

# Kızıltepe Tarımsal Alan İmgelerinin Ekinin Ürün Gelişimine Göre Sınıflandırılması

Classification of Kızıltepe Agricultural Land Images Based on Development in Different Period of Crops

Emrullah ACAR<sup>1</sup> ve Mehmet Sıraç ÖZERDEM<sup>2</sup>

<sup>1</sup> Batman Üniversitesi, Mühendislik Fakültesi, Batman, [emrullah.acar@batman.edu.tr](mailto:emrullah.acar@batman.edu.tr)

<sup>2</sup> Dicle Üniversitesi, Mühendislik Fakültesi, Diyarbakır, [sozerdem@dicle.edu.tr](mailto:sozerdem@dicle.edu.tr)

## Özetçe

*Bu çalışmada, Kızıltepe (Mardin) tarım alanlarına ilişkin imgelerin, bitkinin farklı gelişim dönemlerine (ekim dönemi, az gelişmiş dönem, tam gelişmiş dönem ve hasat dönemi) göre sınıflandırılması amaçlanmıştır. İmgeler TARİT (Tarımsal Rekolte İzleme ve Tahmin Sistemi) projesi kapsamında kurulan istasyonlardan elde edilmiştir. İmge dokusuna duyarlı olan yöntemlerden Gri Seviyeli Eş-oluşum Matrisleri (GLCM) ve Law'ın doku enerji ölçümü (TEM) kullanılarak, ürünün gelişim sürecine ilişkin imgelerin öznelik vektörleri elde edilmiştir. Her iki yöntem ile elde edilen öznelik vektörleri ayrı ayrı sınıflandırıcılarda test edilerek, elde edilen performans sonuçları karşılaştırılmıştır.*

*Sınıflandırıcı olarak Çok Katmanlı Algılayıcı (MLP), k-En Yakın Komşu (k-NN) ve Destek Vektör Makineleri (SVM) yöntemleri kullanılmıştır. GLCM tabanlı sınıflama işlemlerinde, sadece SVM sınıflandırıcının %100 performansa ulaştığı gözlenirken, TEM tabanlı sınıflama işlemlerinde tüm sınıflayıcıların %100 sınıflama başarısına eriştiği gözlenmiştir. Ürün imgelerine ilişkin özneliklerin TEM yöntemi ile ürün gruplarına göre doğru karakterize edilmiş olması, tüm sınıflandırıcıların yüksek performans sergilemesine olanak tanımıştır.*

**Classification of Kızıltepe Agricultural Land Images Based on Development in Different Period of Crops**

## Abstract

*In this research, images of Kızıltepe (Mardin) agricultural land are classified based on development in different period of crops (1-sowing*

*term, 2-little ripe term, 3-ripe term and 4-harvest term). The digital crop images are derived from TARİT (Agricultural Crop Forecast and Following Project) stations. The texture feature vectors are obtained from images of different crop periods with using Gray Level Co-Occurrence Matrix (GLCM) and Law's Texture Energy Measure (TEM) which are very popular methods for image texture extraction. GLCM and TEM based feature vectors are applied to different type of classifiers as inputs and the performance results of each system are compared.*

*For classification the crop images, Multilayer Perceptron (MLP) neural network, k-Nearest Neighbor (k- NN) and Support Vector Machine (SVM) methods are used. While the best performance is observed as 100% in GLCM based SVM classifier only, the same performance is observed in TEM based all classifier types. Texture features of crop images based on TEM method allow us to exhibit high performance in all classifiers.*

## 1. Giriş

Sayısal imge işleme teknolojisi tıp, gıda mühendisliği, biyoloji, ziraat vb. birçok alanda geniş bir şekilde kullanılmaktadır. Sayısal imge işleme, imge işlemek için çok daha fazla karmaşık algoritmaların kullanımına imkan vermekte ve bu nedenle, hem basit işlerde daha iyi performans hem de analog araçlarla uygulanması imkansız olan yöntemlerin uygulanmasında kolaylık sağlayabilmektedir [1,2].

Tarımsal alanlarda elde edilen sayısal kamera imgeleri, ürün hakkında gerekli bilgileri içerir. Bu yaklaşımla arazinin yüksek uzaysal çözünürlüklerde dış yüzeyindeki değişimlerini görüntülemek, hem

daha esnek hem de düşük maliyetlidir. Ayrıca, bitki dinamiklerinin zaman üzerinden belirlenmesi için imgeler hızlı bir şekilde elde edilebilmekte ve kolay bir şekilde arşivlenebilmektedir [3].

Uygulamalarda, tarla gözlemlerinden elde edilen imgelerin önışlemeden geçirilerek öznelik verilerinin elde edilmesi ve farklı sınıflandırma yöntemleri ile elde edilen sonuçların değerlendirilmesi, genel olarak izlenen bir yoldur. Uygulamaların farklılığı, çalışmalarda farklı öznelik çıkarma ve sınıflandırma yöntemlerinin kullanılmasından kaynaklanmaktadır. Literatürde, ürün imgelerinin sınıflandırılmasına ilişkin olarak kümeleme ve makine-öğrenme metodu [4], Yapay Sinir Ağları (YSA) [5-10], SVM [8,11-13], k-NN [14], Dinamik Öğrenmeli Sinir Ağları [15] gibi sınıflandırıcılarının kullanıldığı gözlenmektedir. Sayısal imgelerden öznelik vektörlerinin çıkarılması işleminde ise Dalgacık Dönüşümü [16], Temel Bileşenler Analizi (PCA), Kernel Temel Bileşenler Analizi (KPCA) [17] ve GLCM [18-19] gibi farklı yöntemler kullanılmaktadır.

YSA'lar, ağırlıklandırılmış şekilde birbirlerine bağlanmış birçok işlem (nöron) biriminden oluşan matematiksel sistemlerdir. Aynı zamanda, giriş ve çıkışlar arasındaki karmaşık ilişkileri modellemek ve veri içindeki örüntüleri bulmak için kullanılabilirlerdir. Örüntü tanıma sistemlerinde k-NN yöntemi, sınıfları belli olan bir örnek kümesindeki gözlem değerlerinden yararlanarak, örneğe katılacak yeni gözlemin hangi sınıfa ait olduğunu belirlemek amacıyla kullanılır. SVM ise, sınıflandırma ve regresyon analizi için kullanılan, verileri analiz etme ve örüntüleri tanımayla ilgili denetimli öğrenme yöntemlerini içeren yaklaşımdır.

Bu çalışmada sayısal imgelere ilişkin özneliklerin çıkarılmasında, doku analizinde başarılı sonuçlar üreten GLCM ve TEM yöntemleri kullanılmıştır. İmgelerden elde edilen öznelik vektörlerinin sınıflandırılmasında MLP, k-NN ve SVM yöntemleri kullanılmıştır. Her bir yapının test performansı hesaplanmış ve sonuçlar karşılaştırılarak en iyi performansa sahip olan yapı saptanmıştır.

## 2. Materyal ve Metot

### 2.1. Veri Toplama

Çalışmada kullanılan Kızıltepe (Mardin) tarımsal

alan imgeleri, TARİT (Tarımsal Rekolte İzleme ve Tahmin Sistemi, [www.tarit.org](http://www.tarit.org)) projesi kapsamında kurulan istasyonlardan elde edilmiştir. Bu çalışmada, Kızıltepe Çağıl/2 istasyon verileri kullanılmış olup, istasyonun konumu Şekil-1 de gösterilmiştir.



**Şekil-1:** Çalışmada kullanılan örnek imgelerin alındığı istasyonun harita üzerindeki konumu (37.12354K 40.66438D).

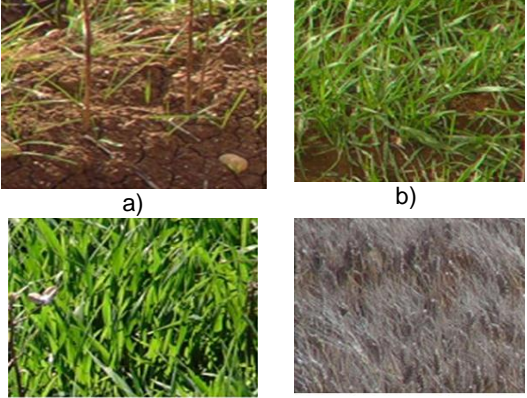
26 Ocak-5 Haziran 2011 tarihleri arasında kayda alınan toplam 120 imge bu çalışmada kullanılmış olup, ürünün gelişme dönemine göre dört farklı sınıfta değerlendirilmiştir. Bu imgelerin 30 tanesi ekim dönemine, 15 tanesi az gelişmiş döneme, 60 tanesi tam gelişmiş döneme ve geriye kalan 15 tanesi ise hasat dönemine ait imgelerden oluşmaktadır. Her döneme ilişkin örnek örüntüler Şekil-2'de, çalışmada kullanılan imge sayılarının aylara göre dağılımı Çizelge-1 de gösterilmiştir.

### 2.2. Özellik Çıkartma

Bu çalışmada kullanılan imgeler 3 boyutlu JPEG formatında olduğundan, imgeler MATLAB programı yardımıyla 2 boyutlu gri tonlu imge formatına dönüştürülmüştür. Uygulamada kullanılan imgelerin ölçükleri 2288x1712 pikseldir. İmgeler 'bicubic' interpolasyon yöntemi ile ölçüklenilerek 64x64 piksellik imgelere dönüştürülmüş ve tüm imgelerde ışık farklılıklarından kaynaklanabilecek parlaklık değişimlerinin önüne geçmek için histogram eşlemesi yapılmıştır. Bu çalışmada sayısal imgelere ilişkin özneliklerin çıkarılmasında, doku analizinde başarılı sonuçlar üreten GLCM ve TEM yöntemleri kullanılmıştır. Bu yöntemler, 2.2.1 ve 2.2.2 bölümlerinde açıklanmıştır.

**Çizelge-1:** Ürün imge sayısının aylara göre dağılımı

	Ocak	Şubat	Mart	Nisan	Mayıs	Haziran
2011	6	28	27	27	27	5

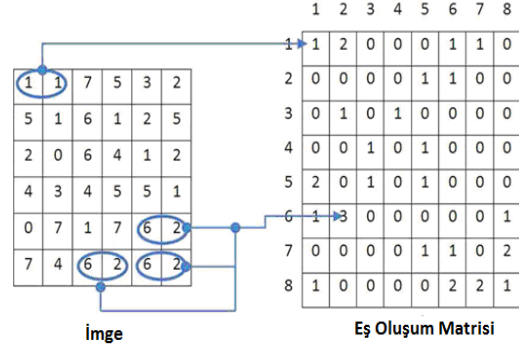
**Şekil-2:** Farklı gelişim dönemlerine ilişkin örnek ürün imgeleri, **a)** Ekim dönemi (Sınıf I), **b)** Az gelişmiş dönem (Sınıf II), **c)** Tam gelişmiş dönem (Sınıf III) ve **d)** Hasat dönemi (Sınıf IV).

### 2.2.1. Gri Seviye Eş Oluşum Matrisi (GLCM)

GLCM, M.Haralick tarafından ortaya atılmış bir özellik çıkarma yöntemi olup, gri tonlu bir imajın özneliğini çıkarmaya yarar. GLCM, iki komşu piksel arasındaki ilişkiyi tanımlar. Bu piksellerden birincisi referans pikseli, ikincisi de komşu piksel olarak bilinir [20]. Matristeki dağılım, pikseller arasındaki mesafe ve açıya göre ayarlanır. Bu matris,  $N_g$  boyutlu bir kare matris olup, matrisin her bir elemanı  $d$  mesafesindeki  $i$  ve  $j$  piksel değerli çiftin oluşum sayısını belirtir [21].

Pikseller arası uzaklığın yanı sıra, piksel çiftlerinin yönlerinin bilinmesine de gerek vardır. En çok ortak bilinen yönler  $\vartheta=0, 45, 90, 135$  ve bunların simetrik benzerleridir. Şekil-3'te gri seviye sayısı 8, pikseller arası uzaklık  $d=1$  ve yön açısı  $\vartheta=0$  olarak hesaplanmış bir eş-oluşum matrisinin örneği verilmiştir. Burada, imge matrisi içindeki (1,1) ve (1,2) koordinatındaki (1,1)'lik piksel çifti bir defa tekrarlandığından dolayı, bu piksel çiftinin eş oluşum matrisindeki (1,1) koordinatındaki elemanı, 1'e eşit olur. Benzer şekilde (6,2) piksel çifti, imge matrisi içinde 3 defa tekrarlandığından dolayı, eş-

oluşum matrisindeki karşılığı 3'e eşit olur. Bu adımlar imge matrisi içindeki diğer piksel çiftleri için de tekrarlanıp, imgeye ait eş oluşum matrisi hesaplanır.



**Şekil-3:** Eş-oluşum matrisinin elde edilmesi

GLCM nin satır ve sütunlarına ilişkin ortalama ve standart sapma eşitlikleri sırasıyla (1) ve (2) nolu bağıntılarda gösterilmiştir. Bu değerler, olasılık yoğunluk fonksiyonu  $p(i,j)$ 'nin satır ve sütunlarının ortalama ve standart sapma değerlerini ifade eder.

$$\mu_x = \sum_i \sum_j i.p(i, j), \quad \mu_y = \sum_i \sum_j j.p(i, j) \quad (1)$$

$$\sigma_x = \sum_{i,j} (i - \mu_x)^2 . p(i, j) \quad (2)$$

$$\sigma_y = \sum_{i,j} (j - \mu_y)^2 . p(i, j)$$

Bu matrislerden imgenin doku karakteristiğini içeren kontrast, korelasyon, enerji, homojenlik, entropi, ortalama ve standart sapma olmak üzere 7 adet özellik hesaplanmıştır [20-22]. GLCM den hesaplanan dokusal özelliklerin bağıntıları aşağıda belirtilmiştir [22-25].

i) Kontrast

$$\sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i, j) \|i - j\| = n \right\} \quad (3)$$

ii) Homojenlik


$$\sum_{i,j} \frac{p(i, j)}{1 + (i - j)^2} \quad (4)$$



vektör, imge için öznitelik vektörü olarak kullanılmıştır.

### 2.3. Sınıflandırma Sisteminin Mimarisi

GLCM ve TEM yöntemleri kullanılarak, her imgenin iki ayrı öznitelik vektörleri çıkarılmıştır. Her iki yöntem kendine özgü yaklaşımıyla, aynı imge için farklı doku öznitelik vektörlerinin elde edilmesine olanak sağlamıştır. Tasarlanan model yapısı Şekil-4'de gösterilmiştir. İlk aşamada, GLCM matrisinden elde edilen istatistiksel parametreler sınıflandırıcı girişine uygulanmıştır. Hesaplanan parametreler sırasıyla kontrast ( $x1$ ), korelasyon ( $x2$ ), enerji ( $x3$ ), homojenlik ( $x4$ ), entropi ( $x5$ ), ortalama ( $x6$ ) ve standart sapma ( $x7$ ) değerleridir. Sistemin giriş parametreleri, sınıflandırıcı türüne göre normalizasyona tabi tutularak, [0-1] değer aralığına dönüştürülmüştür. Ürün imgelerine ilişkin öznitelik vektörleri MLP, k-NN ve SVM sınıflandırıcıları kullanılarak bitkinin gelişim dönemlerine göre sınıflandırılmıştır.



Şekil-4: GLCM veya TEM tabanlı sınıflandırma sistem yapısı

İkinci aşamada, GLCM tabanlı sınıflandırma sistemine benzer bir yapı TEM tabanlı sınıflandırma sistemi için oluşturulmuştur. Farklı kernellerden elde edilen doku enerjilerinin ortalaması, ürün imgelerini temsil eden öznitelik vektörlerini oluşturmuştur. Her imgenin öznitelik vektörünün oluşturulmasında hesaplanan vektör elemanları (parametreler) aşağıda belirtildiği şekilde elde edilmiştir.

EE kernelinden hesaplanan (E5E5) filtresinin enerji ortalaması ( $x1$ ), SS kernelinden hesaplanan (S5S5) filtresinin enerji ortalaması ( $x2$ ), RR kernelinden hesaplanan (R5R5) filtresinin enerji ortalaması ( $x3$ ), EL ve LE kernellerinden hesaplanan (E5L5) filtresinin enerji ortalaması ( $x4$ ), SL ve LS kernellerinden hesaplanan (S5L5) filtresinin enerji ortalaması ( $x5$ ), RL ve LR kernellerinden hesaplanan (R5L5) filtresinin enerji ortalaması ( $x6$ ), SE ve ES kernellerinden hesaplanan (S5E5) filtresinin enerji ortalaması ( $x7$ ), RE ve ER kernellerinden hesaplanan

(R5E5) filtresinin enerji ortalaması ( $x8$ ), RS ve SR kernellerinden hesaplanan (R5S5) filtresinin enerji ortalamasıdır ( $x9$ ). Hesaplanan öznitelik vektörleri, sınıflandırıcı türüne göre normalizasyona tabi tutularak, [0-1] değer aralığına dönüştürülmüştür. Ürün imgelerine ilişkin öznitelik vektörleri sınıflandırıcının girişine uygulanarak, bitkinin gelişim dönemlerine göre sınıflandırılmıştır.

GLCM ve TEM tabanlı her iki sistemin çıkışında, ürün imgeleri dört farklı grupta sınıflandırılmıştır. Ekim dönemi - Sınıf I, az gelişmiş dönem - Sınıf II, tam gelişmiş dönem - Sınıf III ve hasat dönemi - Sınıf IV olarak adlandırılmıştır. Her sınıfa ilişkin örnek örüntüler Şekil-2'de gösterilmiştir.

Bu çalışmada toplam 120 imge kullanılmış olup, çapraz doğrulama yapılarak 120 örneğin dönüşümlü olarak eğitim ve test veri setinde yer alması sağlanmıştır. Çapraz doğrulama sonucu elde edilen veri setinin 3/4 oranı eğitim seti, geriye kalan oran ise test seti için rastgele oluşturulmuştur. Farklı sınıflandırma yöntemleri ile elde edilen tüm performans sonuçları 3. bölümde sunulmuştur.

Performans hesabı, sınıflandırıcıların (MLP, k-NN ve SVM) test sonuçları ile elde edilmesi gerek sonuçların eşleşmesi oranına göre yapılır. Diğer bir deyişle,

$$Performans = \frac{\text{Doğru saptanan örüntü sayısı}}{\text{Toplam test örüntü sayısı}} \times 100$$

eşitliğiyle hesaplanır.

### 3. Uygulama ve Başarımlar

Tüm öznitelik parametreleri kullanılarak, belirtilen sınıflandırıcılara ilişkin performans değerleri bu aşamada hesaplanmıştır. Tüm sınıflandırıcıların test performansları dikkate alındığında, en düşük oranın %70 olduğu gözlenmiştir.

#### 3.1 GLCM tabanlı Sınıflandırma Sonuçları

MLP ile sınıflandırmada, ağ yapısının belirlenmesi önemli bir aşamadır. Kolmogorov'un 1957 yılında yaptığı çalışmada, tek gizli katmanlı bir ağın her türlü problemi sonlu adımda çözebileceğini matematiksel olarak kanıtlamış, ancak gizli katmanda bulunması gereken nöron sayısı belirsizliğini korumuştur [31]. Bundan dolayı, MLP uygulamaları tek gizli katman üzerinden yapılmıştır. 7-n-4 MLP ağ yapısı GLCM tabanlı öznitelik

vektörlerinin sınıflandırılmasında, 9-n-4 ağ yapısı ise TEM tabanlı öznelik vektörlerinin sınıflandırılmasında kullanılmıştır. En iyi performansı sağlayacak ağ yapısının bulunabilmesi için gizli katmandaki nöron sayısı, n=5:5:50 değerlerinde alınmıştır. Problemin çözümü ikili sınıflandırmaya dayandığından, ağ yapısında kullanılan çıkışlar [1000] ekim dönemini, [0100] az gelişmiş dönemini, [0010] tam gelişmiş dönemini ve [0001] hasat dönemini ifade eder.

GLCM tabanlı MLP sınıflandırıcısının farklı ağ yapılarında elde edilen performans bilgileri Çizelge-2'de ve hata matrisi ise Çizelge-3'de verilmiştir. GLCM tabanlı MLP performans değerlerine bakıldığında, Çizelge-2'de görüldüğü gibi performans başarısı [70.00 93.33] aralığında gözlemlenmiş ve en yüksek performans değerinin 7-25-4 ağ topolojisi tarafından sağlandığı saptanmıştır.

**Çizelge-2:** GLCM tabanlı Farklı MLP ağ sınıflandırıcısının performans değerleri. Ağırlıklar (0,1) aralığında rastgele belirlenmiş, öğrenme faktörü 0.9, momentum katsayısı 0.4 ve tüm katmanlarda aktivasyon fonksiyonu olarak logsig kullanılmıştır.

MLP Yapısı	Eşlenen Örüntü Oranı	Performans (%)
7-5-4	(21/30)	70.00
7-10-4	(25/30)	83.33
7-15-4	(27/30)	90.00
7-20-4	(27/30)	90.00
<b>7-25-4</b>	<b>(28/30)</b>	<b>93.33</b>
7-30-4	(26/30)	86.67
7-35-4	(27/30)	90.00
7-40-4	(27/30)	90.00
7-45-4	(26/30)	86.67
7-50-4	(26/30)	86.67

**Çizelge-3:** En iyi performansa sahip GLCM tabanlı MLP sınıflandırıcısının hata matrisi (confusion matrix).

YSA		Saptanan sınıflar			
		Sınıf I	Sınıf II	Sınıf III	Sınıf IV
Asıl sınıflar	Sınıf I	8	0	0	0
	Sınıf II	1	16	0	0
	Sınıf III	0	0	2	0
	Sınıf IV	0	1	0	2

k-NN sınıflandırıcısında, en yakın komşu sayısı k=1:1:20 değerlerinde alınarak, her bir k sayısı için

performans değeri hesaplanmıştır. GLCM tabanlı (k-NN) sınıflandırıcısının farklı komşu (k) sayıları için elde edilen performans bilgileri Çizelge-4 gösterilmiştir. En iyi performansın farklı k değerlerinde edilebildiği ve sınıflandırıcının performans başarısının [83.33-93.33] aralığında olduğu gözlemlenmiştir. En iyi performansı sergileyenlerden biri olan k=7 olan sınıflandırıcının hata matrisi (confusion matrix) ise Çizelge-5'te verilmiştir.

**Çizelge-4:** GLCM tabanlı öznelik vektörleri için farklı k değerleri ile k-NN sınıflandırıcı performansı.

Komşu sayısı (k)	Eşlenen örüntü oranı	Performans (%)
1	(28/30)	93.33
2	(28/30)	93.33
3	(27/30)	90.00
4	(27/30)	90.00
5	(27/00)	90.00
6	(28/30)	93.33
7	(28/30)	93.33
8	(28/30)	93.33
9	(28/30)	93.33
10	(26/30)	86.67
11	(27/30)	90
13	(27/30)	90
15	(27/30)	90
17	(26/30)	86.67
20	(25/30)	83.33

**Çizelge-5:** En yüksek performansa sahip GLCM tabanlı k-NN (k=7) sınıflandırıcısının hata matrisi.

k-NN		Saptanan sınıflar			
		Sınıf I	Sınıf II	Sınıf III	Sınıf IV
Asıl sınıflar	Sınıf I	9	0	0	0
	Sınıf II	0	13	1	0
	Sınıf III	0	0	2	0
	Sınıf IV	0	1	0	4

GLCM tabanlı SVM sınıflandırıcısının performansı Çizelge-6'da verilmiştir. Çizelge 6'da görüldüğü gibi sistemin en yüksek performansı %100 olarak htrbf (Heavily Tailed RBF) kernel tabanlı SVM sınıflandırıcısında gözlemlenmiştir. En yüksek performansa sahip htrbf tabanlı SVM sınıflandırıcısının başarısı %100 olması nedeniyle, çalışmanın hata matrisi (confusion matrix) verilmemiştir.

**Çizelge-6:** GLCM tabanlı farklı kernellere ait SVM sınıflandırıcısının performans değerleri. Kernel genişlik parametresi sigma ( $\sigma=1$ ), Lagrange Çarpan Parametresi ( $c=10000$ ), QP metot parametresi ( $\lambda=1e-2$ ) olarak seçilmiştir.

Kernel	Eşlenen örüntü oranı	Performans (%)
Gaussian	(28/30)	93.33
Poly	(27/30)	90.00
Polyhomog	(28/30)	93.33
Htrbf	(30/30)	100.00

### 3.2 TEM tabanlı Sınıflandırma Sonuçları

TEM tabanlı MLP uygulamaları tek gizli katman üzerinden yapılmıştır. TEM tabanlı öznelik vektörlerinin sınıflandırılmasında 9-n-4 ağ yapısı kullanılmıştır. En iyi performansı sağlayacak ağ yapısının saptanabilmesi için *gizli katmandaki nöron sayısı*,  $n=5:5:50$  değerlerinde alınmıştır. MLP sınıflandırıcısının farklı ağ yapıları ile elde edilen performans sonuçları Çizelge-7'de gösterilmiştir. Çizelgeden görüldüğü üzere tüm ağ yapılarından elde edilen başarı oranı 100% olduğu görülmektedir. Bu başarı doğrudan öznelik vektör çıkarmada kullanılan TEM yönteminin, dokuya ilişkin ayırt edici özellikleri imgelerden tüm detaylarıyla çıkardığı sonucuna varılabilir. Saptanan sınıfların tümü doğru sınıflar olması nedeniyle (performans %100), bu çalışmaya ilişkin hata matrisi gösterilmemiştir.

**Çizelge-7:** TEM tabanlı MLP ağ sınıflandırıcısının performans değerleri. Ağırlıklar (0,1) aralığında rastgele belirlenmiş, öğrenme faktörü 0.9, momentum katsayısı 0.4 ve tüm katmanlarda aktivasyon fonksiyonu olarak logsig kullanılmıştır.

MLP Yapısı	Eşlenen örüntü Oranı	Performans (%)
9-5-4	(30/30)	100.0
9-10-4	(30/30)	100.0
9-15-4	(30/30)	100.0
9-20-4	(30/30)	100.0
9-25-4	(30/30)	100.0
9-30-4	(30/30)	100.0
9-35-4	(30/30)	100.0
9-40-4	(30/30)	100.0
9-45-4	(30/30)	100.0
9-50-4	(30/30)	100.0

TEM tabanlı k-NN sınıflandırıcısında, en yakın komşu sayısı  $k=1:1:20$  değerlerinde alınarak, her bir k sayısı için performans değeri hesaplanmıştır. TEM tabanlı k-NN sınıflandırıcısının farklı komşu (k) sayıları için elde edilen performans bilgileri Çizelge-8'de gösterilmiştir. En iyi performansın farklı k değerlerinde edilebildiği gözlemlenmiştir. MLP de olduğu gibi performansın %100 olması nedeniyle, hata matrisi çizelgesi verilmemiştir.

**Çizelge-8:** TEM tabanlı öznelik vektörleri için farklı k değerleri ile k-NN sınıflandırıcı performansı.

Komşu sayısı (k)	Eşlenen Örüntü oranı	Performans (%)
1	(30/30)	100.0
2	(27/30)	100.0
3	(27/30)	100.0
4	(27/30)	100.0
5	(27/30)	100.0
6	(29/30)	100.0
7	(29/30)	100.0
8	(29/30)	100.0
9	(28/30)	96.67
10	(29/30)	96.67
11	(29/30)	96.67
13	(28/30)	96.67
15	(28/30)	96.67
17	(28/30)	96.67
20	(27/30)	96.67

TEM tabanlı SVM sınıflandırıcısının performansı Çizelge 9'da gösterilmiştir. Çizelge görüldüğü üzere, sistemin en yüksek performansı %100 olarak tüm kernel çeşitlerinde gözlemlenmiştir. Saptanan sınıfların tümü doğru olması nedeniyle, hata matrisi gösterilmiştir.

**Çizelge-9:** Farklı SVM sınıflandırıcısının performans değerleri. Kernel genişlik parametresi sigma ( $\sigma=1$ ), Lagrange Çarpan Parametresi ( $c=10000$ ), QP metot parametresi ( $\lambda=1e-2$ ) olarak seçilmiştir.

Kernel Tipi	Eşlenen örüntü oranı	Performans (%)
Gaussian	(30/30)	100.0
Poly	(30/30)	100.0
Polyhomog	(30/30)	100.0
Htrbf	(30/30)	100.0

## 4. Sonuçlar ve Tartışma

Bu çalışmada, Kızıltepe (Mardin) tarım alanlarına ilişkin sayısal ürün imgelerinin, farklı sınıflandırma

(MLP, k-NN, SVM) yöntemleri kullanılarak, 4 farklı grupta (ekim dönemi, az gelişmiş dönem, tam gelişmiş dönem ve hasat dönemi) sınıflandırılması amaçlanmıştır. Sınıflandırma öncesi literatürde imge dokusuna duyarlı öznelik çıkarma yöntemleri belirlenmiş ve GLCM ve TEM yöntemleri öznelik çıkarma yöntemleri olarak bu çalışmada kullanılmıştır.

İlk aşamada, imgelere ilişkin GLCM tabanlı öznelik vektörleri elde edilmiştir. Vektör elemanları, GLCM matrisinin; kontrast, korelasyon, enerji, homojenlik, entropi, ortalama ve standart sapma değerleridir. İkinci aşamada, TEM yöntemi kullanılarak her imgeden 9 ayrı enerji haritası elde edilmiş ve enerji haritalarının istatistiksel ortalaması alınmıştır. Böylelikle, her imge için 9 elemandan oluşan bir öznelik vektörü elde edilmiştir. Her iki yöntem ile elde edilen öznelik vektörleri sırasıyla MLP, k-NN ve SVM yöntemleri ile sınıflandırılarak, ürün imgeleri gruplandırılmıştır.

GLCM tabanlı öznelik vektörlerinin farklı sınıflandırıcılar ile elde edilen başarı performansı [70 100] aralığında olduğu saptanmıştır. MLP ve k-NN sınıflandırıcılarının en yüksek performansları %93.33 olup, her iki sınıflandırıcı 2 imgeyi doğru sınıflandıramadığı saptanmıştır. En yüksek başarı (%100) htrbf kernel tabanlı SVM ile elde edilmiştir.

TEM tabanlı tüm sınıflandırıcı çeşitlerinde elde edilen sonuçlardan görüldüğü üzere, %100 başarı elde edilmiştir. Bu çalışmada kullanılan imgeler çerçevesinde, TEM yönteminin GLCM yöntemine göre daha başarılı olduğu gözlenmiştir. Ürün imgelerine ilişkin özneliklerin TEM yöntemi ile ürün gruplarına göre karakterize edilmiş olması, tüm sınıflandırıcıların yüksek performans sergilemesine olanak tanımıştır. Bu başarı, TEM öznelik vektör çıkarma yönteminin, literatürde bilinen bir bilginin teyidi olarak, dokuya karşı son derece duyarlı olduğu sonucunu doğurur. Ayrıca TEM yönteminin ayırt edici özellikleri imgelerden tüm detaylarıyla çıkarmış olması, sınıflandırıcıların performansını artırmıştır.

Sonuç olarak, tarımsal ekim alanına gidilmeden ürünün hangi aşamada olduğunu istasyonlardan alınan imgelerden sınıflayabilecek bir sistem tasarlanmıştır. Bu çalışmada önerilen sınıflandırma sistemi geliştirilerek, çok çeşitli tarımsal ekin ürününe uygulanabileceği düşünülmektedir.

## Teşekkür

Bu çalışma İTÜ-UHUZAM ve TAGEM eş yürütücülüğünde ve DPT desteği ile gerçekleştirilen 2000A020010 nolu "Tarımsal Rekolte Tahmin ve Kuraklık İzleme" projesi kapsamında elde edilen veriler kullanılarak gerçekleştirilmiştir.

## Kaynakça

- [1] **B. Chanda and D.D. Majumdar**, 2002, 'Digital Image Processing and Analysis', PHI, New Delhi.
- [2] **Gonzalez R.C. and Woods R.E.**, 1992, 'Digital Image Processing', Addison Wesley Pub Company.
- [3] **Pan, G., Li, F.M. and Sun, G.J.**, 2007, 'Digital camera based measurement of crop cover for wheat yield prediction'. Geoscience and Remote Sensing Symp. IGARSS 2007. IEEE International. 797-800.
- [4] **Conway, JA., Brown, L.M.J., Veck, NJ., Wielogorski, A., Borgeaud, M.**, GEC-Marconi Res. Centre, Chelmsford. 1991, "A Model-Based System for Crop Classification from Radar Imagery" Antennas and Propagation, ICAP91, Seventh Int. Conference on (IEE). Vol.2, pp. 616-619.
- [5] **Shahin M. A., Tollner E. W. and Gitaitis R. D.**, 2002, "Classification of sweet onions based on internal defects using image processing and neural network techniques." Transactions of the ASAE, 2002, vol. 45, no. 5, pp. 1613-1618.
- [6] **Saito Y., Hatanaka T. and Uosaki K.**, 2003, "The eggplant classification using artificial neural network," Neural Networks, vol. 2, pp. 1013-1018
- [7] **Wan Y. N., Lin C. M. and Chiou J. F.**, 2000, "Adaptive classification method for an automatic grain quality inspection system using machine vision and neural network," presented at 2000 ASAE Annual International Meeting, USA.
- [8] **Byvatov E., Fechner U. and Sadowski J.**, 2003, "Comparison of support vector machine and artificial neural network systems for drug/nondrug classification," Chemical Information and Computer Science, vol. 43, no. 6, pp. 1182-1189.
- [9] **Jiazhi P., Min H., Yong H.**, 2007, "Crop and Weed Image Recognition by Morphological Operations and ANN Model". Instrumentation and



Measurement Technology Conference Proceedings. IMTC 2007 IEEE page(s) 1-4.

[10] **Yuan H., Van Der Wiele C.F., Khorram S.**, 2009, "An Automated ANN System for Land Use/Land Cover Classification from Landsat TM Imagery", *Remote Sens.*, 1, 243-265

[11] **Cortes C., Vapnik V.N.**, 1995, "Support-vector networks", *Machine Learning*, vol. 20, pp. 273-297.

[12] **Xiaoli L., Pengcheng N, Zheng-Jun Q., Yong H.**, 2011, "Using wavelet transform and multi-class least square support vector machine in multi-spectral imaging classification of Chinese famous tea". *Expert Systems with Applications Vol.38, Issue 9, Pages 11149-11159.*

[13] **Burges C.**, 1998, "A tutorial on support vector machines for pattern recognition," *Data Mining and Knowledge Discovery*, vol. 2, pp. 121-167.

[14] **Samuel E. B., and Ciril K.** 2001, "Using k-nearest-neighbor classification in the leaves of a tree", *Computational Statistics & Data Analysis* 40 (2002) 27 – 37.

[15] **Chen K.S., Huang W.P., Tsay D.H., and Amar F.**, 1996, "Classification of Multifrequency Polarimetric SAR Imagery Using a Dynamic Learning Neural Network". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 34, No.3

[16] **Kiani, S., Azimifar, Z., Kamgar, S.**, 2010, "Wavelet-Based Crop Detection and Classification". *Electrical Engineering ICEE2010, 18th Iranian Conference. Pages: 587 – 591.*

[17] **Cao L.J., Chua K.S. and Chong W.K.**, 2003, "A comparison of PCA, KPCA and ICA for dimensionality reduction in support vector machine", *Neurocomputing*, vol. 55, pp. 321-336.

[18] **Soh L., Tsatsoulis C.**, 1999, *Texture Analysis of SAR Sea Ice Imagery Using Gray Level Co-Occurrence Matrices*, *IEEE Transactions on Geoscience and Remote Sensing*, vol. 37, no.2

[19] **Zaim, A., Sawalha, A., Quweider, M., Iglesias, J.Tang, R.**, 2006, "A New Method for Iris Recognition using Gray-Level Co-Occurrence Matrix", *IEEE International Conference on Electro/Info. Tech., Michigan, U.S.A.*, 350-353.

[20] **Horng, M. H., Huang, X. J. ve Zhuang, J. H.** 2003. *Texture Feature Coding Method for Texture*

*Analysis and It's Application. Journal of Optical Engineering*, 42 (1), pp: 228-238.

[21] **Roumi, M.** 2009. *Implementing Texture Feature Extraction Algorithms on FPGA*. Master thesis, Delft University of Technology, Faculty of Electrical Engineering, Mathematics and Computer Science, Delfth, Netherlands, pp:15.

[22] **Demirhan A., Güler İ.**, 2010, 'Özörgütlemeli Harita Ağları Ve Gri Düzey Eş Oluşum Matrisleri ile İmge Bölütleme'. *Gazi Üniv. Müh. Mim. Fak. Dergisi Cilt 25, No 2, 285-291.*

[23] **Leen-Kiat S., and Costas T.**, 1999, "Texture Analysis of SAR Sea Ice Imagery Using Gray Level Co-Occurrence Matrices". *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 37, No.2

[24] **Haralick R.M., Shanmugam K., Dinstein I.**, 1973, "Textural Features for Image Classification", *IEEE Transactions on Systems, Man, and Cybernetics*, Vol. SMC-3, No: 6.

[25] **Manian V., Vbsquez R.** 1997. "A Framework for SAR Image Classification: Comparison of Co-Occurrence and a Gabor based method", *Geoscience and Remote Sensing, Remote Sensing-A Sci. Vision for Sustainable Development, IEEE International On* pp: 335 - 337 vol 1.

[26] **Christodoulou, C. I., Pattichis, C. S., Pantziaris, M. and Nicolaidis, A.** 2003, "Texture Based Classification of Atherosclerotic Carotid Plaques". *IEEE Transactions on Medical Imaging*, Vol. 22, No. 7, pp: 902-912.

[27] **Wu, C.M., Chen, Y.C., and Hsieh, K.S.** 1992. "Texture Features for Classification of Ultrasonic Liver Images", *IEEE Transactions on Medical Imaging*, Vol. 11, No. 2, pp: 141-152.

[28] **Laws, K. I.** 1979. "Texture energy measures," in *Proc. Image Understanding Workshop*, pp: 47-51.

[29] **Laws., K.I.** *Textured Image Segmentation*. PhD thesis, Univ.Southern California, 1980.

[30] **Choi, B., Han, S. and Chung, B., Ryou, J.** 2011. "Human Body Parts Candidate Segmentation Using Laws Texture Energy Measures with Skin Color". *Advanced Communication Technology (ICACT)*, 13-16 Feb. 2011, Seoul. pp: 556-560.

[31] **Şengör, N.**, 2001, *YSA Yüksek Lisans Ders Notları*, İTÜ Elektrik Elektronik Fakültesi, İstanbul

