

**KELEBEK TÜRLERİNİN (LYCAENIDAE) BİLGİSAYAR  
GÖRÜ SİSTEMLERİ İLE TEŞHİS EDİLMESİ**

**YÜKSEK LİSANS**

**Pamuk YETER EREZ**

**153104002**

**Biyoloji Anabilim Dalı**

**Tez Danışmanı I: Dr. Öğr. Üyesi Yılmaz KAYA**

**Tez Danışmanı II: Prof. Dr. Musa TÜRKER**

**Nisan-2018**

**SIİRT**

## TEZ KABUL VE ONAYI

**Pamuk YETER EREZ** tarafından hazırlanan “**Kelebek Türlerinin (Lycaenidae) Bilgisayar Görü Sistemleri İle Teşhis Edilmesi**” adlı tez çalışması .../.../... tarihinde aşağıdaki jüri tarafından oybirliği/oyçokluğu ile Siirt Üniversitesi Fen Bilimleri Enstitüsü Biyoloji Anabilim Dalı’nda YÜKSEK LİSANS tezi olarak kabul edilmiştir.

Başkan: Dr. Öğr. Üyesi Erdem SEVEN

İmza:



Üye: Dr. Öğr. Üyesi Mustafa Cemal ÇİFTÇİ

İmza:



Üye: Dr. Öğr. Üyesi Yılmaz KAYA

İmza:



Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 01.02.2013 tarih ve 2013/01/12 sayılı kararı ile onaylanmıştır.

  
İmza  
Doç.Dr. Fevzi HANISU

Enstitü Müdürü

## ÖN SÖZ

İnsanođlu, canlı organizmaları belirli taksonomik kurallara göre sınıflandırarak teşhis etmeye çalışmıştır. İlk sınıflandırma yöntemi genellikle morfolojik karakterlere göre yapılmaktadır ancak bilimsel gelişmeler ile birlikte moleküler tekniklerin yanı sıra görüntü işleme çalışmaları da sistematik çalışmalara dâhil olmuştur. Tanımlama veya teşhis çalışmalarında bireysel farklılıkların önüne geçilebilmesi için bilgisayar destekli görüntü işleme çalışmalarına ihtiyaç duyulmaktadır.

Bu amaçla yapılan tez çalışmasında, farklı kelebek türlerinin görüntü işleme tekniđi ile tanımlanması hedeflenmiştir. Yapılan çalışmanın bilimsel taksonomi çalışmalarına destek ve yardımcı olacağı kanaatindeyiz.

Bu tez çalışması esnasında sürekli yol gösteren ve yardımlarını esirgemeyen danışman hocam Dr. Yılmaz Kaya'ya teşekkürlerimi sunarım.

**Pamuk YETER EREZ**  
**Siirt/ 2019**

# İÇİNDEKİLER

## Sayfa

ÖN SÖZ .....	iii
İÇİNDEKİLER .....	iv
TABLolar LİSTESİ .....	v
ŞEKİLLER LİSTESİ .....	vi
KISALTMALAR VE SİMGELERLİSTESİ.....	vii
ÖZET .....	viii
ABSTRACT.....	ix
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. LİTERATÜR BİLDİRİŞLERİ</b> .....	<b>6</b>
<b>3. MATERYAL VE YÖNTEM</b> .....	<b>10</b>
3.1. Materyal .....	10
3.2. Yöntem.....	13
3.2.1. Gri Düzey Eş Oluşum Matrisi (Gray Level Co-Occurrence Matrix).....	13
3.2. Yerel İkili Örüntüler Yöntemi .....	17
3.2.2. Aşırı Öğrenme Makinesi.....	19
3.3. Kelebek Tanıma Diyagramları.....	21
<b>4. BULGULAR</b> .....	<b>23</b>
4.1. LBP+ELM Sonuçları .....	23
4.2. GLCM+ELM Sonuçları .....	29
4.3. Yöntemlerin Karşılaştırılması.....	36
<b>5. TARTIŞMA SONUÇ</b> .....	<b>37</b>
<b>KAYNAKLAR</b> .....	<b>40</b>
<b>ÖZGEÇMİŞ</b> .....	<b>43</b>

## TABLolar LİSTESİ

	<b>Sayfa</b>
<b>Tablo 3.1.</b> Çalışmada kullanılan kelebek türleri ve kodları	12
<b>Tablo 3.2.</b> Kelebek görüntülerinden elde edilen doku özelliklerine ait formüller	17
<b>Tablo 4.1.</b> Üst yüz görüntüler için başarı oranları	29
<b>Tablo 4.2.</b> Alt yüz görüntüleri için başarı oranları	30
<b>Tablo 4.3.</b> GLCM+ELM ile kelebek üst yüzey görüntüler için başarı oranları	36
<b>Tablo 4.4.</b> GLCM+ELM ile kelebek alt yüzey görüntüler için başarı oranları	37
<b>Tablo 4.5.</b> LBP+ELM ve GLCM+ELM başarı oranları (%)	38



## ŞEKİLLER LİSTESİ

	Sayfa
Şekil 3.1. Çalışmada kullanılan kelebeklere ait üst yüz görüntüleri	11
Şekil 3.2. Çalışmada kullanılan kelebeklere ait alt yüz görüntüleri	12
Şekil 3.3. GLCM Yöntem çalışma prensibi	14
Şekil 3.4. GLCM matrislerin farklı açılar için oluşturulması	15
Şekil 3.5. GLCM Metodu çalışma prensibi	16
Şekil 3.6. Komşu etiketlerin işlenmesi	18
Şekil 3.7. Komşu etiket piksellerinin merkez piksel ile karşılaştırılması	19
Şekil 3.8. İleri beslemeli yapay sinir ağı	21
Şekil 3.9. Kelebek tanıma için önerilen GLCM-ELM yöntemi	23
Şekil 3.10. Kelebek tanıma için önerilen LBP-ELM yöntemi	23
Şekil 4.1. Kelebek ön yüzlere ait Orijinal görüntü, LBP görüntü ve Histogram	26
Şekil 4.2. Kelebek alt yüzlere ait Orijinal görüntü, LBP görüntü ve Histogramları	27
Şekil 4.3. GLCM yön ve mesafeler	31
Şekil 4.4. Farklı mesafeler için kontrast özelliğın dört farklı kelebek türü için dağılımı	32
Şekil 4.5. Farklı mesafeler için korelasyon özelliğın dört farklı kelebek türü için dağılımı	33
Şekil 4.6. Farklı mesafeler için enerji özelliğın dört farklı kelebek türü için dağılımı	34
Şekil 4.7. Farklı mesafeler için kontrast özelliğın dört farklı kelebek türü için dağılımı	35

## KISALTMALAR VE SİMGELER LİSTESİ

<u>Kısaltma</u>	<u>Açıklama</u>
ELM	Extreme Learning Machine; Aşırı Öğrenme Makinesi
LBP	Local Binary Pattern
GLCM	Grey Level Co-occurrence Matrix
CBIR	Content Based Image Retrieval
2D	<u>Two Dimensional</u>
BLS	<u>Branch Length Similarity</u>
YSA	<u>Yapay Sinir Ağları</u>
HOG	Histogram of Oriented Gradients
D	Pikseller Arası Uzaklık

<u>Simge</u>	<u>Açıklama</u>
m	Metre
mm	Milimetre
%	Yüzde
°	Derece
$\theta$	Theta
$\phi$	Phi
$\Sigma$	Toplam
$\beta$	Beta
log	Logaritma
$\sigma$	Sigma
$\mu$	Mu

## ÖZET

### KELEBEK TÜRLERİNİN (LYCAENIDAE) BİLGİSAYAR GÖRÜ SİSTEMLERİ İLE TEŞHİŞ EDİLMESİ

**Pamuk YETER EREZ**

**Siirt Üniversitesi Fen Bilimleri Enstitüsü  
Biyoloji Anabilim Dalı**

**Tez Danışmanı I: Dr. Öğr. Üyesi. Yılmaz KAYA**

**Tez Danışmanı II: Prof. Dr. Musa TÜRKER**

**2018, 55 Sayfa**

İnsanoğlu çevresinde bulunan nesne ve organizmaları sınıflandırma ihtiyacı duymuştur. Sistematik veya taksonomi adı verilen sınıflandırma sisteminde öncelikle morfolojik karakterleri kullanılmaya başlanılmıştır. Bilimsel çalışmalarda meydana gelen gelişmeler ile birlikte moleküler biyoloji, anatomi, karyoloji gibi çalışma alanları da sistematik bilimine dahil olmuştur. Biyolojik canlıların tür sayılarının fazlalığı, benzer ve farklı karakterlerin değişkenliği nedeni ile sınıflandırma sistemi özel program ve teknikler ile desteklenmiştir.

Yapılan tez çalışmasında, kelebek türlerinin tespiti için klasik teşhis yöntemlerine alternatif olarak bilgisayar görü tabanlı bir yöntem önerilmiştir. Kelebek türlerinin sınıflandırılması için karakteristik özelliklere sahip kelebek kanat doku görüntüleri kullanılmıştır. Çalışmada kelebek görüntülerinden etkili özellikler çıkarmak için yerel ikili örüntüler LBP ve GLCM görüntü işleme yöntemleri kullanılmıştır. Kelebek türlerin tespiti iki aşamada gerçekleştirilmiştir. Birinci aşamada öznelilikler elde edilmiş, ikinci aşamada ise bu öznelilikler ELM makine öğrenmesi yöntemi kullanılarak 10-katlı çapraz geçerlilik testi ile sınıflandırma işlemi gerçekleştirilmiştir. Çalışma sonunda sınıflandırma başarısı % 91.6031 olarak elde edilmiştir. Sonuç olarak önerilen bilgisayar görü teşhis yönteminin kelebek türü teşhisinde alternatif yöntemlere destekleyici yöntemler olacağı düşünülmektedir.

**Anahtar Kelimeler:** Lepidoptera, LBP, GLCM, ELM, görüntü işleme, kelebek teşhisi



## **ABSTRACT**

### **MS THESIS**

## **IDENTIFICATION OF BUTTERFLY SPECIES (LYCAENIDAE) WITH IMAGE PROCESS SYSTEM**

**Pamuk YETER EREZ**

**The Graduate School of Natural and Applied Science of Siirt University  
The Degree of Master of Science in Biology**

**Supervisor : Asistant Prof. Yılmaz KAYA**

**Co-Supervisor : Prof. Dr. Musa TÜRKER**

**2018, 55 Pages**

Human have needed to classify the objects and organisms around them. In the classification system called systematic or taxonomy, firstly morphological characters are used. Along with the developments in scientific studies, molecular biology, anatomy and caryology fields have also been included in systematic science. Because of the high number of species of biological organisms, similar and different characters, the classification system was supported by special programs and techniques.

In the thesis, a computer vision based method has been proposed as an alternative to classical diagnostic methods for the determination of butterfly species. Characteristic butterfly wing texture images were used for the classification of butterfly species. In this study, LBP and GLCM image processing methods were used to extract effective properties from butterfly images. The detection of butterfly species was carried out in two stages. In the first stage, the attributes were obtained, and in the second stage, these attributes were performed by 10-fold cross validation test using ELM machine learning method. At the end of the study, classification success was obtained as 91.6031%. As a result, the proposed computer vision method will be supportive to alternative methods in the classification of butterfly species.

**Keywords:** Lepidoptera, LBP, GLCM, ELM, image processing, butterfly identification

## 1. GİRİŞ

Böcekler (*Insecta*), hayvanlar aleminde bir buçuk milyon tür ile temsil edilen en kalabalık sınıftır. En yakın akrabaları Trichoptera'lerden, kanatlarında kıl yerine pul bulunmasıyla ve ergininde emici tipteki ağız parçalarıyla ayırt edilen *Lepidoptera* (kelebek ve güveler) takımı, sahip olduğu 170.000'den fazla türüyle böcekler arasındaki en zengin takımlardan biridir. Türkiye, 5000'den çok Lepidoptera türü ile bölgenin zengin ülkeleri arasında sayılır. Komşularımızdan İran'da 2640, Irak'ta 1122, İsrail ve Lübnan'da ayrı ayrı 851, Pakistan'da 715, Afganistan'da 1351, Ürdün'de ise 308 Lepidoptera türü bilinmektedir. Buna karşılık günümüzde Güney Avrupa ülkelerinden İspanya'da 4336, Fransa'da ise 4803 Lepidoptera türü bilinmektedir. Türkiye de ise bu sayı son güncel verilere göre 5577 taksondur (Koçak ve Kemal, 2018). Türkiye ve Ortadoğu ülkelerinde ulaşılan tür sayıları araştırmaların yetersiz olmasından dolayı çok düşük düzeydedir.

Dünyada kelebeklerin tahmini sayısı 17-18000 kadardır. Güveler kelebeklere göre yaklaşık 10 kat daha zengindir. Türkiye'de kelebekler 412 tür ile temsil edilirken bu sayının 369'u Papilionoidea, 43'i ise Hesperioidea üst familyalarına aittir. Lycaenidae familyasından ise 179 tür bilinmektedir (Koçak ve Kemal, 2018).

Van ilinden ise 99 Lycaenidae türü kaydedilmiştir (Kayci, 2007; Özkol, 2007; Koçak ve Kemal, 2018). Araştırma materyallerini oluşturan 39 Lycaenid türü Ereğ Dağı'ndan (Van) toplanmıştır.

Kelebek ve güvelerin; kanatları, morfolojik özellikleri, desen ve renkleri az veya çok oranda farklılık gösterir. Türe özgü olan bu özellikler, türlerin ayırımında önemli rol oynarlar. Bu tip özellikler türler içinde taksonomik karakterler olarak kullanılırken, bazen birbirine morfolojik olarak çok benzeyen türlerin ayırımında, ayırt edici karakter sayısı daha fazla olduğundan özellikle erkek bireylerde olmak üzere, genital organlarının yapısal özelliklerinin incelenmesine gerek duyulur. Son yıllarda giderek önem kazanan karyolojik araştırmalar sonucunda bazı *Agrodiaetus* (Lycaenidae) türlerinde (Lycaenidae) türlerin kromozom sayılarının ve boylarının tür ayırımında önemli olduğu anlaşılmıştır. *Pontia daplidice* ve *Pontia edusa* gibi tür ayırımı zor olan bazı taksonların aminoasitleri üzerine yapılan araştırmalarla ayrı türler olduğu sonucuna varılmıştır. Bu ayırımı, söz konusu taksonların genital yapıları da bir dereceye kadar desteklemektedir.

Büyüklik açısından kelebek ve güve türleri geniş bir varyasyon gösterir. Ancak bu değişkenlik tür içinde belli bir seviyede sabit kalırsa, o takdirde taksonomik karakter olarak değerlendirilebilir. Güvelerin kanat genişlikleri ölçüldüğünde boyları 2 mm'den (Nepticulidae), 320 mm'ye kadar (*Attacus atlas*) değişebilir. Türkiye'deki en büyük güve yaklaşık 180 mm kanat genişliği ile *Saturnia pyri* (*Saturniidae*), en büyük kelebek ise kanat genişliği ortalama 100 mm olan *Parnassius apollo*'dur.

Bir kelebeğin gelişimi birbirinden çok farklı dört safhada tamamlanmaktadır (holometabol). Kelebek ve güvelerin sistematigi ve sınıflandırması başlangıçtan beri ergin bireyin taşıdığı özellikler üzerine dayandırılmıştır. Baş üzerinde ağız parçaları, anten tipleri, göğüste kanat şekli damarlanma tipleri ve üzerini örten pulların oluşturduğu renk ve desenlerin yanı sıra, bacakların morfolojik özellikleri uzun yıllar bu amaçla değerlendirilmiştir. Geçen yüzyılın başında erkek veya dişi dış genital organların taşıdığı, türden türe değişen fakat tür içinde sabit kalan morfolojik özellikler tür ayırımında ve sınıflandırmada yaygın biçimde kullanılmıştır. Yaklaşık son 50 yıl içerisinde ergin birey üzerindeki karyolojik çalışmalar bilime önemli katkılar sağlamıştır.

Kelebek ve güvelerin yumurta, larva ve pupa safhalarının morfolojisi hakkındaki bilgilerimiz uzun yıllar eksik kalmıştır. Bu nedenle söz edilen safhaların taşıdıkları karakterler sınıflandırma çalışmalarında ihmal edilmiştir. Ancak son yıllarda gerek yumurta gerekse larva ve pupa safhalarının özellikleri bilhassa yüksek kategorilerdeki taksonların (tribus, familya gibi) sistematiginde kullanılmaya başlamıştır.

Doğada Lepidoptera'lerle bitkiler arasında ekolojik yönden sıkı bir ilişki görülür. Kelebekler çiçeklerdeki nektarla beslenirken bu sırada vücutlarına yapışan polenleri çeşitli bitki bireylerine taşıyarak tozlaşmaya katkıda bulunurlar. Bir habitatta bitkilerin varlığı kelebeklerin beslenmesinden ziyade tırtulların gelişimi açısından hayati öneme sahiptir.

Bazı kelebek türleri beslenme açısından geniş bir ekolojik tercihe sahip olduklarından birçok bitki üzerinde yaşayabilmektedir. Ekolojik hoşgörü sınırları dar olan türler ise daha seçici davrandıklarından sadece belirli bitkiler üzerinde beslenebilmektedirler. Bu açıdan değerlendirilirse bir bölgenin bitki örtüsü genel olarak o bölgenin kelebek faunası üzerinde birinci derecede etkilidir.

Bunun yanı sıra Lepidopter'lerin yumurta, larva ve ergin dönemlerdeki ekolojik isteklerindeki farklılıklar, değişik fiziksel özelliklere sahip habitatları tercih etmelerinde, değişik iklim özellikleri gösteren bölgelerde barınmalarında etkindir. Bu

seçicilikleri özellikle kelebekleri belli yerlerdeki doğal koşulların elverişli olup olmaması konusunda araştırmacının bir karara varmasında yararlı olur. Bu yönüyle kelebekler önemli biyolojik indikatörlerdir.

Lepidoptera'lerin larva, pupa ve ergin dönemleri kuş, kertenkele, kurbağa gibi omurgalılarla ve çeşitli yırtıcı eklembacaklıların besin kaynağını teşkil ederler. Bu nedenle yaşam bölgesindeki besin zincirinde önemli bir yeri vardır.

Kelebeklerin çoğunlukla bozulmamış doğal çevrelerini yaşam ortamı olarak tercih etmelerine karşılık, ekolojik toleransı yüksek olan bazı türler, doğal olmayan çevrelerde, sanayileşmiş, şehirleşmiş bölgelerde ve tarım alanlarında da yaşamlarını sürdürebilmektedir (*Pieris* türleri, *Cynthia cardui* gibi).

Lepidoptera'ler kendi aralarında sınıflandırılırken öncelikle dış morfolojik özelliklerine göre sınıflandırılır. Dış morfolojik özelliklerine göre sınıflandırmanın gerçekleştirilemediği durumlarda teşhis için genital karakterler incelenir. Son yıllarda bilim adamları tarafından bu teşhis karakterlerine moleküler düzeyde çalışmalar da eklenerek teşhisin daha kesin yapılmasına olanak sağlanmıştır. Sonradan yapılan tüm bu çalışmalar özellikle teşhislerde kullanılan morfolojik karakterler için tamamen belirleyici olmamakla beraber destekleyici nitelikte olmuştur. Bu çalışma ile beraber teşhis için kullanılan dış morfolojik özelliklere bu canlılardaki doku özelliklerinin de belirleyici olduğu gösterilmeye çalışılmıştır.

Bu çalışmanın amacı kelebek türlerini doğru tespit eden ve sınıflandıran otomatik bir makine görme (computer-vision) sistemi tasarlamaktır. İki aşamadan oluşan çalışmada öncelikle kelebek görüntülerinden doku ve renk özellikleri elde edilmiş, daha sonra bu özellikler kullanılarak aşırı öğrenme makinesi (Extreme Learning Machine=ELM) ile sınıflandırma işlemi gerçekleştirilmiştir. Doku, bir görüntünün yüzeyine ait bir özelliktir (Kaya ve ark., 2015). Görüntü yüzeyindeki bir doku veya desenin düzenli tekrarı olarak ifade edilebilir. Bir görüntüye ait bölgeler farklı renk, parlaklık ve dokulara sahip olabilir.

Biyolojik görüntülerin bilgisayar tabanlı doku analizi, görüntü üzerindeki dokuların matematiksel olarak ifade edilmesidir. Kelebek görüntüleri için görüntülerdeki dokular türlere göre farklılık gösterebilir. Görüntülerdeki dokular görüntü hakkında bilgiler içerir.

Doku, bir görüntünün ilgili alanlarının veya bölgelerinin tanımlanmasında kullanılan önemli özelliklerden biri olup benzer yapıların topluluğu şeklinde ifade edilir (Alam ve Faruqi, 2011). Dokular varlıkların ve sahnelerin, karakteristik parlaklık,

renk, eğim, boyut şekil gibi doğal özelliklerini belirten görsel desenlerdir. Dolayısıyla, doku bir görüntüde bir benzerlik grubu olarak kabul edilebilir. Başka bir tanımda, görüntülerin dokusu, görüntü içindeki bir nesnenin parçalarının görünüşü, yapısı ve düzenini ifade eder (Castellano ve ark., 2004; Zhang ve ark., 2017).

Doku analizi görüntüyü anlama, sınıflama ve yorumlama yapmamızı sağlayan yöntemlerdir. Görüntü işleme ve bilgisayar görü sistemlerinde önemli bir rol oynayan doku analizi, uzaktan algılama, tıbbi görüntü analizi, belge analizi, yüz tanıma, parmak izi tanıma medikal sistemler ve gerçek dış mekan görüntülerinin sınıflandırılması gibi uygulamalarda yaygın olarak kullanılmaktadır (Liu ve ark., 2012; Zhao ve ark., 2016). Doku analizi yoğun bir araştırma alanı olmakla birlikte, gerçek dünya dokularının analiz edilmesi, ışık, ölçek değişiklikleri ve doku yüzeylerdeki değişkenlik nedeniyle doku analizi zor olmaktadır. Doku sınıflandırma genellikle şu aşamalardan oluşur.

(1) Görüntüyü sonraki aşamaya uygun hale getirmek için görüntü üzerinde dönüşüm, (2) görüntüyü bir özellik vektörüne dönüştürme diğer bir deyişle özellik çıkarımı, (3) çıkarılan özellikleri kullanarak görüntülerin ilgili sınıfa atama işlemi (Caputo ve ark., 2010; Nguyen ve ark., 2016). Genel olarak doku sınıflandırma gri tonlu görüntüler için gerçekleştirilmektedir. Renkli doku görüntüler gri renklere dönüştürüldükten sonra kullanılmaktalar.

Son yıllarda doku analizi için çeşitli yaklaşımlar önerilmiştir. Bu yaklaşımların çoğu yapısal, model temelli, istatistiksel (histogram, mutlak gradyan, çalışma uzunluğu matrisi, ortak oluşum matrisi, oto-regresif model, dalgacıklar) ve dönüşüm bazlı yöntemlere dayanmaktadır (Castellano ve ark., 2004; Maani ve ark., 2013; Zhu, 2015).

Uygulamada en yaygın kullanılan yöntemler Local Binary Pattern (LBP), Greylevelco-occurrencematrix (GLCM) yöntemleridir. LBP, Ojala, T. ve Pietikäinen, M. (1999) tarafından önerilmiş doku sınıflandırma için kullanılan etkili en basit istatistiksel yaklaşımlardan biridir. Bir görüntünün veya görüntüdeki bir yerel yapının istatistiksel olarak yoğunluğunu belirtir. LBP görüntüdeki her pikseli, pikselin etrafında dairesel olarak oluşan komşu pikseller ile karşılaştırır (Pan ve ark., 2017).

LBP yaklaşımı, merkez pikselin ve komşularının yerel farklılıklarının merkezi pikselin kendisinden bağımsız olduğu varsayımına dayanmaktadır. Pikseller arasındaki ilişkiler ikili örüntüler ile ifade edilir. LBP'nin başlıca avantajları: (1) güçlü bir ayırt edici, (2) diğer yöntemlere göre daha hesaplama maliyeti, (3) basit uygulanabilir olması. Bu avantajlardan dolayı, LBP doku analizi (Ojala ve ark., 1996; Ojala ve Pietikäinen 1999), yüz ve yüz ifadesi tanıma (Ahonen ve ark., 2006; Zhao ve Pietikainen, 2007;

Zhou ve ark., 2013; Liu ve ark., 2013), çevre modelleme (Pietikäinen ve ark., 2004), biyomedikal görüntü işleme (Nanni ve ark., 2012), uzaktan algılama (Lucieer ve ark., 2005), parmak izi tanıma (Nanni ve Lumuni, 2008), gerçek dış mekan sınıflandırma (García ve Puig, 2008), gıda sınıflandırma (Zheng ve ark., 2006; Cernadas ve ark., 2005) gibi sayısız uygulamalarda kullanılmaktadır.

GLCM görüntü üzerindeki bazı karakteristik özellikleri ölçmemize yarayan istatistiksel bir metottur (Guo ve ark., 2010). GLCM tıp, mühendislik, biyoloji, ziraat, uzaktan algılama gibi farklı alanlarda kullanılır.

LBP ve GLCM ile elde edilen dokusal özellikler aşırı öğrenme makinesi (Extreme Learning Machine=ELM) sınıflandırma yöntemi ile kullanılarak kelebek türü teşhisi gerçekleştirilmiştir. ELM ileri beslemeli tek gizli katmanlı bir yapay sinir ağı modelidir. Bu modelde giriş ve gizli katmandaki sinir hücrelerine ait ağırlıkları ve eşik değerleri rastgele üretilir. Ancak çıkış katmandaki sinir hücre ağırlıkları matematiksel olarak elde edilir. Bu modelin en önemli özelliği öğrenme sürecinin çok hızlı gerçekleşiyor olmasıdır.

Bu çalışmada LBP+ELM ve GLCM+ELM şeklinde iki farklı yaklaşım kullanılmıştır. LBP ve GLCM ile öznitelikler vektörleri oluşturulur. Bu öznitelik vektörleri kullanılarak ELM ile kelebek türü teşhisi gerçekleştirilmiştir.

Biyolojik tür tanımlaması ve teşhisi, çalışmaların ilk basamağını oluşturan temel aşamadır. Biyoçeşitliliği tanımlanması geleneksel, olarak taksonomistler tarafından sağlanan morfolojik çalışmalar ve tanımlara dayanmaktadır. Sadece taksonomistler ve eğitilmiş teknisyenler gibi uzmanlar taksonu doğru bir şekilde tanımlar. Bunun içinde özel beceri ve tecrübe gereklidir. Ancak deneyimli taksonomist sayısı gün geçtikçe büyük ölçüde azalmaktadır. Sonuç olarak bu çalışma ile beraber teşhis için kullanılan dış morfolojik özelliklere dayanarak canlılardaki doku özelliklerinin de tanımlama ve teşhiste belirleyici olduğu gösterilmeye çalışılacaktır.

## 2. LİTERATÜR BİLDİRİŞLERİ

Böcek, kelebek, bitki gibi biyolojik türlere ait görüntülerden elde edilen imaj ve özelliklerin kullanılarak, otomatik olarak tanımlanmasına olan ilginin gün geçtikçe arttığı görülmektedir. Bu konu ile ilgili birçok metot ve yöntem öneren çalışmalara rastlanılmaktadır. Entomoloji bilimi, biyoloji alanında birçok uygulamaya sahiptir (patoloji, sistematik, filogeni, polinizasyon). Artan bir biyolojik talebi karşılamak ve azalan bir işgücü miktarını telafi etmek için, bilgisayar bilimcileri ve biyologların kendi aralarındaki işbirliği uzun yıllardır ele alınmaktadır.

Wang ve ark. (2012), böcek grubuna ait canlıların tanımlanması amacı ile daha uygun sonuç verme nedeni ile içerik tabanlı görüntü alma, (CBIR: Content-based image retrieval) sistemini kullanmışlardır. Araştırmacılar, böcek familyasının taksonomik olarak tanımlanmasına yardımcı olacak kelebek görüntülerine ait bir dizi şekil, renk ve doku özelliği geliştirmişlerdir. Yaptıkları çalışmada Papilionidae familyasının teşhis doğruluğunun % 84'e ulaştığını ileri sürmüşlerdir. Sonuç olarak içerik tabanlı görüntü alma (CBIR) sisteminin kelebeklerin familya seviyesinde tanımlanması için uygun olduğunu rapor etmişlerdir. Yapılan aynı çalışmada ayrıca, farklı özellikler ve benzerlik eşleme algoritmaları ile sonuçlar karşılaştırılmıştır. Tür çeşitliliği, görüntü kalitesi ve çözünürlük gibi veri özelliklerinin, sistem başarısını en çok etkileyen özelliklerin başında olduğunu belirtmişlerdir. Sonuç olarak kelebek familyalarının tanımlanmasında şekil özelliklerinin, renk veya doku özelliklerinden daha önemli olduğunu rapor etmişlerdir.

Martineau ve ark. (2017), yaptıkları “Görüntü tabanlı böcek sınıflandırması üzerine” yaptıkları derleme çalışmasında özellikle “normal aydınlatma ve çekim” koşullarına sahip resimler, yani görüntülerin standart kameralar tarafından alındığı, 2D 'yi işleyebilen yöntemlerle ilgilenmişlerdir. Çalışmada, görüntü özellikleri ayıklayan sistemler üzerine yoğunlaşarak hayvanların bilinen ve doğru bir sınıflandırma sistemi şeklinde ayırmayı hedeflemişlerdir. Görüntülerden özellik çıkarma çalışmalarında iki nokta üzerine odaklanılmıştır. Veri çıkarma aşaması olan segmentasyon aşamasında canlı veya objenin izole edilecek kısmı (algılama için ön plan / arka plan seçimi) ve türlerin ayırımı için kullanılacak özellikleri (yerel, global ve hangi bilgi modeli). Sonuç kısmına gelindiğinde ise araştırmacıların genellikle ayıklanan özellikleri kullanarak örnek verilerdeki tanıma oranını en üst düzeye çıkaracak bir dizi sınıflandırıcı metodun kullanıldığını ileri sürmüşlerdir. Çoğu durumda, her çalışma hem görüntülerin

yakalanması hem de sınıflandırma verilerine odaklandığı için, neredeyse her makalenin kendine ait bir veri kümesi oluşmaktadır.

Kang ve ark. (2012), gerçekleştirdikleri çalışmada, yedi kelebek türünden, *Dilipa fenestra*, *Graphium sarpedon*, *Libythea celtis*, *Luehdorfia puziloi*, *Papilio maackii*, *Papilio xuthus* ve *Parantica sita* toplam 268 örnek görüntü kullanmışlardır. Her örneğin sol kanadı orijinal görüntüden ayrılmış ve  $379 \times 567$  piksel çözünürlükte bir ikili görüntüye dönüştürülmüştür. Türleri tanımlamak için sınır şekil görüntülere ait veritabanı kullanılmıştır. Görüntü koleksiyonunun üçte ikisi eğitim verileri olarak, kalan üçte biri doğrulama veri seti olarak kullanılmıştır. Çalışmada desen sınıflandırıcı çok sınıflı tek bir sinir ağı önerilmiştir. Yapay sinir ağına dayalı olarak önerilen tür tanımlama sistemi için BLS (Branch Length Similarity) entropi profilleri kullanılmıştır. Tüm görüntüler ikili görüntülere dönüştürülmüş, daha sonra sol kanadın sınır şekilleri ayrılmıştır. Şeklin sınırı boyunca 360 eşit dağılmış nokta seçilmiş ve seçilen her nokta için BLS entropisini hesaplanmıştır. Görüntülerin sınır pikseller için hesaplanan BLS entropileri, kelebek türlerinin tanımlanması için yüksek bir doğruluk oranı (% 86'dan fazla) sağlamıştır. Ek olarak, eğitim verilerinin ayarlanması için sistemin sadece birkaç dakika sürmesi gerektiği ileri sürülmüştür.

Yine Kang ve ark. (2014), yaptıkları geliştirme çalışmasında BLS yöntemini, entropi profilinin bölünmesi yoluyla kelebek türlerinin tanımlanmasına uygulanmasını kolaylaştırmak için değiştirme yoluna gitmişlerdir. Test grubu olarak, her tür grubu 10 örnekten oluşan; *Colias erat*, *Parnassius bremeri*, *Eurema hecabe*, *Gonepteryx rhamni* ve *Papilio maackii* kelebek türleri kullanılmıştır. Türleri tanımlamak için kanat şekilleri kullanılmıştır. Kanat şekilleri için sınır piksellerinin saat yönünün tersi yönünde eşit aralıklı x – y koordinatları çıkarılmıştır. Elde edilen piksel sayısı 749 olarak belirlenmiş, ardından 749 x-y çiftini 15 gruba ayrılmıştır. Gruplar için hesaplanmış entropi profilleri oluşturulmuş ve profillerin ağırlık noktaları değerlendirilmiştir. Sonuç olarak, bir kanat şekli için elde edilen tüm entropi profilleri, tek bir ağırlıklı BLS ile sonuçlanan değer ile birleştirildi. Daha sonra, ağırlıklı BLS profilleri arasındaki korelasyon katsayısı istatistiksel olarak karşılaştırılmıştır. Deney sonuçlarına göre, bu yöntemin kelebek türlerinin tanımlanması için istatistiksel olarak daha başarılı olduğu ileri sürülmüştür.

Kelebek türlerinin tanımlanması önemlidir. Çünkü bunlar doğrudan insan ve hayvan tüketimi için kullanılan bitkiler ile ilişkilidir. Ancak, kelebek tanımlama için



yaygın olarak kullanılan güvenilir yöntemler kelebeklerin karmaşık şekilleri nedeniyle verimli ve etkin olarak değerlendirilememektedir. Arazide, kelebek görüntüleri genellikle kelebeğin durduğu konum ve görüntüleyici durumu nedeniyle kamera tarafından farklı açılardan yakalanır, farklı açılardan bakıldığında bir kelebek için çeşitli şekillerin oluştuğu görülür. Yapılan bir çalışmada yine BLS yöntemi kullanılarak kelebeklerin farklı açılardan (dikey olarak ayarlanabilir açı için,  $\theta = \pm 10^\circ, \pm 20^\circ, \dots, \pm 60^\circ$  ve yatay olarak ayarlanabilir açı için,  $\phi = \pm 10^\circ, \pm 20^\circ, \dots, \pm 60^\circ$ ) elde edilen görüntüleri kullanılmıştır. Üst görünüşten yakalanan şekiller  $\theta$  ve  $\phi$  açıları ile döndürülmüş bir düzleme ile yansıtılmış görüntüler elde edilmiştir. Sinir ağı için eğitim verileri olarak farklı  $\theta$  ve  $\phi$  değerlerine sahip çıkarılan şekiller kullanılmış ve test verileri olarak diğer şekiller kullanılmıştır. Deneysel sonuçlar, yöntemimizin çeşitli kelebek şekillerini başarıyla tanımladığını göstermiştir.

Güveler, kelebekler, örümcekler, bukalemunlar ve bir kaç deniz türünü içeren çeşitli hayvanlarda biyolojik adaptasyonlu renklenme gözlemlenmektedir. Orenstein ve ark. (2016) yaptığı çalışmada, kamuflaj gibi karmaşık bir veri kümesinin işlenmesinin bile otomatik bir segmentasyon ve sınıflandırma iş akışı sunmaktadır. Çalışmada, yedi mürekkep balığı örnekleri, toplam 25 olası durum için ayrı ayrı beş farklı alt ve beş yan model görüntü kombinasyonları elde edilmiştir. Mürekkep balığına ait görüntüler, görüntüyü eşikleyen yoğunluk veya HOG (Histogram of Oriented Gradients) yöntemi kullanılarak çıkarılmıştır. HOG prosedürü için; 1-D filtresi kullanarak görüntü gradyanını hesaplanmış, belirtilen sayıda hücre ile histogramları belirtilen boyuttaki hücreler üzerinde üretim yapılmış ve son olarak aydınlatmayı geliştirmek için belirtilen boyuttaki blokları birleştirdikten sonra hücreler normalize edilmiştir. Mürekkep balığı resimleri, texton tabanlı eklem sınıflandırıcısı kullanılarak sınıflandırılmıştır. Eğitim kümesinde her pikselin etrafında bir  $N \times N$  komşusu seçilerek Textonlar oluşturulmuştur. Çalışma sonunda kamuflaj görüntüleri için sınıflandırıcısının görüntüleri, % 95'lik bir doğruluk ile başarı elde ettiği tespit edilmiştir (Orenstein ve ark., 2016).

Kelebekler öncelikle dış morfolojik özelliklerine göre sınıflandırılır. Dış morfolojik özelliklerine göre sınıflandırma mümkün olmadığı durumlarda, genital karakterlerin analiz edilmesi gerekmektedir. Bir kelebeğin genital özelliklerinin belirlenmesi için çeşitli kimyasal maddeler ve yöntemler kullanılmalıdır. Ayrıca bazı kelebeklerin tanımlanması için pahalı olan moleküler teknikler uygulanmalıdır.

Geleneksel teşhis yöntemlerine alternatif olarak kelebek türlerini otomatik olarak tanımlamak için bir bilgisayar öğrenme yöntemi uygulanmıştır (Kaya ve ark. 2015). Çalışma, yerel ikili desen (LBP) ve yapay sinir ağına (YSA) dayanmaktadır. Önerilen yöntemin etkililiğini değerlendirmek için beş türe ait 50 kelebek resmi kullanılmıştır. Yapılan çalışmanın deneysel sonuçları, önerilen yöntemin, kelebek türlerini iyi bir şekilde tanımlandığını göstermiştir. Sonuç olarak LBP öğrenme yöntemine dayalı kelebek tanımlamanın en iyi sınıflandırma sonucuna (% 98) sahip olduğu tespit edilmiştir.

Yılmaz ve ark. (2014), yaptıkları çalışmada kelebek teşhisi için klasik teşhis yöntemlerine alternatif web tabanlı bir içerik tabanlı görüntü erişim (İTGE) görü sistemi önermişlerdir. Yapılan çalışmada Papilionidae, Pieridae familyalarından 38 farklı kelebek türüne ait 380 görüntü ile işlem yapılmıştır. Kelebek türlerine ait görüntülerin karşılaştırılması için yapısal benzerlik indeks metodu (structural similarity index measurement (SSIM)) kullanılmıştır. Çalışmada elde edilen sonuçlara göre önerilen SSIM yöntemin kelebek görüntülerin sınıflandırılmasında yüksek oranda başarı gösterdiği saptanmıştır.

Kaya ve ark. (2013) bir diğer çalışmalarında çok ölçekli LBP yöntemi kullanılarak kelebek görüntüleri sınıflandırılmıştır. Satyridae familyasına ait 14 kelebek türünün 140 adet görüntüsü kullanılmıştır. Kelebek tanımlama işlemi, ANB, SVM ve LR sınıflandırma yöntemleri için girdi olarak  $LBP_{P, R}$  nitelikleri kullanılarak gerçekleştirilmiştir.  $LBP_{P, R}$  parametresi için farklı parametreler için elde edilen makro ve mikro modeller ile % 100 sınıflandırma elde edilmiştir.

### 3. MATERYAL VE YÖNTEM

#### 3.1. Materyal

Çalışma ile ilgili inceleme materyali Van, Erek Dağı'nda 2002 Mayıs ayı ile 2003 Ağustos ayları arasında toplanmıştır. Arazi çalışmaları 1800–3200 metre yükseklikleri arasında yapılmıştır. Kelebekler arazide tül atrap kullanılarak yakalanmıştır. Etil asetat içeren kavanozlarda öldürüldükten sonra önceden hazırlanmış özel zarflarının içerisine gerekli toplama bilgilerini içeren etiketiyle birlikte konmuştur. Arazi çalışmalarının tamamlanmasından sonra geçici saklama kutularındaki örnekler yumuşatma kaplarına alınmıştır. Burada 2–3 günde yumuşayan örnekler uygun numaradaki standart böcek iğneleriyle iğnelenmiştir. Bu örnekler standart müze materyali şeklinde hazırlanmak üzere germe tahtalarında gerilerek kurutulmuştur. Kurutma işlemi 50–55 °C'ye ayarlanmış etüvde bir hafta sürmüştür.

Germe tahtalarından çıkartılan örneklere lokalite etiketleri ilave edilmiş ve koleksiyon çekmecelerine tasnif edilerek yerleştirilmiştir. Örneklerin teşhisinde dış ve iç morfolojik özellikler göz önünde bulundurulmuştur. Dış morfolojik özelliklere bağlı olarak yapılan teşhislerde, baş ve göğüs üzerindeki organ ve ekstremitelerin morfolojik özelliklerinin yanı sıra kanatların alt ve üst yüzlerindeki renk ve desenler dikkate alınmıştır. Taşıdıkları dış morfolojik özelliklerinden teşhis edilemeyen bazı örneklerin erkek genital organlarının preparatları hazırlanmıştır. Teşhis, bu yapıların özelliklerinin ilgili yayınlardaki genital yapılarla karşılaştırılması suretiyle yapılmıştır. Türlerin teşhisinde çeşitli el kitapları, revizyon çalışmaları ve karşılaştırma materyalleri kullanılmıştır. Teşhiste: Carbonell (1993), Carbonell (1998), Skala (2003) Hesselbarth ve ark., (1995) ve Tolman (1997) yayınlarından yararlanılmıştır. Teşhis işlemi bittikten sonra örneklere bilimsel isimlerinin yazılı olduğu teşhis etiketleri iğnelenmiştir.

Çalışmada kullanılan türlerin doku ve renk özelliklerine göre teşhis edilmesi için beş türe ait dijital Nikon marka profesyonel makine ile çekilmiş yüksek çözünürlüklü 10'ar görüntü kullanılmıştır. Çalışmada 39 kelebek türü için hem üst hem de alt yüzlerine ait görüntüler kullanılmıştır. Alt yüz için 390 ve üst yüz için 390 toplamda 780 görüntü kullanılmıştır. Çalışmada kullanılan bir kısım kelebek için hem üst hem de alt yüzlerine ait görüntüler ve isimleri Şekil 3.1-3.2 ve tablo 3.1'de verilmiştir.



Şekil 3.1. Çalışmada kullanılan kelebeklere ait üst yüz görüntüleri



Şekil 3.2. Çalışmada kullanılan kelebeklere ait alt yüz görüntüleri

Çalışmada kullanılan kelebek türlerine kolaylık sağlanması amacı ile kodlama sistemi uygulanmıştır. Her bir türe ait kod numaraları tablo 3.1’de verilmiştir.

**Tablo 3.1.** Çalışmada kullanılan kelebek türleri ve kodları

Kod	Tür	Kod	Tür
T1	<i>Celastrina argiolus</i>	T21	<i>Polyommatus coelestinus</i>
T2	<i>Chilades trochylus</i>	T22	<i>Polyommatus corydonius</i>
T3	<i>Cupido osiris</i>	T23	<i>Polyommatus crassipunctus</i>
T4	<i>Glaucopsyche alexis</i>	T24	<i>Polyommatus daphnis</i>
T5	<i>Heodes alciphron</i>	T25	<i>Polyommatus icarus</i>
T6	<i>Heodes candens</i>	T26	<i>Polyommatus loewii</i>
T7	<i>Heodes tityrus</i>	T27	<i>Polyommatus thersites</i>
T8	<i>Heodes virgaureae</i>	T28	<i>Polyommatus alcedo</i>
T9	<i>Lampides boeticus</i>	T29	<i>Pseudophilotesvicrama</i>
T10	<i>Lycaena phlaeas</i>	T30	<i>Satyriumilicis</i>
T11	<i>Maculinea arion</i>	T31	<i>Satyriumspini</i>
T12	<i>Maculinea rebeli</i>	T32	<i>Thersamonia asabinus</i>
T13	<i>Margelycaena euphratica</i>	T33	<i>Thersamonia kefersteinii</i>
T14	<i>Plebejus argus</i>	T34	<i>Thersamonia kurdistanica</i>
T15	<i>Plebejus carmon</i>	T35	<i>Thersamonia lampon</i>
T16	<i>Plebujuş zephyrinus</i>	T36	<i>Tomares callimachus</i>
T17	<i>Polyommatus aedon</i>	T37	<i>Tomares desinens</i>
T18	<i>Polyommatus amandus</i>	T38	<i>Tomares romanovi</i>
T19	<i>Polyommatus bellargus</i>	T39	<i>Turanana endymion</i>
T20	<i>Polyommatus bellis</i>		

## 3.2. Yöntem

### 3.2.1. Gri Düzey Eş Oluşum Matrisi (Gray Level Co-Occurrence Matrix)

Doku, bir görüntüdeki nesnelere veya bölgelerin tanımlanmasında kullanılan önemli özelliklerden biridir. Doku, yüzeylerin yapısal durumu hakkında önemli bilgiler içermektedir. Gri ton uzamsal bağımlılıklara dayalı dokusal özellikler, resim sınıflandırmasında genel bir uygulanabilirliğe sahiptir. Gri Düzey Eş Oluşum Matrisi (Gray Level Co-Occurrence Matrix=GLCM) metodu Haralick ve arkadaşları (1973) tarafından farklı dokuların sınıflandırılması için önerilmiştir. GLCM geri seviye bağımlılık matrisi olarak da bilinir.

GLCM yöntemi piksel tabanlı bir görüntü işleme yöntemidir. Gri seviyeli bir görüntüden öznelik elde etmek için pikseller arasındaki ilişkiyi kullanan bir yaklaşımdır. GLCM matrisinin oluşturulması; pikseller arası uzaklık (D), piksellerin açısı ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  ve  $135^\circ=\theta$ ) ve dönüşümün yapılacağı gri ton seviye sayısı (maksimum 256) parametreleri temel alınarak yapılmaktadır. GLCM yönteminde öncelikle görüntü; belirlenen gri ton seviye sayısına göre yeniden ölçeklendirilmektedir. Oluşturulan GLCM matrisinde belirtilen gri tonuna sahip; yeniden ölçeklendirilmiş görüntüde belirlenmiş açı ve uzaklıkta bulunan komşu piksel adedinin toplamı atanmaktadır. GLCM metodunu aşağıdaki şekil üzerinde kısaca anlatalım. Şekil 3.3.(A) 0 ile 3 arasında dört gri tonlama değeri gösteren bir resim olarak varsayalım. Bir görüntü için GLCM şekil 3.3.(B) gibi hesaplanmaktadır. Burada #(i,j) belirtilen yön ve açıdaki koşulu sağlayan değerlerin sayısıdır.

0	0	1	1
0	0	1	1
0	2	2	2
2	2	3	3


(A)

Gray tone	0	1	2	3
0	#(0,0)	#(0,1)	#(0,2)	#(0,3)
1	#(1,0)	#(1,1)	#(1,2)	#(1,3)
2	#(2,0)	#(2,1)	#(2,2)	#(2,3)
3	#(3,0)	#(3,1)	#(3,2)	#(3,3)

(B)


Şekil 3.3.(A-B) GLCM Yöntem çalışma prensibi

Şekil 3.3.(A) görüntüsünden uzaklık ( $D=1$ ) ve piksellerin açısı ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  ve  $135^\circ$ )= $\theta=135^\circ$  ve  $d=1$  değerleri için GLCM matrislerini oluşturulmuştur (Şekil 3.4.).



**Şekil 3.4.** GLCM matrislerin farklı açılar için oluşturulması

Daha sonra bu GLCM matrisi normalize edilmektedir. Normalizasyon GLCM matrisin bir hücredeki değer toplam piksel sayısına oranıdır. GLCM matrisine ait istatistikî veriler kullanılarak görüntü analizi yapılmaktadır. GLCM matrisi gri tonundaki görüntünün Şekil 3.5.'de belirtilen işlem sırasına göre GLCM matrisi oluşturmaktadır (Kaya ve ark., 2014).



**Şekil 3.5.** GLCM Metodu çalışma prensibi

GLCM Matrisi açı ve mesafe parametrelerine bağlı olarak Eşitlik 1 ile ifade edilmektedir [11,13].

$$P(i, j, d, \varphi^o) = \# \left\{ \left( (k, l), (m, n) \right) \in D, \right. \\ \left. \left( (k - m), (l - n) \right) \in \{ -d, 0, d \}, I(k, l) = i, \right. \\ \left. I(m, n) = j, \angle \left( (k, l), (m, n) \right) = \varphi^o \right\} \quad (1)$$

Haralick GLCM matrisinden elde edilebilecek 14 adet doku özellik önermiştir. Bu doku özellikleri Tablo 3.2.'de verilmiştir. Ancak çalışmalarda enerji, korelasyon, kontrast ve homojenlik özellikleri tercih edilmektedir.

**1. Enerji:** Bu istatistik, birimlilik veya açısal ikinci moment olarak da adlandırılır. Dokusal düzgünlüğü ölçer. Piksel çift tekrarını belirtir. Yüksek enerji değerleri gri seviye dağılımı sabit veya periyodik bir formda olması durumunda gözlenir.

**2. Kontrast:** Bu istatistik bir görüntünün mekansal frekansını ölçer. Bitişik piksel setinin en yüksek ve en düşük değerleri arasındaki farktır. Görüntüdeki yerel varyasyonlar miktarını ölçer.

**3. Homojenlik:** Bu istatistik, Ters Diferansiyel Moment olarak da adlandırılır. Görüntü homojenliğini ölçer. Görüntünün tüm öğeleri aynı olduğunda, maksimum değeri vardır. GLCM kontrastı ve homojenliği, piksel çiftleri popülasyonunda eşdeğer dağılım açısından güçlü fakat tersine korelasyona sahiptir. Bu, eğer enerji sabit tutulurken kontrast artarsa homojenlik azalır demektir.

**4. Korelasyon:** Korelasyon özelliği, görüntüdeki gri tonlu doğrusal bağımlılıkların bir ölçüsüdür.



**Tablo 3.2.** Kelebek görüntülerinden elde edilen doku özelliklerine ait formüller


No	Özellik	Formül
1	Kontrast	$f_1 = \sum_{m=0}^{N_g-1} m^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{d,g^\circ}(i, j) \right\},  i-j =m$
2	Küme Eğilimi	$f_2 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (i+j-2u)^2 p\left(\frac{i}{j}\right), u = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} ip_{d,g^\circ}(i, j)$
3	Korelasyon	$f_3 = \frac{\sum_{i=1}^{N_g} \sum_{j=1}^{N_g} (ij) p_{d,g^\circ}(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$
4	Varyans	$f_4 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{d,g^\circ}(i, j) (i - \mu)^2$
5	Homojenlik	$f_5 = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} \frac{1}{1+(i-j)^2} p_{d,g^\circ}(i, j)$
6	Toplam Ortalama	$f_6 = \sum_{i=2}^{2N_g} ip_{x+y}(i)$
7	Toplam Entropi	$f_7 = - \sum_{i=2}^{2N_g} p_{x+y}(i) \log p_{x+y}(i)$
8	Toplam varyans	$f_8 = \sum_{i=2}^{2N_g} (i - f_7)^2 p_{x+y}(i)$
9	Entropi	$f_9 = - \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{d,g^\circ}(i, j) \log p_{d,g^\circ}(i, j)$
10	Varyans Farkı	$f_{10} = \text{variance of } \sum_{i=1}^{N_g} \sum_{j=1}^{N_g}  i-j  p_{d,g^\circ}(i, j)$
11	Entropi Farkı	$f_{11} = - \sum_{i=0}^{N_g-1} p_{x-y}(i) \log p_{x-y}(i)$
12	Azami Korelasyon Katsayısı	$f_{12} = \sum_m \frac{p_{d,g^\circ}(i, m) p_{d,g^\circ}(j, m)}{p_x(i) p_y(m)}$
13	Enerji	$f_{13} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{d,g^\circ}^2(i, j)$
14	Açısal İkinci Moment	$f_{14} = \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{d,g^\circ}(i, j)^2$

### 3.2. Yerel İkili Örüntüler Yöntemi

Yerel ikili örüntüler (Local Binary Pattern=LBP) LBP doku analizi operatörü, gri-seviyeden bağımsız bir doku ölçümü yöntemidir. Orijinal LBP operatörü, görüntünün her pikseli için bir etiket oluşturmaktadır. Bu etiket merkez pikselin 3x3 komşuluğundaki piksellerle karşılaştırılması sonucu elde edilen ikili bir sayıdır. Görüntüden elde edilen her piksel, kendisi ve komşuları arasındaki farkın basamak fonksiyonu ile ikilileştirilmesi sonucu elde edilir.

$$LBP_{P,R}(x_c) = \sum_{p=0}^{P-1} \mu(x_p - x_c)2^p, \quad \mu(y) = \begin{cases} 1, & y \geq 0 \text{ ise} \\ 0, & y < 0 \text{ ise} \end{cases}$$

Burada  $x_c$ , LBP etiketi üretilen merkez pikseli,  $x_p$ , merkez pikselin komşularını, R komşuların merkez piksele olan uzaklığını, P ise işleme sokulan komşu sayısını belirtir. Bu yapı çeşitli dairesel komşulukların kullanılabilceğini de göstermektedir. Böylece LBP ile farklı ölçekteki dokuların analizini gerçekleştirmek mümkün olmaktadır. Şekilde farklı LBP operatörlerine örnek verilmiştir.



**Şekil 3.6.** Komşu etiketlerin işlenmesi

Komşu etiketlerinin birbirleri ile birleştirilmesi sonucu ile elde edilen LBP değerleri merkez piksel için yeterli ve benzersiz bir tanımlayıcı değer olarak kullanılır. Şekil 3.6.'da LBP ile piksellerin etiketlenmesine ait bir örnek verilmiştir.



**Şekil 3.7.** Komşu etiket piksellerinin merkez piksel ile karşılaştırılması

Oluşturulan LBP değerlerin tümü doku analizinde kullanılmaz. Tanımlamada kullanılan düzgün örüntüler, ikili LBP kodunda 0-1 ya da 1-0 geçiş sayısı 2 ya da daha az olanlardır. Örneğin; 000000 ve 111111 örüntüleri 0 geçişe, 011000 ve 110011 örüntüleri 2 geçişe sahip olduklarından düzgündür (Şekil 3.7.). Fakat 4 geçişli 010100 ve 5 geçişli 010101 örüntüleri düzgün değildir. Yapılan çalışmalarda araştırılan doku yüzeylerinin büyük bir kısmının düzgün örüntülerden oluştuğu görülmektedir.

LBP histogramı çıkarılırken düzgün örüntüler kullanıldığından, histogramda her bir düzgün örüntü için bir bölme bulunurken, düzgün olmayan tüm örüntüler için bir bölme bulunmaktadır. Tüm örüntüler incelendiğinde 8 komşuluk için 256 farklı kod oluşmakta ve bunların 58 örüntü düzgün olmaktadır. Bu durumda LBP histogramı 59 bölmeye sahip olmaktadır.  $I(x,y)$  bir resim için 1 piksel uzaklıktaki 8 komşu için LBP histogramı aşağıdaki gibi elde edilmektedir.

$$H_i = \sum_{x_c \in I(x,y)} f \{LPB_{1,8}(x_c) = U(i)\}, i = 0,1,2 \dots n - 1, f(y) = \begin{cases} 1, y \text{ yanlış ise} \\ 0, y \text{ doğru ise} \end{cases}$$

Histogram üretiminde düzgün örüntüler dikkate alındığından  $n=58$ ,  $U(i)$  ise 8 komşulukta üretilen mümkün 256 farklı örüntüden düzgün 58 tanesini tutan dizidir. Bu histogram resim üzerindeki kenarlar, benekler, düz alanlar gibi mikro-örüntüler ile ilgili bilgi taşır. Görüntünün daha verimli bir gösterimi için oluşturmak için LBP histogramları kullanılır. Bu amaçla resim  $R_0, R_1, R_2, \dots R_{m-1}$  şeklinde  $m$  bölgeye ayrılıp her bölge için ayrı ayrı histogramlar elde edilir. Aşağıdaki gibi elde edilebilir.

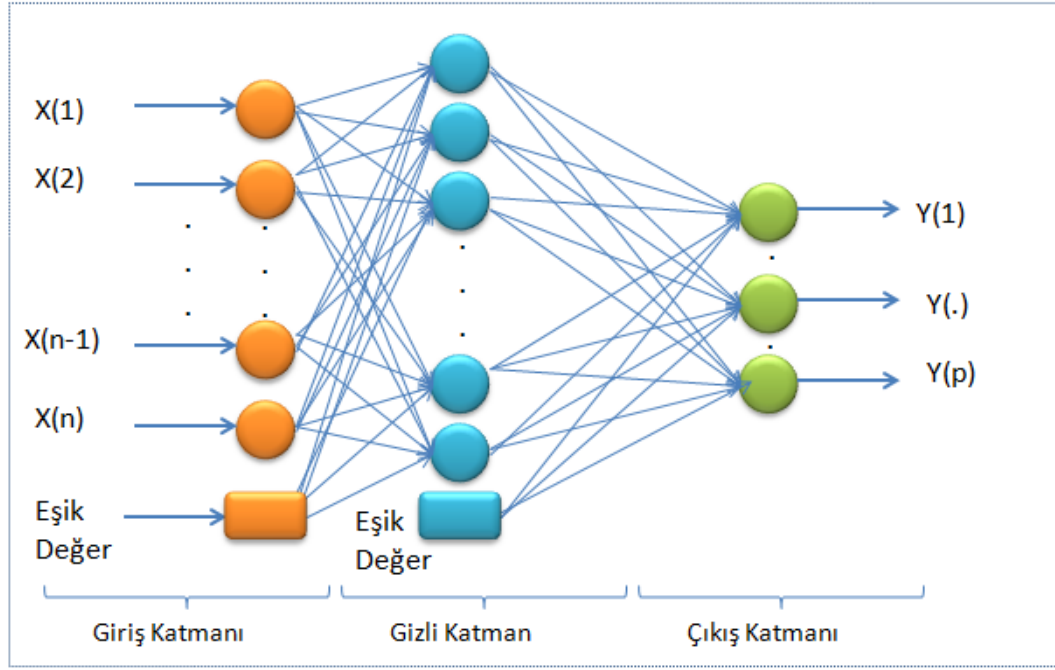
$$H_{i,j} = \sum_{x_c \in R_j} f \{LPB_{1,8}(x_c) = U(i)\}, i = 0,1,2 \dots n - 1, j = 0,1,2,3, \dots m - 1$$

$H_{i,j}$ , j. bölgeye ait LBP histogramdaki i. Değeri ifade etmektedir. Üretilen histogramlar birleştirilerek giriş resmi resmi için tek histogram elde edilir.

### 3.2.2. Aşırı Öğrenme Makinesi

Aşırı öğrenme makinesi (Extreme Learning Machine=ELM), giriş ağırlıkları rastgele çıkış ağırlıkları ise analitik olarak hesaplanan tek gizli katmanlı ileri beslemeli bir yapay sinir ağı (YSA) modelidir. ELM'de gizli katmanda sigmodial, sine, Gaussian ve hard-limitin gibi aktivasyon fonksiyonları yanında YSA'dan farklı olarak türevlenemeyen veya kesikli aktivasyon fonksiyonları da kullanılabilir (Suresh ve ark., 2010; Kaya ve ark., 2014).

Geleneksel ileri beslemeli yapay sinir ağlarının performansı momentum, öğrenme oranı vb. bazı parametrelere bağlıdır. Bu tür ağlarda ağırlıklar ve eşik değerler gibi parametrelerin gradyen temelli öğrenme algoritmaları ile güncellenmesi gerekir. Ancak iyi performansın sağlanması için öğrenme süreci hem zaman almakta hem de hata yerel bir noktaya takılabilmektedir. Momentum değerinin değiştirilmesi belki hatanın yerel bir noktaya takılmasını engelleyebilir ancak öğrenme sürecinin uzun sürmesini etkilemeyecektir. ELM de giriş ağırlıkları ve eşik değerleri rastgele üretilmekte ancak çıkış ağırlıkları analitik olarak elde edilmektedir (Huang ve ark., 2006). ELM ağı tek gizli katmanlı ileri beslemeli bir YSA modelinin özelleştirilmiş halidir. Şekil 3.8.'de tek gizli katmanlı ileri beslemeli bir YSA'na ait şekil gösterilmiştir.



Şekil 3.8. İleri beslemeli yapay sinir ağı

Burada  $X = (X_1, X_2, X_3 \dots X_N)$  giriş ve  $Y$  ise çıkış özelliklerini belirtmek üzere, gizli katmanda  $M$  nörona sahip ağ matematiksel olarak aşağıdaki gibi ifade edilir (Suresh ve ark., 2010).

$$\sum_{i=1}^M \beta_i g(W_i X_k + b_i) = O_k, \quad k = 1, 2 \dots \dots N \quad (2)$$

Burada  $W_i = (W_{i1}, W_{i2} \dots W_{in})$  giriş katmandaki  $\beta_i = (\beta_{i1}, \beta_{i2} \dots \beta_{im})$  çıkış katmandaki ağırlıkları,  $b_i$  gizli katman nöronların eşik değerlerini ve  $O_k$  çıkış değerlerini belirtir.  $g(.)$  aktivasyon fonksiyonudur (Hai-Jun ve ark., 2008).  $N$  giriş özellikli bir ağda amaç hatanın  $\sum_{k=1}^N (o_k - Y_k) = 0$  olması veya  $\min \|\sum_{k=1}^N (o_k - Y_k)^2\|$  hatanın elde edilmesidir. Dolayısıyla Eşitlik 2 aşağıdaki gibi yazılabilir (Huang ve ark., 2006).

$$\sum_{i=1}^M \beta_i g(W_i X_k + b_i) = Y_k, \quad k = 1, 2 \dots \dots N \quad (3)$$

Yukarıdaki eşitlikte,  $H\beta = Y$  yazılabilir (Huang ve ark., 2006 ).

Burada

$$H(W_1, \dots \dots W_M; b_1, \dots \dots b_M; X_1, \dots \dots X_N) = \begin{bmatrix} g(W_1 X_1 + b_1) & \dots & g(W_M X_1 + b_M) \\ \vdots & \ddots & \vdots \\ g(W_1 X_N + b_1) & \dots & g(W_M X_N + b_M) \end{bmatrix} \quad (5)$$

ve

$$\beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_M^T \end{bmatrix}_{M \times m} \quad \text{ve} \quad Y = \begin{bmatrix} Y_1^T \\ \vdots \\ Y_N^T \end{bmatrix}_{N \times m} \quad (6)$$

şeklinde ifade edilebilir (Huang ve ark., 2006 ). Burada  $H$  gizli katman çıkış matrisidir. Geleneksel ileri beslemeli bir YSA da ağırlık eğitilmesi, ELM 'de  $H\beta = Y$  doğrusal denklemde en küçük kareler çözümünün aranmasıdır. ELM algoritması üç adımda aşağıdaki gibi özetlenebilir (Handoko ve ark., 2006; Yuan ve ark., 2011).

1. **Aşama:**  $W_i = (W_{i1}, W_{i2} \dots W_{in})$  giriş ağırlıkları ve gizli katman  $b_i$  eşik değerleri rastgele üretilir.
2. **Aşama:**  $H$  gizli katman çıkışı hesaplanır.
3. **Aşama:**  $\hat{\beta}$  çıkış ağırlıkları  $\hat{\beta} = H^+Y$  göre hesaplanır.  $Y$  karar özelliğidir.

### 3.3. Kelebek Tanıma Diyagramları

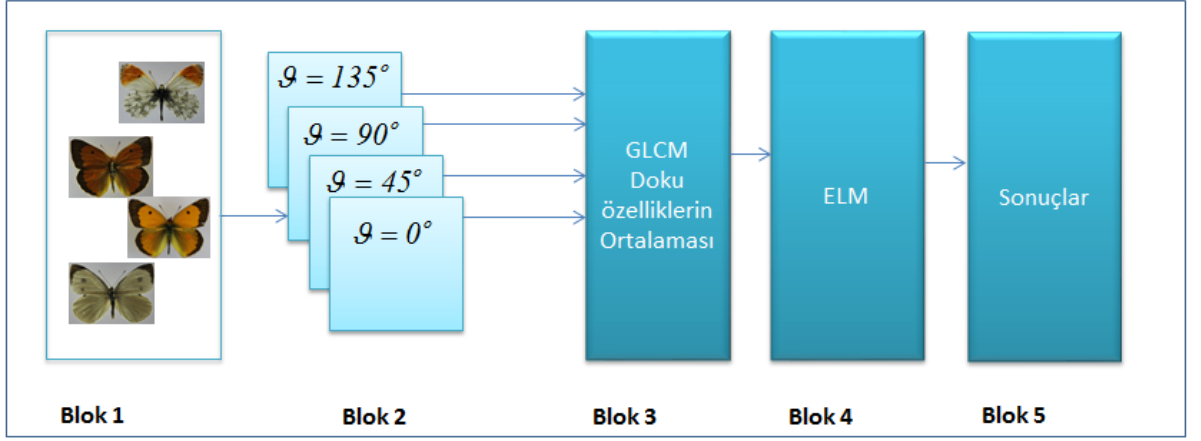
Bu çalışmada kelebek türünün tespiti için GLCM- ELM ve LBP-ELEM tabanlı iki model önerilmiştir. Bu çalışmada kullanılan modellere ait diyagramlar aşağıdaki şekillerde gösterilmiştir. Dört bloktan oluşan çalışmada her bloktaki işlemler kısaca aşağıdaki gibi özetlenebilir.

**Blok 1:** Sekiz bitki türüne ait farklı pozisyonlardaki toplam altmış dört (64) kelebek görüntüsünden on dört (14) doku özelliğinin elde edilmesi.

**Blok 2:** Dört farklı yön ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  ve  $135^\circ$ ) ve uzaklık ( $d=2, 4, 6, 8$ ) için elde edilen doku özelliklerinin ortalamalarının alınması.

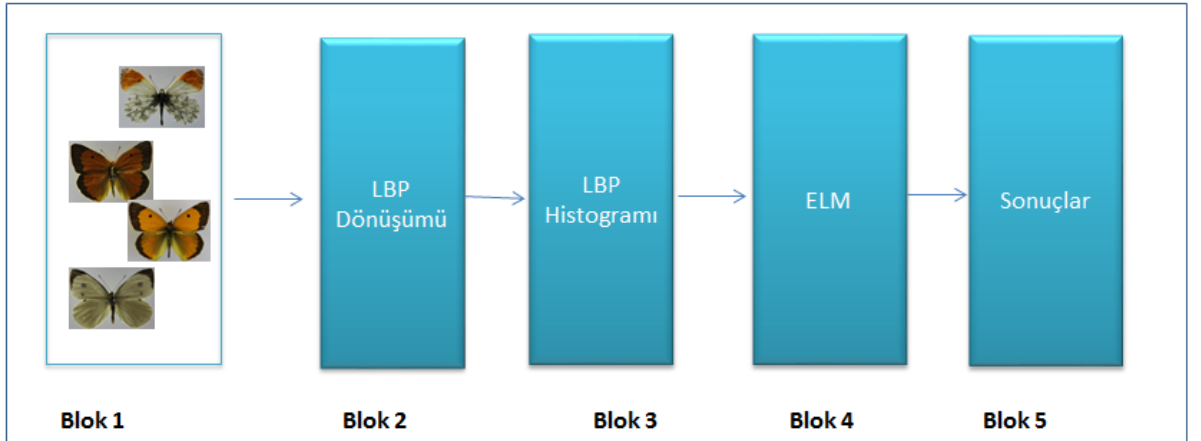
**Blok 3:** Veri kümesinin 50–50%, 70–30% ve 80–20% şeklinde farklı eğitim-test oranları için ELM ile sınıflandırma işleminin gerçekleştirilmesi.

**Blok 4:** Sınıflandırma sonuçlarının paylaşılması (karar aşaması) (Şekil 3.9.).



**Şekil 3.9.** Kelebek tanıma için önerilen GLCM-ELM yöntemi

Kelebek Tanıma için önerilen ikinci yaklaşıma ait diyagram şekil 3.10.'da verilmiştir.



**Şekil 3.10.** Kelebek tanıma için önerilen LBP-ELM yöntemi

Dört bloktan oluşan çalışmada her bloktaki işlemler kısaca aşağıdaki gibi özetlenebilir.

**Blok 1:** Sekiz bitki türüne ait farklı pozisyonlardaki toplam altmış dört (64) kelebek görüntüsünden on dört (14) doku özelliğın elde edilmesi.

**Blok 2:** Dört farklı yön ( $0^\circ$ ,  $45^\circ$ ,  $90^\circ$  ve  $135^\circ$ ) ve uzaklık( $d=2, 4, 6, 8$ ) için elde edilen doku özelliklerin ortalamalarının alınması.

**Blok 3:** Veri kümesinin 50–50%, 70–30% ve 80–20% şeklinde farklı eğitim-test oranları için ELM ile sınıflandırma işleminin gerçekleştirilmesi.

**Blok 4:** Sınıflandırma sonuçlarının paylaşılması (karar aşaması).


## 4. BULGULAR

### 4.1. LBP+ELM Sonuçları

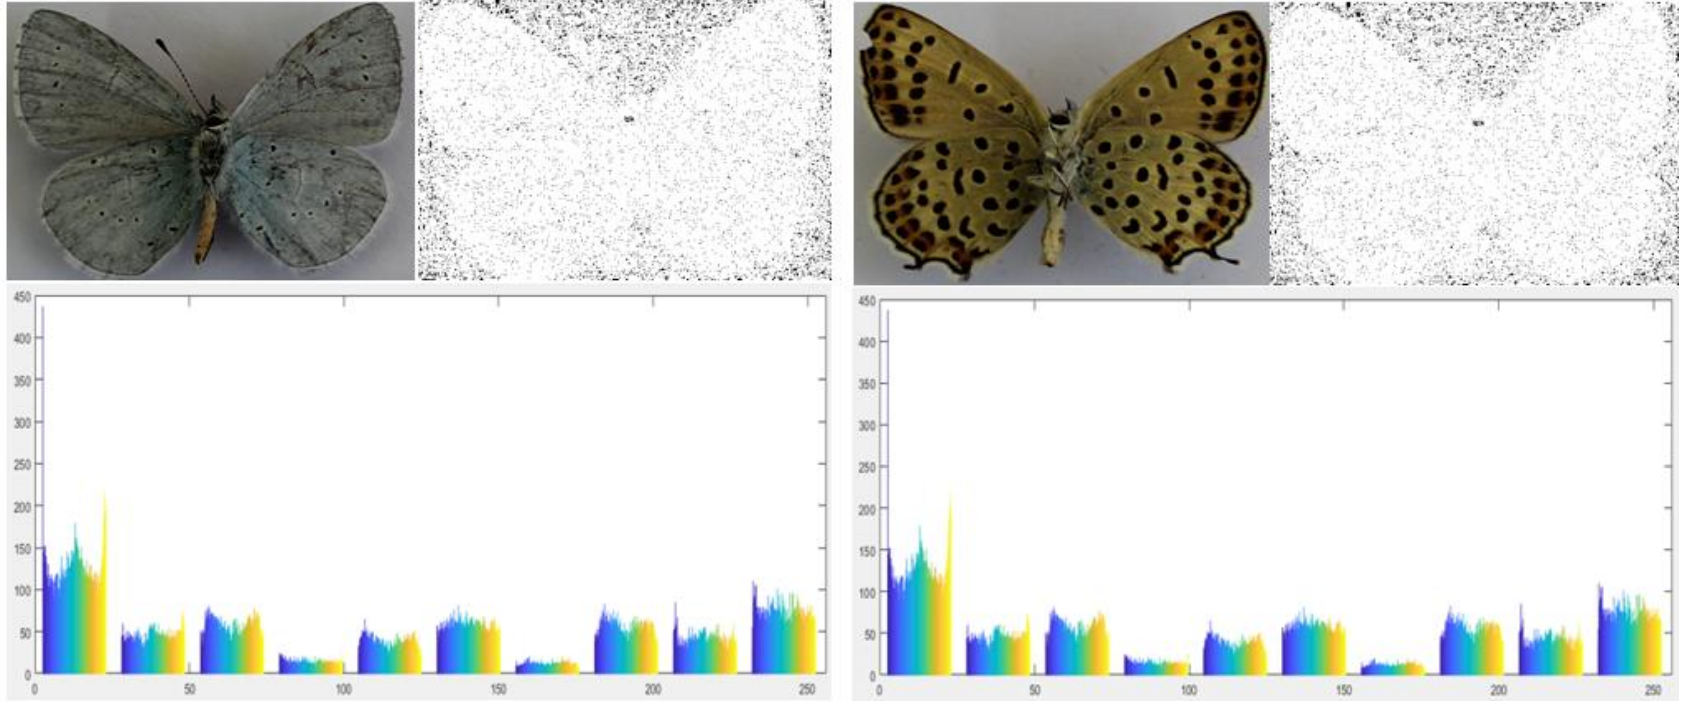
Bu bölümde kelebek görüntülerin hem ön hem de alt yüzlerinden elde edilen LBP özelliklerini kullanarak ELM ile sınıflandırma işlemi gerçekleştirilmiştir. LBP ile elde edilen özelliklerin her kelebek için farklı dağılım gösterdiği aşağıdaki şekil üzerinde görülebilir.

Şekil 4.1. ve 4.2.'de kelebek görüntüleri hem ön hem de alt yüzler için LBP resim ve bu resimlere ait histogramlar verilmiştir. Şekil 4.1.'den görüldüğü gibi iki kelebek için LBP özelliklerin farklı bir dağılım gösterdiği görülmektedir. Histogramlar birbirinden farklıdır. Aynı şekilde kelebek alt yüzler için de geçerlidir. Şekil 4.2.'den görüldüğü gibi iki kelebek türü için histogram dağılımları farklıdır. Bu farklılıklar türlerin sınıflandırılmasında etkilidir.





**Şekil 4.1.** Kelebek ön yüzlerine ait Orijinal görüntü, LBP görüntü ve Histogram



Şekil 4.2. Kelebek alt yüzlere ait Orijinal görüntü, LBP görüntü ve Histogramları

Tablo 4.1. ve Tablo 4.2.'de ELM ile sınıflandırma başarı oranları verilmiştir. Tablo 4.1.'de kelebek üst görüntülere ait sınıflandırma başarı oranları verilmiştir. Sınıflandırma işlemi 10 kat çapraz geçerlilik testine göre gerçekleştirilmiştir. Yapılan çapraz doğrulama işlemine göre veri kümesi 10 kümeye bölünmüştür. Bir çapraz doğrulamada 10 kümenin 1 kümesi test, 9 kümesi ise eğitim için kullanılır. Her küme 1 kez test için geriye kalan 9 küme ise eğitim için kullanılmış anlamına gelir. Tablo 4.1.'e bakıldığında çoğu kelebek türü (T2,T3,T7,T8,T11, T15,T16, T21, T22, T25, T30, T31, T32, T37, T38 ve T39) için sınıflandırma başarı oranı %100 gözlenmiştir. Diğer türler için hatalı sınıflandırmalar gerçekleşmiştir. Kelebek görüntülerin ön yüzünün kullanılması ile en kötü sınıflandırma başarı oranı (T18,T19, T20 ve T27) türleri için elde edilmiştir. Sonuçlara göre T18 ve T19 birbirine benzetilmiştir.

Tablo 4.2.'de kelebek alt yüzlerini kullanarak elde edilen başarı oranları verilmiştir. Tabloya bakıldığında %100 başarı oranları (T2,T5, T7, T8, T10, T12, T14, T15, T16, T19, T20, T22, T23, T29, T30, T31, T32, T33, T36, T37 ve T39) türleri için elde edilmiştir. En düşük başarı oranı T28 türü için gözlenmiştir. Tablo 4.1. ve Tablo 4.2. karşılaştırıldığında üst yüzler için ortalama başarı oranı %85.4637 olarak gözlenirken, alt yüzler için bu başarı oranı %91.6031 olarak gözlenmiştir. Sonuç olarak LBP+ELM yöntemi ile kelebeklerin alt yüzlerinden elde edilen özellikler ile daha yüksek başarı oranı elde edilmiştir.

**Tablo 4.1.** LBP+ELM ile üst yüz görüntüler için başarı oranları

Tür	Doğru Sınıflandırma	Yanlış Sınıflandırma	Başarı Oranı (%)
T1	8	2	0,80
T2	10	0	1,00
T3	10	0	1,00
T4	7	3	0,70
T5	9	1	0,90
T6	9	1	0,90
T7	10	0	1,00
T8	10	0	1,00
T9	9	1	0,90
T10	9	1	0,90
T11	10	0	1,00
T12	9	1	0,90
T13	8	2	0,80
T14	7	3	0,70
T15	10	0	1,00
T16	10	0	1,00
T17	8	2	0,80
T18	6	4	0,60
T19	5	5	0,50
T20	6	4	0,60
T21	10	0	1,00
T22	10	0	1,00
T23	8	2	0,80
T24	8	2	0,80
T25	10	0	1,00
T26	7	3	0,70
T27	6	4	0,60
T28	9	1	0,90
T29	7	3	0,70
T30	10	0	1,00
T31	10	0	1,00
T32	10	0	1,00
T33	9	1	0,90
T34	8	2	0,80
T35	9	1	0,90
T36	9	1	0,90
T37	10	0	1,00
T38	10	0	1,00
T39	10	0	1,00
<b>Ortalama Başarı Oranı (%)</b>			<b>85.4637</b>


**Tablo 4.2.** Alt yüz görüntüleri için başarı oranları

Tür	Doğru Sınıflandırma	Yanlış Sınıflandırma	Başarı Oranı (%)
T1	9	1	0,9000
T2	10	0	1,00
T3	8	2	0,80
T4	9	1	0,90
T5	10	0	1,00
T6	9	1	0,90
T7	10	0	1,00
T8	10	0	1,00
T9	9	1	0,90
T10	10	0	1,00
T11	9	1	0,90
T12	10	0	1,00
T13	8	2	0,80
T14	10	0	1,00
T15	10	0	1,00
T16	10	0	1,00
T17	8	2	0,80
T18	9	1	0,90
T19	10	0	1,00
T20	10	0	1,00
T21	9	1	0,90
T22	10	0	1,00
T23	10	0	1,00
T24	9	1	0,90
T25	9	1	0,90
T26	8	2	0,80
T27	7	3	0,70
T28	6	4	0,60
T29	10	0	1,00
T30	10	0	1,00
T31	10	0	1,00
T32	10	0	1,00
T33	10	0	1,00
T34	8	2	0,80
T35	8	2	0,80
T36	10	0	1,00
T37	10	0	1,00
T38	8	2	0,80
T39	10	0	1,00
<b>Ortalama Başarı Oranı (%)</b>			<b>91.6031</b>

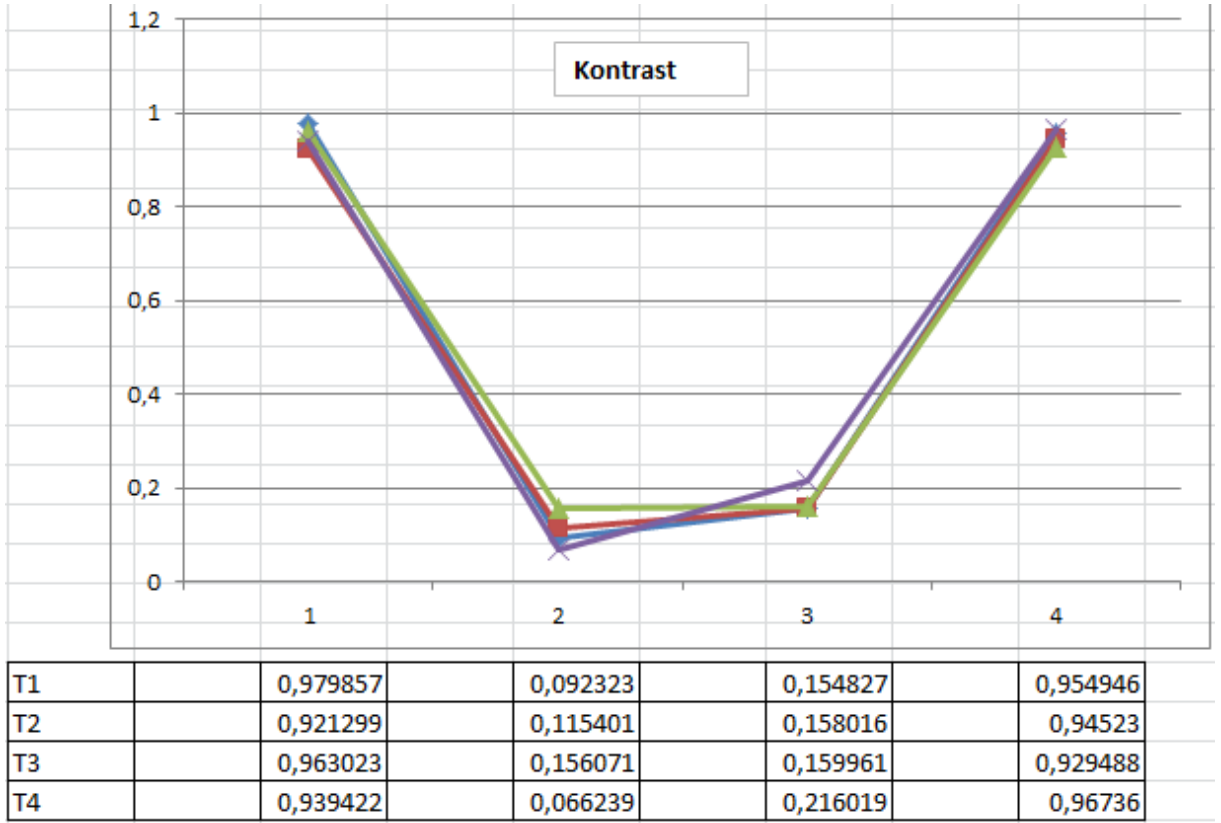
## 4.2. GLCM+ELM Sonuçları

Bu bölümde kelebek görüntülerinden GLCM ile özellikler elde edilmiştir. GLCM piksellerin mekânsal ilişkilerini göz önünde bulunduran istatistiksel bir yöntemdir. GLCM gri seviye uzamsal bağımlılık matrisi olarak da bilinir. GLCM işlevleri, belirli bir değerlerle ve belirli bir uzamsal ilişkide piksel çiftlerinin ne sıklıkta bir görüntüde meydana geldiğini hesaplar. GLCM bir görüntünün dokusunu analiz etmek için önce görüntünün GLCM matrisini oluşturur. Daha sonra bu matrsten istatistiksel özellikler elde edilerek görüntü karakterize edilir. Elde edilen özellikler ELM ile sınıflandırılacaktır.

GLCM matrisi şekil 4.3.'teki gibi dört farklı açı için (0,45, 90 ve 135 ) ve dört farklı uzaklık için (d=1,2,3,4) özellikler elde edilmiştir. GLCM matrisinden kontrast, homojenlik, enerji ve korelasyon özellikleri kullanılmıştır. Toplam 4 özellik, 4 açı ve 4 mesafe için özellikler çıkarılmıştır. Toplamda 64 özellik kullanılmıştır. Farklı mesafeler için bu özelliklerin kelebek türleri için farklı dağılım gösterdiği Şekil 4.4. - Şekil 4.7. arasında gösterilmiştir.




Şekil 4.3. GLCM yön ve mesafeler



**Şekil 4.4.** Farklı mesafeler için kontrast özelliğın dört farklı kelebek türü için dağılımı

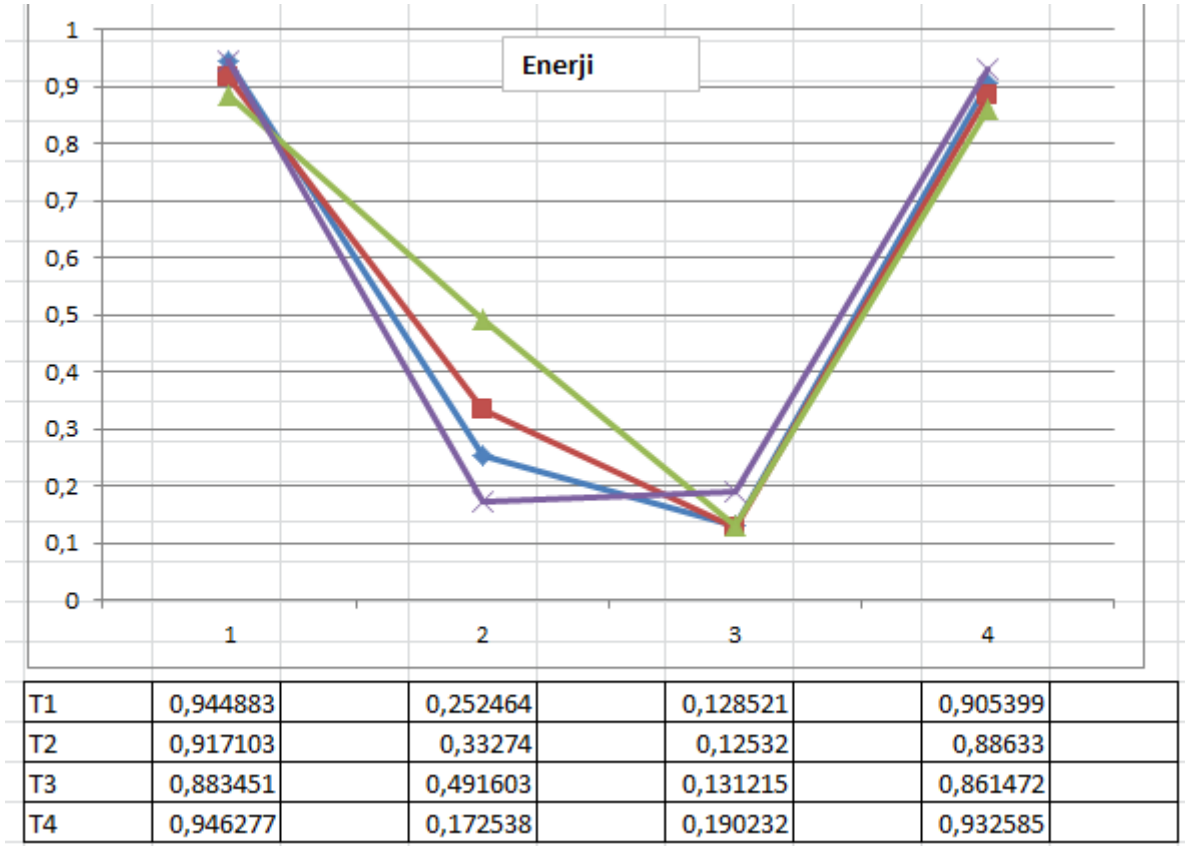
Şekil 4.4.'te kontrast değerin farklı mesafeler için değışim gösterdiği görölmektedir. Dört farklı kelebek türü için kontrast değeri çok az farklılık gösterdiği görölmektedir.



**Şekil 4.5.** Farklı mesafeler için korelasyon özelliğın dört farklı kelebek türü için dağılımı

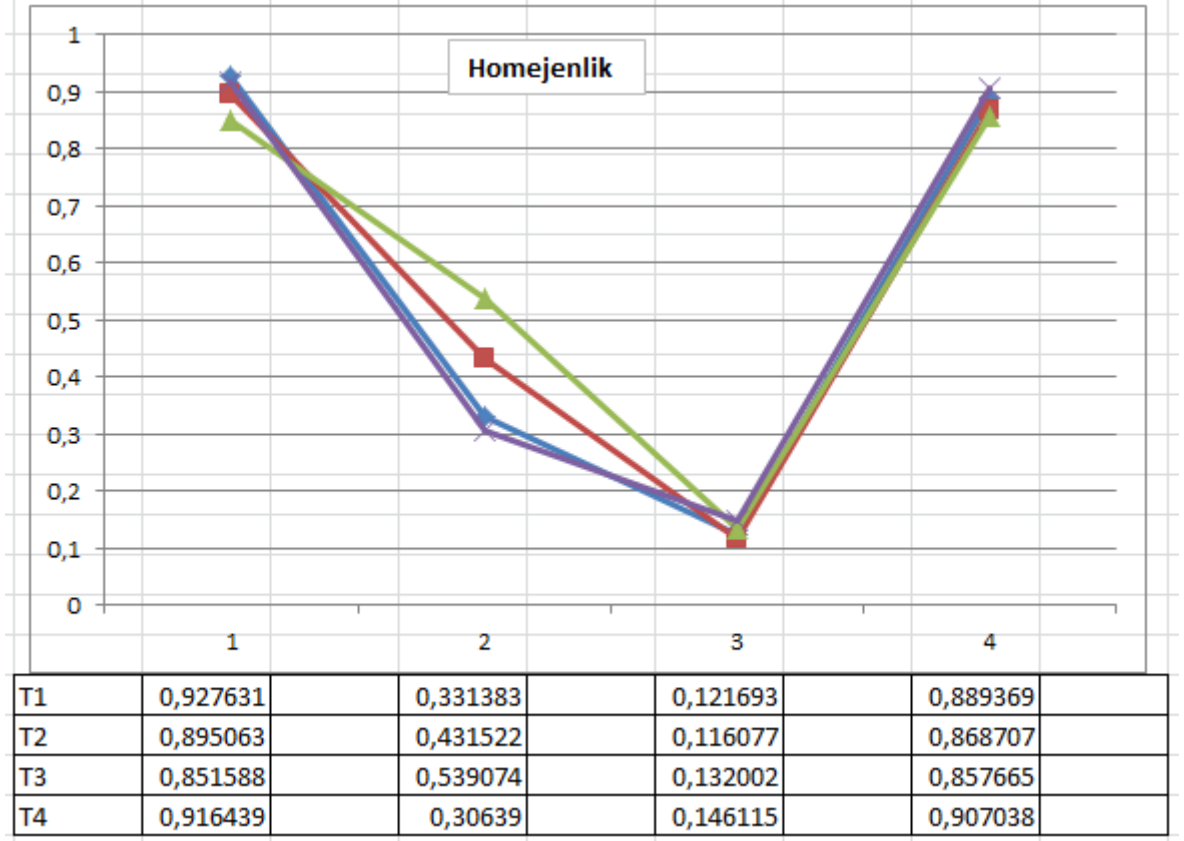
Şekil 4.5.'e bakıldığında enerji değerin farklı mesafeler için değışim gösterdiği görülebilir. Dört farklı kelebek türü için az da olsa farklılık göstermiştir.





**Şekil 4.6.** Farklı mesafeler için enerji özelliğın dört farklı kelebek türü için dağılımı

Şekil 4.6’da görüldüğü gibi korelasyon değeri kelebek türleri için farklı dağılım göstermiştir. Mesafeler içinde farklı dağılım göstermiştir.



**Şekil 4.7.** Farklı mesafeler için kontrast özelliğın dört farklı kelebek türü için dağılımı

Homojenlik grafiğine bakıldığında farklı kelebek türleri için farklı mesafelerde farklı değerlerin yakalandığı görülmektedir.

GLCM+ELM ile elde edilen sonuçlar tablo 4.3. ve 4.4.'te verilmiştir. Kelebek üst yüzeyler için başarı oranları Tablo 4.3.'te gösterilmiştir. Tabloya bakıldığında direkt olarak diğer kelebeklerden ayrışan türler (T2,T3,T5,T6, T7, T8, T10, T11, T12, T17,T19, T20, T22, T25, T27, T29, T30, T31, T34, T35, T38 ve T39) olarak gözlenmiştir. T4, T16, T21, T23 ve T26 türler için %60 başarı oranı gözlenmiştir. En düşük başarı oranı bu türler için gözlenmiştir. GLCM+ELM yöntemi ile kelebek ön yüzey görüntülerini kullanarak ortalama %88.9743 başarı oranı elde edilmiştir.

GLCM+ELM yönteminin kelebek alt yüzey görüntüleri için kullanılarak elde edilen başarı oranları Tablo 4.4.'te verilmiştir. Tabloya bakıldığında en yüksek başarı oranları T1, T2, T3, T5, T6, T8, T9, T10, T12, T19, T20, T23, T26, T29, T30, T31, T32, T34, T35, T36, T37, T38 ve T39 türleri için elde edilmiştir. %60 ve altı düşük başarı oranları T7, T18, T22 ve T25 türleri için gözlenmiştir. Kelebek alt yüzey görüntülerini kullanarak ortalama % 89.4871 başarı oranı gözlenmiştir.

**Tablo 4.3.** GLCM+ELM ile kelebek üst yüzey görüntüler için başarı oranları

<b>Tür</b>	<b>Doğru Sınıflandırma</b>	<b>Yanlış Sınıflandırma</b>	<b>Başarı Oranı (%)</b>
T1	7	3	0,70
T2	10	0	1,00
T3	10	0	1,00
T4	6	4	0,60
T5	10	0	1,00
T6	10	0	1,00
T7	10	0	1,00
T8	10	0	1,00
T9	8	2	0,80
T10	10	0	1,00
T11	10	0	1,00
T12	10	0	1,00
T13	9	1	0,90
T14	9	1	0,90
T15	8	2	0,80
T16	6	4	0,60
T17	10	0	1,00
T18	7	3	0,70
T19	10	0	1,00
T20	10	0	1,00
T21	6	4	0,60
T22	10	0	1,00
T23	6	4	0,60
T24	8	2	0,80
T25	10	0	1,00
T26	6	4	0,60
T27	10	0	1,00
T28	7	3	0,70
T29	10	0	1,00
T30	10	0	1,00
T31	10	0	1,00
T32	8	2	0,80
T33	9	1	0,90
T34	10	0	1,00
T35	10	0	1,00
T36	8	2	0,80
T37	9	1	0,90
T38	10	0	1,00
T39	10	0	1,00
<b>Ortalama Başarı Oranı (%)</b>			<b>88.9743</b>

**Tablo 4.4.** GLCM+ELM ile kelebek alt yüzey görüntüler için başarı oranları

<b>Tür</b>	<b>Doğru Sınıflandırma</b>	<b>Yanlış Sınıflandırma</b>	<b>Başarı Oranı (%)</b>
T1	10	0	1,00
T2	10	0	1,00
T3	10	0	1,00
T4	9	1	0,90
T5	10	0	1,00
T6	10	0	1,00
T7	6	4	0,60
T8	10	0	1,00
T9	10	0	1,00
T10	10	0	1,00
T11	9	1	0,90
T12	10	0	1,00
T13	7	3	0,70
T14	8	2	0,80
T15	8	2	0,80
T16	8	2	0,80
T17	8	2	0,80
T18	5	5	0,50
T19	10	0	1,00
T20	10	0	1,00
T21	9	1	0,90
T22	6	4	0,60
T23	10	0	1,00
T24	8	2	0,80
T25	6	4	0,60
T26	10	0	1,00
T27	7	3	0,70
T28	8	2	0,80
T29	10	0	1,00
T30	10	0	1,00
T31	10	0	1,00
T32	10	0	1,00
T33	7	3	0,70
T34	10	0	1,00
T35	10	0	1,00
T36	10	0	1,00
T37	10	0	1,00
T38	10	0	1,00
T39	10	0	1,00
<b>Ortalama Başarı Oranı (%)</b>			<b>89.4871</b>

### 4.3. Yöntemlerin Karşılaştırılması

Bu tez çalışmasında kelebek görüntülerini sınıflandırmak için LBP+ELM ve GLCM+ELM şeklinde iki farklı yaklaşım denenmiştir. Yaklaşımlar kelebek görüntülerin hem ön hem de alt yüzleri için test edilmiştir. Elde edilen başarı oranları Tablo 4.5.'te verilmiştir. Tabloya göre en başarılı sonuçlar LBP+ELM yönteminin kelebek alt görüntülerini kullanılması durumunda gözlenmiştir. Ancak diğer sonuçlar da başarılı kabul edilebilir.

**Tablo 4.5.** LBP+ELM ve GLCM+ELM başarı oranları (%)

Yöntem	Üst Yüz	Alt Yüz
LBP+ELM	85.4637	<b>91.6031</b>
GLCM+ELM	88.9743	89.4871

## 5. TARTIŞMA SONUÇ

Kelebek ve güvelerde kanatları morfolojik özellikleri, desen ve renkleri az veya çok derece büyük değişim gösterir. Türe spesifik olan bu özellikler ilk bakışta çoğu defa türlerin ayırımında önemli rol oynarlar. Son yıllarda giderek önem kazanan karyolojik araştırmalar sonucunda bazı *Agrodiaetus* (Lycaenidae) türlerin kromozom sayılarının ve boylarının tür ayırımında önemli olduğu anlaşılmıştır.

Klasik sınıflandırma ve tanımlama yöntemlerinde canlıların çeşitli karakteristikleri kullanılmaktadır. Bununla birlikte tür ayırımında hangi karakteristiğin daha tanımlayıcı olduğu gibi sorular hep gelmiştir. Ayrıca gözlem yapılarak kelebek türlerinin sınıflandırılması çok güçlü bir sistematik bilgisi gerektirmektedir. Bu durum çoğu zaman zoologlar için bile çok zor bir alan olmuştur. Ayrıca alanında uzman zoologların sayısındaki azalma kelebek türlerinin tanımlanması için görüntü işleme ve ilişkilerin tanımlanmasına dayalı teknikler gibi farklı yöntemlerin kullanımını zorunlu hale getirmiştir. Ayrıca kamera sistemlerinin ve diğer portatif cihazların geliştirilmesi gibi konuyla ilgili farklı alanlardaki gelişmeler bu düşüncenin uygulanabilirliğini artırmıştır.

Yirminci yüzyılın ikinci yarısında laboratuvar tekniklerinde meydana gelen ilerlemelerle birlikte, biyolojik anlamda önemli olan moleküllerin analiziyle türler arası ve tür içi genetik çeşitliliğin kategorize edilmesi ve sınıflandırılması mümkün olmuştur. Bu anlamda çeşitli yöntemler olmakla birlikte farklı organizmalara ait DNA sekanslarının kıyaslanması sonucu elde edilen sonuçların en güçlü ve en kullanışlı olduğu söylenebilir.

Son yıllarda giderek önem kazanan karyolojik araştırmalar sonucunda bazı *Agrodiaetus* türlerinde (Lycaenidae) türlerin kromozom sayılarının ve boylarının tür ayırımında önemli olduğu anlaşılmıştır. Bu tez çalışmasında kelebek türlerinin sınıflandırılması için klasik yöntemlere alternatif bilgisayar görü tabanlı bir yöntem önerilmiştir. Çalışmada kelebek görüntülerini kullanan otomatik makine görme sistemi tasarlanmıştır. Bu sistem ile kelebek görüntülerinden kelebek türü tespit edilmiş ve sınıflandırılmıştır. Çalışmada ilk olarak kelebek görüntülerinden LBP ve GLCM ile doku özellikleri elde edilmiştir. Elde edilen bu özellikler kullanılarak ELM makine öğrenmesi yöntemi ile sınıflandırma işlemi gerçekleştirilmiştir. Doku görüntünün yüzeyine ait özelliklerdir (Kaya ve ark., 2013). Bilgisayar tabanlı doku analizi biyolojik görüntü üzerindeki dokuların matematiksel olarak ifade edilmesidir.

Kelebek görüntüleri için görüntüdeki dokular, türlere göre farklılık gösterebilir ve dokular görüntü hakkında bilgiye/detaya ulaşmamızı sağlayabilecek bilgiler içerebilir. Doku bir görüntünün ilgili alanlarının veya bölgelerinin tanımlanmasında kullanılan benzer yapıların topluluğu şeklinde ifade edilir (Alam ve Faruqi, 2011). Dokular nesnelerin, varlıkların boyut, şekil, parlaklık, renk ve karakteristik gibi özelliklerini ifade eden desenlerdir. Görüntülerin dokusu, görüntü içindeki bir nesnenin parçalarının görünüşü, yapısı ve düzenini ifade eder (Castellano ve ark., 2004; Zhang ve ark., 2017). Doku, bir görüntünün yüzeyine ait bir özelliktir (Kaya ve ark., 2015). Görüntü yüzeyindeki bir doku veya desenin düzenli tekrarı olarak ifade edilebilir. Bir görüntüye ait bölgeler farklı renk, parlaklık ve dokulara sahip olabilir.

Biyolojik görüntülerin bilgisayar tabanlı doku analizi görüntü üzerindeki dokuların matematiksel olarak ifade edilmesidir. Kelebek görüntüleri için görüntülerdeki dokular türlere göre farklılık gösterebilir. Görüntülerdeki dokular görüntü hakkında bilgiler içerir.

Bu tez çalışmasında LBP+ELM ve GLCM+ELM şeklinde iki farklı yaklaşım kullanılmıştır. LBP ve GLCM ile öznitelikler vektörleri oluşturulur. Bu öznitelik vektörleri kullanılarak ELM ile kelebek türü teşhisi gerçekleştirilir. LBP ve GLCM ile elde edilen dokusal özellikler aşırı öğrenme makinesi (Extreme Learning Machine=ELM) sınıflandırma yöntemi ile kullanılarak kelebek türü teşhisi gerçekleştirilmiştir. ELM ileri beslemeli tek gizli katmanlı bir yapay sinir ağı modelidir. Bu modelde giriş ve gizli katmandaki sinir hücrelerine ait ağırlıkları ve eşik değerleri rastgele üretilir. Ancak çıkış katmandaki sinir hücre ağırlıkları matematiksel olarak elde edilir. Bu modelin en önemli özelliği öğrenme sürecinin çok hızlı gerçekleşiyor olmasıdır.

Çalışmada 39 kelebek türü için hem üst hem de alt yüzlerine ait görüntüler kullanılmıştır. Alt yüz için 390 ve üst yüz için 390 toplamda 780 görüntü kullanılmıştır. Kelebeklerin hem üst hem de alt yüzlerine ait görüntüler kullanılmıştır. LBP+ELM ile yöntemi kelebeklerin üst yüz görüntülerinin kullanılması durumunda % 85.4637 teşhis başarısı gözlenmiştir. T2,T3,T7,T8,T11, T15,T16, T21, T22, T25, T30, T31, T32, T37, T38 ve T39 kelebek türleri için sınıflandırma başarı oranı %100 gözlenmiştir (Tablo 4.1). Kelebek görüntülerin ön yüzünün kullanılması ile en kötü sınıflandırma başarı oranı (T18,T19, T20 ve T27) türleri için elde edilmiştir. Sonuçlara göre T18 ve T19 birbirine benzetilmiştir.

LBP+ELM ile kelebeklerin alt yüzlerinin kullanılması durumunda T2,T5, T7, T8, T10, T12, T14, T15, T16, T19, T20, T22, T23, T29, T30, T31, T32, T33, T36, T37 ve T39 türleri için %100 başarı oranları gözlenmiştir (Tablo 4.2). En düşük başarı oranı T28 türü için gözlenmiştir. Ancak alt yüzler için ortalama başarı oranı %91.6031 olarak elde edilmiştir.

GLCM+ELM yöntemine bakıldığında kelebek görüntülerin üst yüzlerinin kullanılması durumunda ortalama %88.9743 başarı oranı elde edilmiştir. Teşhis sonuçlarına bakıldığında direkt olarak diğer kelebeklerden ayrışan türler (T2,T3,T5,T6, T7, T8, T10, T11, T12, T17,T19, T20, T22, T25, T27, T29, T30, T31, T34, T35, T38 ve T39) olarak gözlenmiştir (Tablo 4.3). T4, T16, T21, T23 ve T26 türler için %60 başarı oranı gözlenmiştir. En düşük başarı oranı bu türler için gözlenmiştir.

GLCM+ELM yönteminin kelebek alt yüzey görüntüleri için kullanılarak elde edilen başarı oranlarına bakıldığında en yüksek başarı oranları T1, T2, T3, T5, T6, T8, T9, T10, T12, T19, T20, T23, T26, T29, T30, T31, T32, T34, T35, T36, T37, T38 ve T39 türleri için elde edilmiştir. %60 ve altı düşük başarı oranları T7, T18, T22 ve T25 türleri için gözlenmiştir. Kelebek alt yüzey görüntülerini kullanarak ortalama 89.4871 başarı oranı gözlenmiştir.

En yüksek başarı oranı LBP+ELM ile %91.6031 olarak kelebeklerin alt yüzlerinin kullanılması ile elde edilmiştir. Benzer görüntüler üzerinde yapılan diğer çalışmalar (Kaya ve Kayci, 2014) ile karşılaştırıldığında başarı oranlarının kabul edilebilir aralıklarda olduğu görülmektedir.



## KAYNAKLAR

- Ahonen, T., Hadid, A., Pietikainen, M., 2006. Face description with local binary patterns: Application to face recognition, *Pattern Analysis and Machine Intelligence*, IEEE *Transactions on Pattern Analysis*, 28(12), 2037-2041.
- Alam, F., Faruqi, R., 2011. Optimized calculations of Haralick texture features. *Euro. Journal of Scientific Research*. 50 (4), 543–553.
- Caputo, B., Hayman, E., Fritz, M., Eklundh, J. O., 2010. Classifying materials in the real world. *Image and Vision Computing*, 28(1), 150-163.
- Carbonell, F., 1993. Contribution a la connaissance du genre *Agrodiaetus* Hübner (1822): le complexe ultraspécifique d'*A. transcaspica* Staudinger (1899) (Lepidoptera, Lycaenidae). *Linneana Belgica*, 89-116.
- Carbonell, F., 1998. Contribution a la connaissance du genre *Agrodiaetus* Hübner (1822), position taxinomique d'*Agrodiaetus anticarmon* Koçak, 1983 (Lepidoptera, Lycaenidae). *Linneana Belgica*, 263-265.
- Castellano, G., Bonilha, L., Li, L.M., Cendes, F., 2004. Texture analysis of medical images. *Clin. Radiol.* 59, 1061–1069.
- Cernadas E., Carrión P., Rodríguez P.G., Muriel E., Antequera T., 2005. Analyzing magnetic resonance images of Iberian pork loin to predict its sensorial characteristics, *Comput.Vis.Image Underst.*, 98, 345–361.
- García, M. A., Puig, D, 2008. Supervised texture classification by integration of multiple texture methods and evaluation windows, *Image and Vision Computing*, 25 (7), 1091-1106.
- Guo, Y., Zhao G., Pietikäinen M., 2010. Discriminative features for texture description, *Pattern Recogn.* 45 (10): 3834–3843.
- Guo, Z., Zhang L., Zhang D., 2010. Rotation invariant texture classification using LBP variance (LBPV) with global matching, *Pattern Recognition* 43:706–719.
- Hai-Jun, R., Yew-Soon O., Ah-Hwee T., Zexuan Zhu. 2008. A fast pruned-extreme learning machine for classification problem. *Neurocomputing*, 72, 359-366.
- Handoko, S. D., Keong, K. C., Ong, Y. S., Zhang G.L., Brusica V., 2006. Extreme learning machine for predicting HLA-peptide binding, *Lecture Notes in Computer*, 3973, 716–721.
- Haralick, R.E., Shanmugam K., Dinstein I., 1973. Textural Features for Image Classification, *IEEE Transactions on Systems*, , 3, 6-12.
- Hesselbarth, G., Oorschot, H.v., Wagener, S., 1995. Die Tagfalter der Türkei. *Bochum*. Germany.
- Huang, G.B., Zhu, Q.Y., Siew, C.K., 2006. Extreme learning machine: theory and applications. *Neurocomputing*, 70 (1-3), 489–501.

- Kang, S., Cho, J., Lee, S., 2014. Identification of butterfly based on their shapes when viewed from different angles using an artificial neural network. *Journal of Asia-Pacific Entomology* 17,143–149
- Kang, S., Jeon, W., Lee, S., 2012. Butterfly species identification by branch length similarity entropy. *Journal of Asia-Pacific Entomology* 15; 437–441.
- Kaya, Y., Kayci, L., Uyar, M., 2015. Automatic identification of butterfly species based on local binary patterns and artificial neural network. *Applied Soft Computing*, 28, 132–137.
- Kaya, Y., Kayci, L. 2014. "Kelebek görüntülerin sınıflandırılması için bir içerik bazlı görüntü erişim sistemi." *Akademik Bilişim: 5-7*. Türkiye
- Kaya, Y., Kayci L., Sezgin. N., 2013. Classification of butterfly images with multi-scale local binary patterns. *Signal Processing and Communications Applications Conference (SIU), 21st. IEEE*. Malatya, Türkiye
- Kaya, Y., Kayci, L., Tekin, R., Faruk, E. Ö., 2014. Evaluation of texture features for automatic detecting butterfly species using extreme learning machine. *Journal of Experimental & Theoretical Artificial Intelligence*, 26(2), 267-281.
- Kayci, L., 2007. Erek Dağı (Van) *Papilionoidea* ve *Hesperioidea* Ekolojisi ve Faunası Üzerine Araştırmalar (*Lepidoptera*). *Priamus Supplement*, 6:1-47.
- Liu, F., Tang, Z., Tang, J, 2013. "WLBP: Weber local binary pattern for local image description", *Neurocomputing*, 120, 325-335.
- Liu, L., Zhao, L., Long, Y., Kuang, G., Fieguth, P., 2012. "Extended local binary patterns for texture classification", *Image and Vision Computing*, 30 (2), 86-99.
- Lucieer, A., Stein, A., Fisher, P, 2005. Multivariate texture- based segmentation of remotely sensed imagery for extraction of objects and their uncertainty, *International Journal of Remote Sensing*, Vol. 26(14), 2917-2936.
- Maani, R., Sanjay K., Yee-Hong Y., 2013. Noise robust rotation invariant features for texture classification. *Pattern Recognition* 46: 2103-2116.
- Martineaua, M., Contea D., Raveauxa R, Arnault I., Munierb D., Venturinia G.A., 2017. Survey on image-based insect classification. *Pattern Recognition* 65: 273–284.
- Nanni, L., Brahmam, S., Lumini, A. 2012 A simple method for improving local binary patterns by considering non-uniform patterns, *Pattern Recognition*, 45(10), 3844-3852.
- Nanni, L., Lumini, A, 2008. Local binary patterns for a hybrid fingerprint matcher, *Pattern recognition*, 41(11), 3461-3466.
- Nguyen, T. P., Vu, N. S., Manzanera, A., 2016. Statistical binary patterns for rotational invariant texture classification. *Neurocomputing*, 173, 1565-1577.
- Ojala, T., Pietikäinen, M., 1999. Unsupervised texture segmentation using feature distributions", *Pattern Recognition*, 32(3), 477-486.

- Ojala, T., Pietikäinen, M., Harwood, D., 1996. A comparative study of texture measures with classification based on featured distributions”, *Pattern recognition*, 29(1), 51-59.
- Orenstein, E.C., Justin, M., Haaga, Y., Gagnonc, L., Jules S.J., 2016. Automated classification of camouflaging cuttlefish. *Methods in Oceanography* (15–16), 21–34.
- Pan, Z., Li, Z., Fan, H., Wu, X., 2017. Feature based local binary pattern for rotation invariant texture classification. *Expert Systems with Applications*, 88, 238-248.
- Pietikäinen, M., Nurmela, T., Mäenpää, T., Turtinen, M., 2004. View-based recognition of real-world textures”, *Pattern Recognition*, 37(2), 313-323,
- Skala, P., 2003. New taxa of the genus *Hyponephele* MUSCHAMP, 1915 from Iran and Turkey (Lepidoptera, Nymphalidae). *Linneana Belgica*, 19 (1), 41-50.
- Suresh, S., Saraswathi, S., Sundararajan, N., 2010. Performance enhancement of extreme learning machine for multi-category sparse data classification problems. *Engineering Applications of Artificial Intelligence* 23, 1149–1157.
- Tolman, T., 1997. Butterflies of Britain and Europe. *Harper Collins Publishers*, London. 320.
- Wang, J., Ji, L., Liang, A., Yuan, D., 2012. The identification of butterfly families using content-based image retrieval. *Biosystem Engineering* 111, 24-32.
- Yuan, Q., Weidong, Z., Shufang, L., Dongmei, C., 2011. Epileptic EEG classification based on Extreme learning machine and nonlinear features. *Epilepsy Research* . 96; 29-38
- Zhang, Z., Liu, S., Mei, X., Xiao, B., Zheng, L., 2017. Learning completed discriminative local features for texture classification. *Pattern Recognition*, 67, 263-275.
- Zhao, G., Pietikainen, M., 2007. Dynamic texture recognition using local binary patterns with an application to facial expressions”, *Pattern Analysis and Machine Intelligence* 29(6), 915-928.
- Zhao, Y., Wang, R. G., Wang, W. M., Gao, W., 2016. Local quantization code histogram for texture classification. *Neurocomputing*, 207, 354-364.
- Zheng, C, D., Sun, W., Zheng, L., 2006. Recent applications of image texture for evaluation of food qualities: a review, *Trends Food Sci.Technol.*17, 113–128.
- Zhou, S.R., Yin, J.P., Zhang, J. M., 2013. Local binary pattern (LBP) and local phase quantization (LBQ) based on Gabor filter for face representation”, *Neurocomputing*, 116, 260-264.
- Zhu, Z., 2015. "An adaptive hybrid pattern for noise-robust texture analysis." *Pattern Recognition* 48 (8), 2592-2608.

## ÖZGEÇMİŞ

### KİŞİSEL BİLGİLER

**Adı** : Pamuk YETER EREZ  
**Doğum Yeri ve Tarihi** : Eyüp, 30.09.1989  
**Telefon** : 0 538 791 15 86  
**E-posta** : selmags@hotmail.com

### EĞİTİM

<b>Derece</b>	<b>Adı, İlçe, İl</b>	<b>Bitirme Yılı</b>
Lise	Yalova Lisesi	2006
Üniversite	Yüzüncü Yıl Üniversitesi, Fen Edebiyat Fakültesi, Biyoloji Bölümü.	2012
Yüksek Lisans Doktora	Siirt Üniversitesi	2019