve benzer çalışmalar yapacak araştırmacılar tarafından kullanılması önerilmektedir.

## KAYNAKLAR

- VERNER, J., MORRISON, M.L., RALPH, C.J., 1996, *Modeling Habitat Relationships of Terrestrial vertebrates*, University of Wisconsin Press, Madison, WI.
- EFE, Ö., KAYNAK, O., 2000, *Yapay Sinir Ağları ve Uygulamaları*, Boğaziçi University Printhouse, İstanbul.
- CHON, T., PARK, Y.S., MOON, K.H., CHA, E.Y., 1996, Patternizing Communities by Using an Artificial Neural Network, *Ecological Modelling*, Vol.90, 69-78.
- GUAN, B.T., GERTNER, G.Z., PARYSOW, P., 1997, A Framework for Uncertainty Assessment of Mechanistic Forest Growth models: a Neural Network Example, *Ecological Modelling*, Vol.98, 47-58.
- LEVINE, E.R., KIMES, D.S., SIGILLITO, V.G., 1996, Classifying Soil Structure Using Neural Networks, *Ecological Modelling*, Vol.92, 101-108.
- ANDERSON, J.A., 1995, *An Introduction to Neural Networks*, MIT, Cambridge, Massachusetts.
- BARAN, P., LEK, S., DELACOSTE, M., BELAUD, A., 1996, Stochastic Models That Predict Trout Population Density or Biomass on a Mesohabitat Scale, *Hydrobiologica*, Vol.337, 1-9.
- BISHOP, C.M., 1995, *Neural Networks for Pattern Recognition*, Oxford University Press, Oxford.
- BOUDJEMA, G., CHAU, N.P., 1996, Revealing Dynamics of Ecological Systems from Natural Recordings, *Ecological Modelling*, Vol.91, 15-23.
- FIELDING, A.H., 1999, *Machine Learning Methods for Ecological Applications*, Kluwer, Dordrecht, 209-223.
- GOODMAN, P.H., 1996, NevProp Software, Version 3, University of Nevada, Reno NV. (<http://www.scs.unr.edu/nevprop/>)
- LEK, S., BELAUD, A., BARANP., DIMOPOULOS, I., DELACOSTE, M., 1996, Role of Some Environmental Variables in Trout Abundance Models Using Neural Networks, *Aquat. Living Resour.* Vol.9, 23-29.
- LEK, S., DELACOSTE, M., BARAN, P., DIMOPOULOS, I., LAUGA, J., AULAGNIER, S., 1996, Application of Neural Networks to Modelling Non-linear Relationships in Ecology, *Ecological Modelling*, Vol.90, 39-52.

- ÖZESMİ, S., L., ÖZESMİ, U., 1999, An Artificial Neural Network Approach to Spatial Habitat Modelling with Interspecific Interaction, *Ecological Modelling*, Vol.116, 15-31.
- ÖZESMİ, S.L., TAN, C.O., ÖZESMİ, U., 2002, *Methodological issues in building, training and testing artificial neural networks*, 26-30 August 2002, 3rd Conference of the International for Ecological Informatics, Grottaferrata, Italy, 64.
- PARUELO, J.M., TOMASEL, F., 1997, Prediction of Functional Characteristics of Ecosystems: a Comparison of Artificial Neural Networks and Regression Models, *Ecological Modelling*, Vol. 98, 173-186.
- PER, E., 2003, *Sultan Sazlığı ve Tuzla Gölü'nde Lojistik Regresyon ve Yapay Sinir Ağları İle Kuş Habitat Modellemesi*, Lisans Tezi, Erciyes Üniversitesi Biyoloji Bölümü.
- POFF, N.L., TOKAR, S., JOHNSON, P., 1996, Stream Hydrological and Ecological Responses to climate Change Assessed with an Artificial Neural Network, *Limnological Oceanography*, Vol.41, 857-863.
- RECKNAGEL, F., FRENCH, M., HARKONEN, P., YABUNAKA, K., 1997, Artificial Neural Network Approach for Modelling and Prediction of Algal Blooms, *Ecological Modelling*, Vol. 96, 11-28.
- RIPLEY, B.D., 1996, *Pattern Recognition and Neural Networks*, Cambridge University Press, Cambridge.
- ROSELAAR, C.S., 1995, *Taxonomy, Morphology and Distribution of the Songbirds of Turkey: an Atlas of Biodiversity of Turkish Passerine Bird*, GMB Uitgeverij, Haarlem, 90-74345-07-7.
- SCARDI, M., 1996, Artificial Neural Networks as Empirical Models for Estimating Phytoplankton Production, *Marine Ecology, Prog. Ser.* Vol. 139, 289-299.
- SNOW, D.W., PERRINS, C.M., 1998, *The Birds of the Western Palearctic: Coincise Edition, Volume 2*, Oxford University Press, Oxford, 0-19-850188-9.
- TAN, S.S., SMEINS, F.E., 1996, Predicting Grassland Community Changes with an Artificial Neural Network Model, *Ecological Modelling*, Vol.84, 91-97.
- WEISS, S.M., KULIKOWSKI, C.A., 1991, *Computer Systems that Learn*, Morgan Kaufman, San Mateo.
- WELCH, H.J., ed. 2004, *GAP Biodiversity Research Project 2001 – 2003 Final Report*, DHKD (Turkish Society for the Conservation of Nature), İstanbul, Turkey.

## EKLER

### EK 1 – KIZIL BAŞLI ÖRÜMCEKKUŞU İÇİN NEVPROP3 SONUÇ DOSYASI ÖRNEĞİ (\*.RES)

```
##### NevProp (NP4r1) started on Sun Apr 11 16:48:42 2004

... SEED=9017 using rand(),srand()
... Read in 546 TRAIN CASES [random 218 cases (39%) to a holdout subset]

# DATA FILE SETTINGS
NHeaders 1      IDColumn YES
StandardizeInputs 1 SaveStandWts YES ImputeMissing median
InputColumns 1 2 3 4 5 6 7 8 9 10 11 12
OutputColumns 13
NVars 13      ShuffleData YES
# REPORTING SETTINGS
DescribeVars YES
NBoots 2      NEffectBoots 0
CalcIndex YES ScoreThreshold 0.1
OutputStatVars 0
MinCasesPerBin 0
# CONNECT CALLS
Connect 1 12 13 20
Connect 13 20 21 21
# CONFIGURATION SETTINGS
Ninputs 12      Nhidden 8      Noutputs 1
kNN 0          1ofN NO
HiddenUnitType 1 OutputUnitType 3
/* OutputUnitTypes assigned: 2 */
WeightRange 0.001
# TRAINING SETTINGS
TrainCriterion 2
BiasPenalty NO WeightDecay -0.001
OptimizeMethod 3 SigmoidPrimeOffset 0
QPMaxFactor 1.75 QPModeSwitchThreshold 0
Stochastic NO LearnRate 0.01 SplitLearnRate NO Momentum 0.01
# BEST-BY-HOLDOUT SETTINGS
PercentHoldout 39.00
AutoTrain YES MinEpochs 50 BeyondBestEpoch 1.5
NSplits 5 SepBootXVal YES
# RELEVANCE DETERMINATION SETTINGS
UseARD NO WhenARD Auto ARDTolerance 0.05 ARDFreq 1
GroupSelection Input BiasRelevance NO ARDFactor 1

##### Start of Model Fitting #####
Start of Phase I: Find TRAIN-SUBSET error at best HOLDOUT-SUBSET criterion.

      __TRAIN-SUBSET_( 328)__ __HOLDOUT-SUBSET_( 218)__
Train FrGrdD AvSqWt APnCrEn ACrEn AThEr 1-c APnCrEn ACrEn AThEr 1-c
Epoch (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3)
```

```

-----
0 N/A 0.0003 693.134 693.134 1000. 554.2 693.165 693.165 1000. 579.6
1 1000.0 0.0003 692.705 692.705 1000. 525.4 693.961 693.961 1000. 566.5
2 0.0000 0.0003 692.516 692.516 1000. 444.6 696.255 696.255 1000. 496.9
3 0.0000 0.0003 692.478 692.478 1000. 312.3 695.496 695.496 1000. 385.5
4 0.0000 0.0004 692.476 692.476 1000. 246.9 695.495 695.495 1000. 330.5
5 0.0000 0.0008 692.476 692.476 1000. 231.1 695.495 695.495 1000. 307.9
6 0.0000 0.0022 692.472 692.472 1000. 228.9 695.491 695.491 1000. 300.9
7 0.0000 0.0074 692.457 692.457 1000. 228.5 695.479 695.479 1000. 298.6
8 0.0000 0.0269 692.400 692.400 1000. 228.9 695.432 695.432 1000. 298.0
9 0.0000 0.1003 692.179 692.179 1000. 228.8 695.252 695.252 1000. 297.0
10 0.0000 0.3775 691.329 691.329 1000. 229.1 694.561 694.561 1000. 297.0
.
.
.
153 0.0000 8055.5 103.121 101.844 213.4 5.324 559.464 557.542 348.6 105.0
154 0.0000 8073.8 102.727 101.447 222.6 5.138 555.200 553.274 344.0 104.4
155 0.0000 8111.5 102.086 100.800 213.4 5.249 560.116 558.181 334.9 105.0
156 0.0000 8133.7 101.654 100.364 216.5 5.175 561.526 559.586 339.4 105.4
157 0.0000 8171.1 101.109 99.8134 216.5 5.026 562.535 560.586 334.9 105.6

```

.  
.  
.

153 0.0000 8055.5 103.121 101.844 213.4 5.324 559.464 557.542 348.6 105.0  
154 0.0000 8073.8 102.727 101.447 222.6 5.138 555.200 553.274 344.0 104.4  
155 0.0000 8111.5 102.086 100.800 213.4 5.249 560.116 558.181 334.9 105.0  
156 0.0000 8133.7 101.654 100.364 216.5 5.175 561.526 559.586 339.4 105.4  
157 0.0000 8171.1 101.109 99.8134 216.5 5.026 562.535 560.586 334.9 105.6

Done. Epoch 157 is beyond 1.5 X BestEpoch 104 (and MinEpochs).

##### Summary of Input Relevance Determination #####  
( sum square weights of ith input group)  
Relevance formula:  $R_i = \frac{\text{sum square weights of ith input group}}{\text{sum square weights of all input groups}}$

| Input | Relevance |
|-------|-----------|
| ^^^^  | ^^^^^^    |
| 1     | 1.64%     |
| 2     | 1.01%     |
| 3     | 1.54%     |
| 4     | 2.30%     |
| 5     | 1.59%     |
| 6     | 2.91%     |
| 7     | 16.42%    |
| 8     | 8.54%     |
| 9     | 3.31%     |
| 10    | 21.86%    |
| 11    | 33.61%    |
| 12    | 5.27%     |

##### End of Input Relevance Report #####

(Up to) 10 BEST reports on HOLDOUT-SUBSET using Best-By criterion graphed:

| Epochs | APCE (e-3) | BEST  | <---- APnCrEn ----> | WORST |
|--------|------------|-------|---------------------|-------|
| 92     | 424.65499  | ***** |                     |       |
| 95     | 422.82769  | ***** |                     |       |
| 96     | 420.41528  | ***** |                     |       |
| 97     | 424.41371  | ***** |                     |       |
| 98     | 422.01069  | ***** |                     |       |
| 99     | 420.39108  | ***** |                     |       |
| 100    | 422.51483  | ***** |                     |       |
| 101    | 423.36524  | ***** |                     |       |
| 103    | 424.64954  | ***** |                     |       |
| 104    | 414.97189  | *     |                     |       |

.....=>Skips at least one reporting period.

\*-----\*

For split #1 of 5, target error = 0.175369 from Epoch 104.

\_\_\_\_TRAIN-SUBSET\_( 328)\_\_\_\_HOLDOUT-SUBSET\_( 218)\_\_\_\_  
 Train FrGrdD AvSqWt APnCrEn ACrEn AThEr 1-c APnCrEn ACrEn AThEr 1-c  
 Epoch (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3)

```

0 N/A 0.0003 693.154 693.154 1000. 571.7 693.134 693.134 1000. 555.1
1 1000.0 0.0003 693.041 693.041 1000. 548.7 693.441 693.441 1000. 542.6
2 0.0000 0.0003 692.990 692.990 1000. 473.7 694.245 694.245 1000. 469.6
3 0.0000 0.0003 692.979 692.979 1000. 331.5 693.985 693.985 1000. 352.3
4 0.0000 0.0004 692.979 692.979 1000. 267.2 693.985 693.985 1000. 288.0
5 0.0000 0.0007 692.979 692.979 1000. 246.5 693.985 693.985 1000. 266.2
6 0.0000 0.0017 692.976 692.976 1000. 239.1 693.982 693.982 1000. 259.4
7 0.0000 0.0056 692.966 692.966 1000. 235.4 693.973 693.973 1000. 257.2
8 0.0000 0.0196 692.927 692.927 1000. 234.5 693.936 693.936 1000. 257.2
9 0.0000 0.0719 692.780 692.779 1000. 233.8 693.798 693.798 1000. 257.3
10 0.0000 0.2672 692.217 692.217 1000. 232.8 693.273 693.273 1000. 257.2
.
.
.

```

```

66 0.0000 2043.5 334.781 334.457 597.6 65.57 544.605 544.118 550.5 161.9
67 0.0000 2117.0 332.532 332.196 603.7 63.97 543.580 543.075 555.0 161.9
68 0.0000 2131.6 329.789 329.451 594.5 63.45 552.637 552.129 550.5 164.0
69 0.0000 2194.8 330.458 330.110 591.5 64.38 561.513 560.989 555.0 168.7
70 0.0000 2186.1 326.365 326.018 582.3 61.63 553.988 553.467 536.7 163.6
71 0.0000 2203.1 324.738 324.389 588.4 61.59 560.049 559.523 550.5 165.6
72 0.0000 2232.2 323.065 322.711 579.3 60.21 552.400 551.868 555.0 164.4
73 0.0000 2273.5 321.111 320.750 573.2 60.10 565.016 564.473 545.9 166.2

```

Done. Epoch 73 is beyond 1.5 X BestEpoch 48 (and MinEpochs).

##### Summary of Input Relevance Determination #####

( sum square weights of ith input group)

Relevance formula:  $R_i = \frac{\text{sum square weights of ith input group}}{\text{sum square weights of all input groups}}$

( sum square weights of all input groups)

| Input | Relevance |
|-------|-----------|
| ~~~~~ | ~~~~~     |
| 1     | 1.63%     |
| 2     | 0.95%     |
| 3     | 1.59%     |
| 4     | 1.79%     |
| 5     | 1.14%     |
| 6     | 2.23%     |
| 7     | 5.12%     |
| 8     | 13.48%    |
| 9     | 13.77%    |
| 10    | 23.54%    |
| 11    | 31.61%    |
| 12    | 3.16%     |

##### End of Input Relevance Report #####

(Up to) 10 BEST reports on HOLDOUT-SUBSET using Best-By criterion graphed:

Epochs APCE (e-3) BEST <---- APnCrEn ----> WORST

```

-----|-----|
41 518.59200 *****
-----
43 512.31211 *****
-----
45 500.61220 ****
46 505.68604 *****
47 509.95672 *****
48 498.81154 *
49 502.04480 *****
50 507.46143 *****
51 504.61936 *****
52 510.38367 *****

.....=>Skips at least one reporting period.
*-----*
For split #2 of 5, target error = 0.417162 from Epoch 48.

      __TRAIN-SUBSET_( 328)__ __HOLDOUT-SUBSET_( 218)__
Train FrGrdD AvSqWt APnCrEn ACrEn AThEr 1-c APnCrEn ACrEn AThEr 1-c
Epoch (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3)
-----
0 N/A 0.0003 693.158 693.158 1000. 560.5 693.127 693.127 1000. 567.8
1 1000.0 0.0003 692.848 692.848 1000. 539.9 693.898 693.898 1000. 553.9
2 0.0000 0.0003 692.711 692.711 1000. 440.9 695.957 695.957 1000. 492.6
3 0.0000 0.0003 692.682 692.682 1000. 310.3 695.291 695.291 1000. 364.9
4 0.0000 0.0004 692.681 692.681 1000. 290.4 695.290 695.290 1000. 335.3
5 0.0000 0.0008 692.681 692.681 1000. 285.5 695.290 695.290 1000. 331.7
6 0.0000 0.0022 692.678 692.678 1000. 277.6 695.287 695.287 1000. 326.1
7 0.0000 0.0073 692.666 692.666 1000. 272.4 695.276 695.276 1000. 324.8
8 0.0000 0.0256 692.620 692.620 1000. 268.5 695.233 695.232 1000. 321.8
9 0.0000 0.0931 692.437 692.437 1000. 267.0 695.063 695.063 1000. 321.0
10 0.0000 0.3431 691.729 691.729 1000. 266.4 694.407 694.406 1000. 319.9
.
.
.
124 0.0000 5154.8 205.011 204.193 381.1 21.51 581.997 580.767 467.9 144.9
125 0.0000 5168.2 204.017 203.198 384.1 21.40 583.923 582.690 454.1 145.7
126 0.0000 5189.4 202.397 201.574 387.2 20.69 583.941 582.703 449.5 145.4
127 0.0000 5233.4 199.714 198.885 387.2 19.87 585.389 584.140 454.1 146.4
128 0.0000 5320.8 195.916 195.073 387.2 18.87 588.807 587.538 449.5 146.3
129 0.0000 5480.1 192.080 191.211 372.0 18.20 599.229 597.922 435.8 147.2
130 0.0000 5519.7 206.333 205.458 396.3 17.60 598.007 596.690 477.1 151.0
131 0.0000 5530.6 190.515 189.638 368.9 18.53 593.927 592.608 449.5 147.6
Done. Epoch 131 is beyond 1.5 X BestEpoch 87 (and MinEpochs).

##### Summary of Input Relevance Determination #####
      ( sum square weights of ith input group)
Relevance formula: R_i = -----
      ( sum square weights of all input groups)

Input   Relevance
^^^^^^  ^^^^^^^^^
1       3.14%
2       0.47%
3       4.10%
4       2.18%
5       2.71%
6       2.34%

```

```

7      5.46%
8      1.64%
9      3.35%
10     37.33%
11     34.96%
12     2.33%
##### End of Input Relevance Report #####

(Up to) 10 BEST reports on HOLDOUT-SUBSET using Best-By criterion graphed:

Epochs  APCE (e-3) BEST  <--- APnCrEn ---->  WORST
-----  -|-----|
78 510.30296 *****
.....
80 515.52325 *****
81 512.46387 *****
82 511.46752 *****
83 513.38935 *****
.....
85 513.81797 *****
86 513.69232 *****
87 508.52382 *
88 515.44482 *****
.....
91 514.85562 *****

.....=>Skips at least one reporting period.
*-----*

For split #3 of 5, target error = 0.275267 from Epoch 87.

____TRAIN-SUBSET_( 328)____HOLDOUT-SUBSET_( 218)____
Train FrGrdD AvSqWt APnCrEn ACrEn AThEr 1-c APnCrEn ACrEn AThEr 1-c
Epoch (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3)
-----
0 N/A 0.0003 693.138 693.138 1000. 557.4 693.158 693.158 1000. 568.9
1 1000.0 0.0003 692.950 692.950 1000. 540.3 693.481 693.481 1000. 552.2
2 0.0000 0.0003 692.866 692.866 1000. 454.4 694.433 694.433 1000. 469.2
3 0.0000 0.0003 692.849 692.849 1000. 335.7 694.116 694.116 1000. 327.8
4 0.0000 0.0004 692.849 692.849 1000. 312.5 694.116 694.116 1000. 301.6
5 0.0000 0.0008 692.848 692.848 1000. 312.8 694.115 694.115 1000. 296.5
6 0.0000 0.0023 692.845 692.845 1000. 311.1 694.112 694.112 1000. 292.4
7 0.0000 0.0075 692.832 692.832 1000. 310.7 694.099 694.099 1000. 287.9
8 0.0000 0.0270 692.779 692.779 1000. 310.1 694.052 694.052 1000. 286.8
9 0.0000 0.0992 692.574 692.574 1000. 309.8 693.866 693.866 1000. 287.2
10 0.0000 0.3693 691.786 691.786 1000. 309.6 693.152 693.152 1000. 286.7
.
.
.
73 0.0000 1752.1 363.529 363.251 673.8 77.19 497.014 496.596 656.0 158.5
74 0.0000 1835.1 376.254 375.963 612.8 89.77 495.668 495.230 637.6 161.6
75 0.0000 1783.6 358.254 357.971 661.6 77.19 490.585 490.160 656.0 156.7
76 0.0000 1792.5 356.845 356.561 664.6 76.86 491.365 490.938 665.1 155.1
77 0.0000 1818.0 354.402 354.114 664.6 76.34 491.609 491.175 656.0 156.3
78 0.0000 1866.0 350.220 349.925 661.6 74.59 492.024 491.579 656.0 157.1
79 0.0000 1952.3 344.833 344.524 646.3 71.65 501.262 500.797 642.2 160.1
Done. Epoch 79 is beyond 1.5 X BestEpoch 52 (and MinEpochs).

##### Summary of Input Relevance Determination #####
( sum square weights of ith input group)

```

Relevance formula:  $R_i = \frac{\text{weight}_i}{\sum \text{square weights of all input groups}}$

Input      Relevance  
~~~~~      ~~~~~~

|    |        |
|----|--------|
| 1  | 0.29%  |
| 2  | 3.82%  |
| 3  | 0.23%  |
| 4  | 4.67%  |
| 5  | 4.48%  |
| 6  | 4.31%  |
| 7  | 18.24% |
| 8  | 8.87%  |
| 9  | 27.78% |
| 10 | 6.62%  |
| 11 | 17.15% |
| 12 | 3.54%  |

##### End of Input Relevance Report #####

(Up to) 10 BEST reports on HOLDOUT-SUBSET using Best-By criterion graphed:

Epochs   APCE (e-3) BEST   <---- APnCrEn ---->   WORST

-----|-----  
42 474.63483 \*\*\*\*\*

44 471.08224 \*\*\*\*\*

46 473.57687 \*\*\*\*\*

47 469.04898 \*\*\*\*\*

48 469.33058 \*\*\*\*\*

49 466.18333 \*\*\*\*\*

52 462.47831 \*

53 470.20128 \*\*\*\*\*

54 474.74000 \*\*\*\*\*

55 476.37245 \*\*\*\*\*

.....=>Skips at least one reporting period.

\*-----\*

For split #4 of 5, target error = 0.438234 from Epoch 52.

\_\_\_\_TRAIN-SUBSET\_( 328)\_\_\_\_HOLDOUT-SUBSET\_( 218)\_\_\_\_  
Train FrGrdD AvSqWt APnCrEn ACrEn AThEr 1-c APnCrEn ACrEn AThEr 1-c  
Epoch (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3) (e-3)

|    |        |        |         |         |       |       |         |         |       |       |
|----|--------|--------|---------|---------|-------|-------|---------|---------|-------|-------|
| 0  | N/A    | 0.0003 | 693.152 | 693.152 | 1000. | 557.5 | 693.138 | 693.138 | 1000. | 573.7 |
| 1  | 1000.0 | 0.0003 | 693.100 | 693.100 | 1000. | 540.5 | 693.290 | 693.290 | 1000. | 558.9 |
| 2  | 0.0000 | 0.0003 | 693.076 | 693.076 | 1000. | 473.3 | 693.682 | 693.682 | 1000. | 489.0 |
| 3  | 0.0000 | 0.0003 | 693.072 | 693.072 | 1000. | 341.3 | 693.556 | 693.556 | 1000. | 341.4 |
| 4  | 0.0000 | 0.0004 | 693.072 | 693.072 | 1000. | 275.0 | 693.556 | 693.556 | 1000. | 263.2 |
| 5  | 0.0000 | 0.0007 | 693.072 | 693.072 | 1000. | 257.4 | 693.556 | 693.556 | 1000. | 234.3 |
| 6  | 0.0000 | 0.0018 | 693.069 | 693.069 | 1000. | 252.9 | 693.553 | 693.553 | 1000. | 227.8 |
| 7  | 0.0000 | 0.0058 | 693.061 | 693.061 | 1000. | 247.5 | 693.543 | 693.543 | 1000. | 225.4 |
| 8  | 0.0000 | 0.0201 | 693.027 | 693.027 | 1000. | 244.7 | 693.505 | 693.505 | 1000. | 226.3 |
| 9  | 0.0000 | 0.0720 | 692.900 | 692.900 | 1000. | 243.4 | 693.358 | 693.358 | 1000. | 226.6 |
| 10 | 0.0000 | 0.2615 | 692.416 | 692.416 | 1000. | 243.2 | 692.805 | 692.805 | 1000. | 226.8 |

.  
.
   
.

```

127 0.0000 5415.5 225.387 224.528 393.3 29.90 434.070 432.778 440.4 104.5
128 0.0000 5497.2 223.839 222.968 378.0 29.12 433.313 432.002 440.4 104.5
129 0.0000 5558.0 222.430 221.549 381.1 28.41 434.840 433.514 445.0 104.8
130 0.0000 5632.7 220.946 220.053 381.1 28.67 434.386 433.042 445.0 103.4
131 0.0000 5727.8 220.354 219.446 381.1 28.89 421.398 420.031 431.2 100.2
132 0.0000 5766.6 218.521 217.606 375.0 27.55 434.650 433.275 440.4 103.5
133 0.0000 5789.7 217.362 216.444 375.0 27.55 429.101 427.720 440.4 102.1

```

Done. Epoch 133 is beyond 1.5 X BestEpoch 88 (and MinEpochs).

##### Summary of Input Relevance Determination #####  
 ( sum square weights of ith input group)  
 Relevance formula:  $R_i = \frac{\text{sum square weights of ith input group}}{\text{sum square weights of all input groups}}$

| Input | Relevance |
|-------|-----------|
| ~~~~~ | ~~~~~     |
| 1     | 1.32%     |
| 2     | 0.66%     |
| 3     | 0.83%     |
| 4     | 0.70%     |
| 5     | 0.93%     |
| 6     | 0.58%     |
| 7     | 0.62%     |
| 8     | 22.32%    |
| 9     | 0.92%     |
| 10    | 3.70%     |
| 11    | 60.91%    |
| 12    | 6.53%     |

##### End of Input Relevance Report #####

(Up to) 10 BEST reports on HOLDOUT-SUBSET using Best-By criterion graphed:

Epochs APCE (e-3) BEST <---- APnCrEn ----> WORST

```

-----|-----|
84 407.84186 *****
.....
86 408.22697 *****
87 407.85736 *****
88 404.98969 *
.....
96 407.54598 *****
.....
98 408.34963 *****
99 408.33122 *****
100 407.56261 *****
101 408.04952 *****
102 407.67780 *****

```

.....=>Skips at least one reporting period.

\*-----\*

For split #5 of 5, target error = 0.310448 from Epoch 88.


\*-----\*

Result of Phase 1 (5 splits):

Avg TRAIN\_SUBSET target 0.323296 from average of 75 Epochs of training.

Convergence of Average Target Error After each split:

SD/Mean NSPLIT#0.175 0.206 0.236 0.266 0.296 0.327



\*-----\*

Start of Phase II: Re-train on entire TRAIN-SET to target error above.

\_\_\_\_TRAIN-SET\_( 546)\_\_\_\_  
 Train FrGrdD AvSqWt APnCrEn ACrEn AThEr 1-c  
 Epoch (e-3) (e-3) (e-3) (e-3) (e-3) (e-3)

0 N/A 0.0003 693.145 693.145 1000. 564.0  
 1 1000.0 0.0003 693.141 693.141 1000. 523.8  
 2 0.0000 0.0003 693.143 693.143 1000. 369.4  
 3 0.0000 0.0004 693.138 693.138 1000. 313.8  
 4 0.0000 0.0007 693.137 693.137 1000. 304.3  
 5 0.0000 0.0018 693.136 693.136 1000. 298.3  
 6 0.0000 0.0065 693.125 693.125 1000. 293.8  
 7 0.0000 0.0255 693.073 693.073 1000. 291.4  
 8 0.0000 0.1041 692.845 692.845 1000. 290.5  
 9 0.0000 0.4330 691.873 691.873 1000. 290.1  
 10 0.0000 1.8155 687.870 687.870 1000. 289.5

.

.

.

96 0.0000 2248.3 337.735 337.521 553.1 71.62  
 97 0.0000 2268.0 335.686 335.470 551.3 70.58  
 98 0.0000 2310.1 332.943 332.723 553.1 69.11  
 99 0.0000 2351.8 329.449 329.225 551.3 67.02  
 100 0.0000 2384.7 325.627 325.400 547.6 65.12  
 101 0.0000 2413.3 322.528 322.299 538.5 64.57

##### Summary of Input Relevance Determination #####  
 ( sum square weights of ith input group)

Relevance formula:  $R_i = \frac{\text{sum square weights of } i\text{th input group}}{\text{sum square weights of all input groups}}$

| Input | Relevance |
|-------|-----------|
| ^^^^  | ^^^^^^    |
| 1     | 2.56%     |
| 2     | 0.78%     |
| 3     | 0.87%     |
| 4     | 5.49%     |
| 5     | 3.14%     |
| 6     | 2.19%     |
| 7     | 4.82%     |
| 8     | 6.01%     |
| 9     | 6.23%     |
| 10    | 11.09%    |
| 11    | 52.17%    |
| 12    | 4.64%     |

##### End of Input Relevance Report #####

REACHED TARGET ERROR = 0.323296 at Epoch 101

\*-----\*

Returning trained network from Epoch 101.

## EK 2 – KIZIL BAŞLI ÖRÜMCCEKKUŞU İÇİN NEVPROP3 KOMUT DOSYASI ÖRNEĞİ (\*.NET)

```

FileFormat 3.0
## DESCRIPTION:
#####
#- lanius son model
# NP FILE SETTINGS
    ResultsFile      l8.res
    SaveWeightsFile   l8.wts
    saveTrainPrdFile  l8.ptr
readtestfile l8.tst
savetestprdfile l8.pts
    NHeaders 1      IDCColumn YES
    StandardizeInputs 1  SaveStandWts YES ImputeMissing median
    InputColumns 1 2 3 4 5 6 7 8 9 10 11 12
    OutputColumns 13
    NVars 13      ShuffleData YES
# REPORTING SETTINGS
    DescribeVars YES
    CalcclIndex YES    ScoreThreshold 0.1    Nboots 2
# CONNECT CALLS
    Connect 1 12 13 20
    connect 13 20 21 21
    # CONFIGURATION SETTINGS
    Ninputs 12      Nhidden 8      Noutputs 1
    # WeightRange 0.001
# TRAINING SETTINGS

# BEST-BY-HOLDOUT SETTINGS
/* NHoldout 50 */    PercentHoldout 40.00
    AutoTrain YES    MinEpochs 50    BeyondBestEpoch 1.5
    NSplits 5
# AUTOMATIC RELEVANCE DETERMINATION SETTINGS

DATA

```

## ÖZGEÇMİŞ

1977 yılında İstanbul’da doğdum. İlkokulu Mevlana İlköğretim Oklunda, Ortaokul ve Liseyi Bahçelievler Lisesi’nde tamamladım. Orta Doğu Teknik Üniversitesi Matematik Bölümü’nden 2000 yılında mezun oldum. Yine aynı yıl İstanbul Üniversitesi’nde yüksek lisans programına kaydoldum.

1999 yılında Türkiye Doğal Hayatı Koruma Derneği’nde Konya Biyolojik Çeşitlilik Projesi asistanı olarak yarı zamanlı çalışmaya başladım. 2000 – 2002 yılları arasında yine aynı kurumda Önemli Kuş Alanları Projesi Sorumlusu olarak çalıştım. 2003 tarihinden bu yana Doğa Derneği’nde Önemli Kuş Alanları Sorumlusu olarak çalışmaktayım. Çalışma hayatım boyunca Türkiye’de bir çok kuş araştırmasının koordinatörü olarak çalıştım. 2001 yılından bu yana Dünya Kuşları Koruma Kurumunun (BirdLife International) Türkiye temsilciliğinden sorumluyum.