

**T.C.
SÜLEYMAN DEMİREL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**BUDAK FAKTÖRÜNE GÖRE KIZILÇAM (*PINUS BRUTIA TEN.*)
AHŞAP DÖŞEME TAHTALARININ KALİTE SINIFININ GÖRÜNTÜ
İŞLEME TEKNİKLERİ KULLANILARAK BELİRLENMESİ**

İbrahim ÇETİNER

**Danışman
Yrd. Doç. Dr. Ahmet Ali VAR**

**DOKTORA TEZİ
ORMAN MÜHENDİSLİĞİ ANABİLİM DALI
ISPARTA – 2014**

© 2014 [İbrahim ÇETİNER]

TEZ ONAYI

İbrahim ÇETİNER tarafından hazırlanan "**Budak Faktörüne Göre Kızılçam (*Pinus brutia* Ten.) Ahşap Döşeme Tahtalarının Kalite Sınıfının Görüntü İşleme Teknikleri Kullanılarak Belirlenmesi**" adlı tez çalışması aşağıdaki jüri üyeleri önünde Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü **Orman Mühendisliği Anabilim Dalı'nda DOKTORA TEZİ** olarak başarı ile savunulmuştur.

Danışman **Yrd.Doç.Dr. Ahmet Ali VAR**
Süleyman Demirel Üniversitesi



Jüri Üyesi **Prof. Dr. Nusret AS**
İstanbul Üniversitesi



Jüri Üyesi **Doç.Dr. Kürşad ÖZKAN**
Süleyman Demirel Üniversitesi



Jüri Üyesi **Doç.Dr. Ecir Uğur KÜÇÜKSİLLE**
Süleyman Demirel Üniversitesi



Jüri Üyesi **Doç. Dr. Tuncay AYDOĞAN**
Süleyman Demirel Üniversitesi



Enstitü Müdürü

Doç. Dr. Ahmet ŞAHİNER



TAAHHÜTNAME

Bu tezin akademik ve etik kurallara uygun olarak yazıldığını ve kullanılan tüm literatür bilgilerinin referans gösterilerek tezde yer aldığını beyan ederim.

İbrahim ÇETİNER

İÇİNDEKİLER

	Sayfa
İÇİNDEKİLER	i
ÖZET	iii
ABSTRACT	v
TEŞEKKÜR	vii
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	xi
SİMGELER VE KISALTMALAR DİZİNİ	xii
1. GİRİŞ	1
2. KAYNAK ÖZETLERİ	5
3. MATERYAL VE YÖNTEM	12
3.1. Ahşap	12
3.2. Ahşap Döşeme Çeşitleri	13
3.2.1. Klasik ahşap döşemeler	13
3.2.2. Döşemelik lambri imalatı	14
3.2.3. Düz lambri imalatı	14
3.2.4. Fugalı lambri imalatı	15
3.2.5. Lambalı lambri imalatı	15
3.2.6. Kafes döşeme imalatı	16
3.2.7. Parke döşemeler	17
3.2.7.1. Rabıtalı ahşap parke imalatında önemli hususlar	18
3.2.7.2. Rabıtalı ahşap parke sınıfları	18
3.3 Kızılçam (Pinus brutia Ten. henry)	20
3.4. Orman Ürünleri Standartları	21
3.4.1. TS 11970/Mart 1996 Standardı	23
3.4.2. TS 11970 EN13990/Mart 2006 Standardı	24
3.5. Örüntü Tanıma	27
3.5.1. Örüntü tanıma süreci	27
3.6. Öz nitelik Çıkarma	29
3.6.1. IM öz nitelik çıkarma yöntemi	33
3.6.2. GLCM öz nitelik çıkarma yöntemi	34
3.6.3. DM öz nitelik çıkarma yöntemi	36
3.6.3.1. Haar	36
3.6.3.2. Daubechies db	37
3.6.3.3. Bior	37
3.6.3.4. Coif	38
3.6.3.5. Symlet	38
3.6.3.6. İki boyutlu kesikli zaman dalgacık dönüşümleri	42
3.7. Sınıflandırma	44
3.7.1. KNN sınıflandırma yöntemi	44
3.7.2. LDA sınıflandırma yöntemi	45
3.7.3. BAYES sınıflandırma yöntemi	46
3.7.4. YSA sınıflandırma yöntemi	46
3.7.4.1. Yapay sinir ağlarının ana öğeleri	47
3.7.4.2. Yapay Sinir Ağlarında Öğrenme	51
3.7.4.3. Geri yayılım yöntemi	56
3.7.4.4. Modelleme	57

3.8. ROC Analizi	58
4. ARAŞTIRMA BULGULARI	59
4.1. Veritabanlar	59
4.1.1. Budak veritabanı	59
4.1.2. Döşemelik tahta veritabanı	60
4.1.3. Ahşap veritabanı	61
4.2. Gerçek Renk Gri Skala Dönüşümü	61
4.3. Eşik Değeri Belirleme ve Deney Sonuçları	62
4.3.1. Global eşikleme	65
4.3.2. Minimum çapraz entropisi yöntemi ile eşikleme sonuçları	66
4.3.3. Otsu yöntemi ile eşikleme sonuçları	68
4.4. Bağlantı Bileşen Analizi ile Etiketlenmiş Görüntülerin Deney Sonuçları	71
4.5. Medyan Filtreleme ile Gürültü Temizleme Deney Sonuçları	73
4.6. Ahşap Görüntüleri Üzerindeki Nesnelerin İşaretlenmesi	73
4.7. TS 11970 Standardına Göre Deney Sonuçları	74
4.8. Budak Tip Belirleme	76
4.9. YSA Kullanılarak Budak Görüntülerinin Sınıflandırılması	85
4.9.1. Eğitim yönteminin seçimi	87
4.10. Farklı Sınıflandırıcılar Kullanılarak Budak Görüntülerinin Sınıflandırılması	93
4.11. Döşemelik Tahtalardaki Budakların Analizi	97
4.11.1. Uzman kişilerce döşemelik tahtaların sınıflandırılması	97
4.11.2. Uzman sistemlerce döşemelik tahtaların sınıflandırılması	98
5. TARTIŞMA VE SONUÇ	102
KAYNAKLAR	110
EKLER	118
EK A. Deney Sonuçları	119
ÖZGEÇMİŞ	155

ÖZET

Doktora Tezi

BUDAK FAKTÖRÜNE GÖRE KIZILÇAM (*PİNUS BRUTIA* TEN.) AHŞAP DÖŞEME TAHTALARININ KALİTE SINIFININ GÖRÜNTÜ İŞLEME TEKNİKLERİ KULLANILARAK BELİRLENMESİ

İbrahim ÇETİNER

**Süleyman Demirel Üniversitesi
Fen Bilimleri Enstitüsü
Orman Mühendisliği Anabilim Dalı**

Danışman: Yrd. Doç. Dr. Ahmet Ali VAR

Bu tez çalışmasında, kızılçam ağacından sadece budak faktörüne göre elde edilen ahşap döşeme tahtalarının kalite sınıfının görüntü işleme teknikleri kullanılarak belirlenmesini hedefleyen bir çalışma gerçekleştirilmiştir. Günümüzde ahşabın kalitesi, kusurların sayısı ve onların dağılımları ile belirlenmektedir. Bir ahşap parçasının direncini azaltan en genel kusur tipine budak denilmektedir. Ahşapların el ile seçilmesi ve sınıflandırılması zor, maliyetli ve zaman alıcı bir işlemdir. Bu noktada, son ürünün kalitesini etkileyen ve budak kusurlarını doğru bir şekilde otomatik olarak tanımlanmasını ve incelenmesini sağlayan otomatik budak kusur tespit yöntemleri öne sürülmüştür.

Otomatik budak kusur tespit yöntemleri, orman ürünleri endüstrisinde verimliliği artırarak kaynaklardan daha iyi yararlanılmasına, işçilik maliyetlerinin azaltılmasına, daha akıllı, doğru ve güvenilir bir şekilde kerestelerin kalitelerine göre sınıflandırılmasına imkân tanımaktadır.

Otomatik budak kusur tespit yöntemleri, ahşap budak kusurlarının yerlerinin belirlenmesi ve bu budak kusur tiplerinin tanımlanması olmak üzere iki aşamadan oluşmaktadır. Budak kusurlarının bulunması istenen ahşap görüntülerin elde edilmesiyle başlamaktadır. Görüntülerin normalleştirilmesi ve gürültülerin temizlenmesi yapılması gereken ön işlemlerdir. Özneteliklerin çıkarılması ve sınıflandırılması ile budak kusurları sayısallaştırılarak tip tanımlaması yapılmaktadır.

Bu tez çalışmasının gerçekleştirilmesini sağlayabilmek için belirli şartlar altında elde edilmiş döşemelik tahta görüntü veritabanları kullanılmıştır. Bu görüntü veritabanları üzerinde budak büyüklükleri baz alınarak budak sınıfları TS 11970 ve TS EN13990 standartlarına göre belirlenmiştir.

Belirtilen standartlar ve veritabanları üzerinde ikilileştirme ve dört farklı eşikleme yöntemi uygulanmıştır. Otsu, İteratif tabanlı, minimum çapraz entropi tabanlı ve ortalama ile standart sapmaya bağlı farklı eşikleme yöntemleri

uygulanarak karşılaştırma yapılmıştır. Belirtilen eşikleme yöntemleri karşılaştırma yapabilmek için veritabanında bulunan tüm görüntüler üzerinde deneysel çalışmalar yapılmıştır. Bu deneysel çalışmalarda, ön plandaki budak kusurlarını arka plandaki budak kusuru olmayan bölgelerden etkili bir şekilde kaldırılmasını sağlayarak budak kusurlarını diğer nesnelerden bağımsız olarak ortaya çıkmasını sağlayan en iyi yöntem tespit edilmeye çalışılmıştır. Sonrasında, morfolojik işlemler ile budak kusur yerleri ve dağılımları tespit edilerek budak kusurlu bölgeler görüntüden tek tek çıkarılmıştır. Bu budak kusurlu bölgeler dalgacık moment (DM), moment değişmezleri yöntemi (IM), gri seviye eş oluşum matrisi (GLCM), IM+GLCM ve DM+GLCM momentleriyle ile öznitelikleri çıkarılmıştır. Çıkarılan öznitelikler belirtilen standartlara göre gruplandırılarak, ahşap üzerindeki budak tiplerine göre ahşap sınıflandırılması yapılmıştır. Sınıflandırılması yapılan ahşap üzerindeki her bir budağı tanıma aşamasında, en yakın k komşu yöntemi (KNN), yapay sinir ağları (YSA), doğrusal diskriminant analiz (LDA) ve Naive Bayes (BAYES) sınıflandırıcıları kullanılmıştır.

Çalışmada bir saniyeden daha kısa bir sürede, döşemelik tahta üzerindeki budak kusurları tespit edilerek tahtanın kalite sınıfı ve budak kusur tiplerinin tanımlanması gerçekleştirilmiştir. Bu süre, bir insanın ahşap budak kusurlarını tanıma süresinin ortalamasından çok daha kısadır. Döşemelik tahta kalite sınıfı, standartlarda belirtilen budak kusurunun büyüklüğü ve adedine göre yaklaşık %98'lik bir oranla gerçekleştirilmiştir. Budak kusur tiplerinin tanımlanması işlemi ile ilgili olarak Oulu Üniversitesinden alınan budak veritabanı görüntüleri üzerinde yapılan çalışmada %98'lik bir başarı elde edilmiştir. İkinci olarak farklı ışık ortamlarında çekilmiş döşemelik tahta veritabanı görüntüleri üzerinde yapılan çalışmalarda ise %72'lik bir başarı elde edilmiştir. İki farklı veritabanı üzerinde yapılan çalışmalardaki başarı sonuçlarındaki farklılıkların sebepleri arasında görüntülerin alındığı ortam, gölge etkisi, ışık yansıması, ışık, ahşap üzerinde her noktadaki parlaklığın aynı olmaması bulunmaktadır. Bu gibi sebeplerden dolayı görüntüde meydana gelen olumsuz etkileri ortadan kaldırabilecek şekilde bir sistem aracılığıyla elde edilebilecek görüntüler üzerinde yapılan deneysel çalışmalarda tip belirleme başarı oranının %98'e kadar artırılabilceği tespit edilmiştir.

Anahtar kelimeler: Ahşap, kızılçam, budak kusur tespiti, öznitelik çıkarma, kalite sınıflandırma

2014, 155 sayfa

ABSTRACT

Ph.D. Thesis

DETERMINATION USING IMAGE PROCESSING TECHNIQUES OF QUALITY CLASSES OF WOOD FLOORBOARDS PRODUCED FROM RED PINE ACCORDING TO KNOT FACTOR

İbrahim ÇETİNER

**Süleyman Demirel University
Graduate School of Applied and Natural Sciences
Department of Forestry Engineering**

Supervisor: Asst. Prof. Dr. Ahmet Ali VAR

In this thesis, quality of class of final product is intended to automatically determine by setting properly distribution and number of defects on wood. Nowadays number of defects and quality of wood is determined by their distribution. The most common type of defect is called knot by reducing the resistance of a wooden part. Selection and classification of wood manually is difficult, costly and time-consuming process. At this point automatic defect detection methods have been proposed to affect the quality of the final product and defects are accurately automatically identified and analyzed.

Automatic defect detection methods that are recognize opportunities in more intelligent, accurate and reliable way is to allow to be classified according to the quality of wood, reduction of labor costs, and better utilization of resources by increasing productivity in the forest products industry.

Automatic defect detection methods consist of two stages that are the determination of location of defect used in the forest products industry and including identification of this defect type. The basic of these methods begin with the acquisition of desired wood images of finding defects. Normalization of images and removal of noises are preprocesses which are needed to be done. By digitized defects with extraction and classification of features may be performed to type identification.

Floorboards image databases obtained under certain conditions which are used to ensure the realization of this thesis. Knot classes are determined according to TS 11790 and EN 13990 standards based on the size of knot on this image databases.

Binary on different standards and databases and three different threshold methods were applied. The comparison was made by applying different threshold methods that are connected to standard deviation with an average, the minimum cross-entropy-based, iterative-based. These threshold methods have been tested in all the images contained in databases. Best method that providing independent of other objects of defects was studied to determine by

removing non-defective regions in background from defects in the foreground in these experiments. Then, the defective regions are removed individually from the image by detecting locations and distributions of defects with morphological operations. If these defective regions are knot, features are extracted with wavelet moment (DM), moment invariant method (IM), gray level co-occurrence matrix (GLCM), IM+GLCM and DM+GLCM moments. Wood classification is made according to the type of knot on wood by grouping of extracted features are according to specified standards. K nearest neighbor method (KNN), artificial neural network (YSA), linear discriminant analysis (LDA) and Naive Bayes (BAYES) classifiers are used in recognition stage of each knot on classification wood.

In the study, determination of knot defect types and quality class of board by detection of knot defects on the floorboard in a shorter time than a sec are carried out. This time is much shorter than a human's average identification the time of all wood defects.

The floorboard quality class is carried out approximately a rate of 98% determined according to number and size of knot defect specified in the standards. In the study has been achieved a 98% success on knot image database taken from the University of Oulu with regarding to identification process of knot defect types. Secondly, in the study a 72% success has been achieved on floorboard image database captured in different lighting environments. Light reflection, the light, the brightness of each point on the wood are not the same, image captured environment, shadow effect are found between differences causes of study success results on two different database. Such reasons, the types determine success rate can be increased up to 98% which is determined in experimental studies performed on images that can be obtained through a system the negative effects on the image which may eliminate.

Keywords: Wood, pine, knot defect detection, feature extraction, quality classification.

2014, 155 pages

TEŞEKKÜR

Bu araştırma için beni yönlendiren, karşılaştığım zorlukları bilgi ve tecrübesi ile aşmamda yardımcı olan değerli Danışman Hocam Yrd. Doç. Dr. Ahmet Ali VAR'a teşekkürlerimi sunarım. Literatür araştırmalarımnda ve tez çalışmamda yardımcı olan değerli hocalarım Prof. Dr. Nusret AS, Doç. Dr. Kürşad ÖZKAN, Doç. Dr. Ecir Uğur KÜÇÜKSİLLE ve Doç. Dr. Tuncay AYDOĞAN'a teşekkür ederim.

Orman ürünleri sınıflandırılmasında yardımlarını esirgemeyen sanayici alanında uzman Atilla HİLAL (Hilaller Orman Ürünleri), Mehmet TEKİN (Özdamar Kereste İmalat Ticaret ve San. Ltd. Şti), Altınar GÜÇ (Güçlü Kereste Fabrikası) beyefendilere teşekkür ederim.

Tez çalışmam sırasında yardımlarını esirgemeyen Öğr. Gör. Halit ÇETİNER'e teşekkür ederim.

3126-D-12 No'lu Proje ile tezimi maddi olarak destekleyen Süleyman Demirel Üniversitesi Bilimsel Araştırma Projeleri Yönetim Birimi Başkanlığı'na teşekkür ederim.

Tezimin her aşamasında beni yalnız bırakmayan aileme sonsuz sevgi ve saygılarımı sunarım.

İbrahim ÇETİNER
ISPARTA, 2014

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1 Profil ve rabıta makinesinde lambri yapılması	14
Şekil 3.2 Bir weinig makinesinde bıçakların konumu	14
Şekil 3.3 Çam keresteden yapılmış fugalı lambri örnekleri	15
Şekil 3.4 Fuga açılmış lambri örnekleri	15
Şekil 3.5 Lambrielerde weing makineleri ile lamba açılması	16
Şekil 3.6 Lambalı lambrielerin daire testere makinesinde yapılışı	16
Şekil 3.7 Kafes döşemede ızgaraların yerleştirilmesi	17
Şekil 3.8 Parke döşeme teknikleri	17
Şekil 3.9 Rabıtalı tavan taban döşemesi	19
Şekil 3.10 Kızılçam orman alanı	20
Şekil 3.11 TS 11970 (1996) Budak Büyüklükleri	24
Şekil 3.12 TS EN 13990 (2006) Budak Büyüklükleri	26
Şekil 3.13 Kullanılan Budak Kusurları	28
Şekil 3.14 Örüntü Tanıma Süreci	28
Şekil 3.15 İki bölgenin Euler sayıları sırasıyla 0 ve -1	30
Şekil 3.16 Yoğunluğun örnekleri a) Yoğun olan bölge örneği, b) Yoğun olmayan bölge örneği	31
Şekil 3.17 Bölgenin dış merkezlilik değeri A/B örneği	31
Şekil 3.18 Eş oluşum matrisinin elde edilmesi .	35
Şekil 3.19 Haar Dalga Şekli	37
Şekil 3.20 Daubechies Dalga Şekli	37
Şekil 3.21 Bior Dalga Şekli	38
Şekil 3.22 Coif Dalga Şekli	38
Şekil 3.23 Symlet Dalga Şekli	39
Şekil 3.24 Dalgacık dönüşümünde süzgeçleme işlemi .	40
Şekil 3.25 Standart dalgacık analizi	41
Şekil 3.26 Yaprak budak için dalgacık dönüşümü genel gösterimi	43
Şekil 3.27 Yapay bir sinir düğüm	48
Şekil 3.28 Etkinlik işlevi fonksiyonları: a) Doğrusal etkinlik işlevi fonksiyonu, b) Log-sigmoid etkinlik işlevi fonksiyonu	50
Şekil 3.29 Temel öğrenme yöntemi	51
Şekil 3.30 Danışmanlı öğrenme	52
Şekil 3.31 Geri yayılım ağ yapısı	54
Şekil 3.32 Çok katmanlı sinir ağı	55
Şekil 3.33. YSA eğitimi blok diyagramı	58
Şekil 4.1 Kullanılan budak veritabanından bazı örnekler	59
Şekil 4.2 Isparta yeni sanayi kereste fabrikalarından farklı ışık ortamlarında çekilmiş olan görüntüler	60
Şekil 4.3 Ahşap veritabanından bazı örnekler	61
Şekil 4.4 Renkli görüntüyü gri formata çevirme: a) orijinal görüntü,	

b) gri ölçeklenmiş görüntü	62
Şekil 4.5 Parlaklık ve karşıtlık değerine göre eşiklenmiş görüntüler:	
a) orijinal görüntü, b) eşiklenmiş görüntü	64
Şekil 4.6 Parlaklık ve karşıtlık değerine göre eşiklenmiş görüntüler:	
a) Orijinal görüntü, b) Eşiklenmiş görüntü	66
Şekil 4.7 Parlaklık ve karşıtlık değerine göre eşiklenmiş görüntüler:	
a) Orijinal görüntü, b) Eşiklenmiş görüntü	66
Şekil 4.8 Parlaklık ve karşıtlık değerine göre eşiklenmiş görüntüler:	
a) Orijinal görüntü, b) Eşiklenmiş görüntü	66
Şekil 4.9 minCE yöntemine göre eşiklenmiş görüntüler: a) Orijinal görüntü, b) Eşiklenmiş görüntü	68
Şekil 4.10 Otsu yöntemine göre eşiklenmiş görüntüler: a) Orijinal görüntü, b) Eşiklenmiş görüntü	70
Şekil 4.11. TS 11970 standardına göre işlem adımları: a) Orijinal görüntü b) Iteratif yöntemle eşiklenmiş görüntü c) Görüntünün birden çıkarılması, d) Görüntünde beyaz kısımlarının doldurulması.	72
Şekil 4.12 Medyan filtreleme a) İki tonlu görüntü b) Gürültüler temizlenmiş görüntü	73
Şekil 4.13. Ahşap üzerindeki budak olma ihtimali olan nesnelerin etiketlenmesi	74
Şekil 4.14. TS 11970 göre deney sonuçları	74
Şekil 4.15 Tip tanımlaması: a) Orijinal görüntü, b) Etiketlenmiş görüntü, c) Örüntü tanıma adımlarının tamamının uygulandığı görüntü	76
Şekil 4.16 Döşemelik tahtanın ön işlemleri: a) Orijinal görüntü, b) Gri seviye görüntü, c) Eşiklenmiş görüntü, d) Deliklerin doldurulmuş görüntü	77
Şekil 4.17 Etiketleme sonuçları: a) Delikleri doldurulmuş görüntü, b) 500 mm ² 'den küçük olan bölgeleri kaldırılmış görüntü	78
Şekil 4.18 Etiketleme işlemi a) Etiketlenmiş görüntü, b) Görüntü nesnelerinin merkez değerlerine numaralar verilmesi	79
Şekil 4.19 Otsu eşikleme: a) Belirtilen standartlara uygun olarak tespit edilen bir budak bölgesi, b) Otsu eşikleme yöntemi ile ikilileştirilmesi	79
Şekil 4.20 Toplu olarak kusurlarının tespiti ve alan değerlerinin gösterilmesi	80
Şekil 4.21 Toplu olarak kusurlarının tespiti, tip tanımlaması ve TS 11970 standardına göre kalite belirlemesinin yapılması	81
Şekil 4.22 Toplu olarak kusurları tespiti, tip tanımlaması ve TS EN 13990 standardına göre kalite belirlemesinin yapılması	81
Şekil 4.23 TS EN 13990 standardına göre kalitesi belirlemiş döşemelik tahta	82
Şekil 4.24 TS 11970 standardına göre kalitesi belirlemiş döşemelik tahta	82
Şekil 4.25 TS EN 13990 standardına göre kalitesi belirlenmiş ahşap	83

Şekil 4.26 TS 11970 standardına göre kalitesi belirlemiş ahşap	83
Şekil 4.27 Sistemin blok diyagramı: a) Orijinal görüntü, b) Öznitelik vektörü, c) Öznitelik vektör girişine göre ağ yapısının oluşturulması, d) Budak kusurunun bağlantı bileşen analizi ile kutulanması.	85
Şekil 4.28 YSA genel yapısı	86
Şekil 4.29 Tanıma adımları	86
Şekil 4.30 Yaprak budak için sinyalin yaklaşım ve detay katsayılarının: a) Grafikselsel gösterimi, b) Enerjisinin şekilselsel gösterimi	88
Şekil 4.31 Kaynamış budak için sinyalin yaklaşım ve detay katsayılarının: a) Grafikselsel gösterimi, b) Enerjisinin şekilselsel gösterimi	88
Şekil 4.32 Kuru budak için sinyalin yaklaşım ve detay katsayılarının: a) Grafikselsel gösterimi, b) Enerjisinin şekilselsel gösterimi	89
Şekil 4.33 Kenar budak için sinyalin yaklaşım ve detay katsayılarının: a) Grafikselsel gösterimi, b) Enerjisinin şekilselsel gösterimi	89
Şekil 4.34 Boynuz budak için sinyalin yaklaşım ve detay katsayılarının: a) Grafikselsel gösterimi, b) Enerjisinin şekilselsel gösterimi	90
Şekil 4.35 Sağlam budak için sinyalin yaklaşım ve detay katsayılarının: a) Grafikselsel gösterimi, b) Enerjisinin şekilselsel gösterimi	90
Şekil 4.36 Çürük budak için sinyalin yaklaşım ve detay katsayılarının: a) Grafikselsel gösterimi, b) Enerjisinin şekilselsel gösterimi	91
Şekil 4.37 Öne sürülen çalışmanın adımları	93
Şekil 4.38 Aynı sınıf uzman görüşü	99

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1 Sağlam Budak	23
Çizelge 3.2 Düşen Budak	24
Çizelge 3.3 Ahşap nesnelerin özellik değerleri	29
Çizelge 4.1 Eşik değeri karşılaştırılması	65
Çizelge 4.2 İteratif yöntem ile eşik değeri karşılaştırılması	66
Çizelge 4.3 minCE yöntemi ile elde edilen eşik değerleri	67
Çizelge 4.4 Otsu yöntemi ile elde edilen eşik değerleri	71
Çizelge 4.5 Kusur tanıma süreleri	84
Çizelge 4.6 Budakların sinir ağları ile sınıflandırma sonuçları	87
Çizelge 4.7 Dalgacık türüne göre eğitim süresi, eğitim ve test tanıma oranları	91
Çizelge 4.8 Öznitelik çıkarım yöntemlerinden elde edilen öznitelik sayıları	94
Çizelge 4.9 1260 tane budak görüntüsünün DM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri	94
Çizelge 4.10 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları	94
Çizelge 4.11 1260 tane budak görüntüsünün IM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri	94
Çizelge 4.12 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları	95
Çizelge 4.13 1260 tane budak görüntüsü GLCM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri	95
Çizelge 4.14 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları	95
Çizelge 4.15 1260 tane budak görüntüsünün IM+GLCM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri	95
Çizelge 4.16 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları	95
Çizelge 4.17 1260 tane budak görüntüsünün GLCM+DM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri	96
Çizelge 4.18 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları	96
Çizelge 4.19 Deney Sonuçları	96
Çizelge 4.20 Uzman görüşleri ve sistem sonuçlarına göre ROC değerleri	100

SİMGELER VE KISALTMALAR DİZİNİ

A	Yaklaşım
AMP	Artificial metaplasticity
b	Sapma vektörü
BAYES	Naive Bayes sınıflandırıcısı
D	Detay
dbN	Daubechies dalgacık dönüşüm numarası
DM	Dalgacık moment
Eş	Eşitlik
F	Çizgiden merkeze mesafe
$f(x,y)$	x ve y noktaları için tanımlı gri seviyeli örüntü bilgisi
$g(t)$	Yüksek geçiren filtre
GLCM	Gri seviye eş oluşum matrisi
GLCM	Gri seviye iç içe matris
$h(t)$	Alçak geçiren filtre
IM	Moment değişmezleri yöntemi
KNN	En yakın k komşu yöntemi
LBP	Yerel ikili örüntüler
LDA	Doğrusal diskriminant analizi
NMF	Negatif olmayan matris çarpanlarına ayırma
OUG	Ortalama uzman görüşü
PCA	Temel bileşen analizi
ROC	Alıcı işlem karakteristikleri
$S(t)$	Orijinal sinyal
sn	Saniye
SOM	Özdüzenleyici Haritalar
Sp-DNDR	Doğrusal olmayan boyut azaltımı
SVM	Destek vektör makinesi
T	Gri seviye dönüşüm fonksiyonu
w	Ayarlanabilir ağ ağırlıkları
$W_{m,n}$	Dalgacık dönüşüm katsayıları
x_i	Ağın i . giriş değeri
y_i	Ağın i . çıkış değeri
YSA	Yapay sinir ağı
α	Ölçek parametresi
α_0	Sabit bir ötelenme adımı
β	Zamanda öteleme parametresi
β_0	Zaman ekseninde ötelenme aralığı
θ	Çizginin açısı
Φ	Yaklaşım fonksiyonu
ψ	Dalgacık fonksiyonu
η	Öğrenme oranı ya da adım büyüklüğü
μ_0	Gri sevideki görüntü değeri
μ_1	Parlaklık değeri
μ_2	Karşıtlık değeri

1. GİRİŞ

Kereste fabrikalarında tomruklar; inşaat, mobilya ve diğer imalat endüstrisi tarafından kullanılan ahşap malzemeye dönüştürülmektedir. Budaklar, genel olarak ahşap malzemenin bölünebilirliğini, çatlamasını ve eğilmesini etkilemektedir. Ahşap direncini budaklar zayıflatmakta ve sonrasında ahşabın üzerindeki kusurlardan dolayı yapısal kullanım değeri azalmaktadır. Kusurlu ahşap bir güce maruz kaldığında yük altında dikey çizgiler oluşmaktadır (Mohan ve Venkatachalapathy, 2012). Bu genel oluşan etkiler her bir ahşabın ekonomik değerini ve potansiyel kullanımını belirlemektedir. Bu kullanımlar kalite sınıflarının oluşmasının genel sebepleridir. Kalite sınıfları arasında ise fiyat farklılıkları bulunmaktadır. Bu yüzden ağaç endüstrisindeki kalite sınıflandırmasını gerçekleştiren görsel inceleme sürecinin doğruluğu önemli bir ilgi alanı olmuştur (Silven ve Kauppinen, 1994). Her bir ahşabın kalite sınıfı için farklı yaklaşımlar sunulmuş olmasına rağmen (Ylakoski ve Visa, 1993), kalite sınıfı ahşap üzerindeki kusurlara ve bu kusurların ahşap üzerindeki dağılımlarına bağlıdır.

Ahşap kalite sınıfı tanımlamasında farklı kusurların yanı sıra sağlam kusursuz ahşaplar bile önemli farklılıklara sahiptir. Örneğin, literatür incelendiğinde Avrupa'da 400 farklı kusur sınıfı, Finlandiya'ya özgü 30 farklı kusur sınıfı ve Türkiye'de 46 kusur sınıfı tanımlanmıştır (Günay, 1982). Bunlardan bazıları; sağlam, kuru, çürük, kaynamış, yaprak, kenar, boynuz gibi kusur sınıflarıdır. Bunların her biri boyut, konum, şekil, çap, büyüklük, genişlik ve görünüm gibi çeşitliğe sahiptir. Bu kadar fazla kusur tipinin tanımlı olması insan gözlemcisinin kusur sınıflandırmasını gerçekleştirmesini zorlaştırmaktadır. Bir insan gözlemci aynı anda 3-5 grupta sınıflandırmayı gerçekleştirebilmektedir, aynı zamanda bir insan her dakikada %75-80 doğrulukta 30 tane ahşabı sınıflandırabilmektedir (Silven ve Kauppinen, 1994).

Yu vd. (2010), uzun süren ağaç incelemesinin göz yorgunluğuna sebep olduğunu, bu sebepten dolayı kusur incelemede düşük etkinlik ve doğruluk oranları elde etmişlerdir. (Huber vd., 1985; Grönlund, 1995)'te geniş bir şekilde ahşapların sınıflandırılmasında göz yorgunluğundan dolayı, insan görü

incelemelerinin nadiren %70'den daha başarılı olduklarını tespit etmişlerdir.

Huber vd. (1985), kırmızı meşe ahşabının sınıflandırılmasında kusurun yer tespiti, tanımlanması ve belirlenmesinde insanın %68 performansa sahip olduğunu belirlemişlerdir. Grönlund (1995), iki farklı insan tarafından aynı ahşabın 4 farklı sınıfa ayrılmasında ahşapların sadece %60'ında aynı sınıfa atadıklarını tespit etmiştir. Bu sebeplerden dolayı, sadece insan ile yapılan incelemelerin yeteri kadar etkili, verimli ve objektif olduğu söylenemez.

Bu verimsizliği ortadan kaldırabilmek için bazı şirketler, insan ile etkileşimli olarak çalışan kusur kesme makinesi tasarlamışlardır. Ancak bu makinelerde, ahşaptaki kusurların işaretlenmesi ve tanımlanması bir insan tarafından floresan renkli kalem kullanılarak yapılmaktadır. Böylece kusurların makine tarafından ortadan kaldırılması sağlanmaktadır. Burada işaretleme yapılmasının dezavantajı, döşemelik tahta üzerinde işlem yapan operatörün çizik, kırık veya leke gibi çok küçük kusurları görememesi ve dikkatsizliğinden dolayı tanımlamada bu kusurların etkisini azaltmasıdır.

İnsan merkezli makine görü tabanlı sistemlerin başarı etkisinin düşük olmasından dolayı bilgisayar, veri ve sinyal işleme teknolojilerindeki gelişmelerde dikkate alınarak bu teknolojilerin avantajlarından yararlanan tahribatsız bir şekilde makine görü tabanlı otomatik kusur tespit yöntemleri geliştirmeye çalışılmıştır. Bu yöntemlerde;

1. Kusurları tanınması için bir insanın eğitilmesi,
2. Bu eğitim süresinin uzun zaman alması,
3. Eğitilmiş kişinin aynı anda en fazla 3-5 kusur sınıfına ayrılabilmesi,
4. Kusur tanımlamada insan kaynaklı hatalar gibi,

Sebepler göz önüne alınarak kusur tip sayısına göre kalite seviyesini belirleyebilecek tahribatsız, verimliliği yüksek, işçilik maliyetleri düşük, daha akıllı, doğru, güvenilir, farklı veri setleri üzerinde başarı ile çalışabilen bir makine görü tabanlı kalite kontrol ve kusur tespit yöntemleri geliştirilmiştir.

Kusur tespit yöntemlerinde değişik teknoloji ve yöntemler kullanılabilmektedir. Bu yöntemler kereste fabrikalarının ahşap kusur belirleme işlemlerinin değişik süreçlerinde uygulanabilmektedir. Kereste fabrikaları, kalite değerlendirmesi için standartlaşmış kuralları keresteler üzerine uyguladıktan sonra ağacı teslim etmektedir. Kereste fabrikalarında, keresteler kesilerek ahşaplar elde edilmektedir. Bu ahşaplar sırasıyla yapı (inşaat), mobilya ve diğer imalat endüstrilerinde kullanılmaktadır. Kereste türleri arasında önemli farklar olduğundan, otomatik olarak keresteden elde edilen ahşapları sınıflandırmak zor bir işlemdir (Lampinen vd., 1995). Ahşapların doğru bir şekilde makine görüşü tabanlı sınıflandırılabilmesi için, ahşapların uygun bir ışık altında çekilmiş görüntülerinin kullanılması gerekmektedir. Bu ortamın hazırlanması ve hassas bir kameranın mevcut olması önemlidir. Belirtilen koşullar altında VTT (Valtion Teknillinen Tutkimuskeskus) Teknik Araştırma Merkezi adında bir araştırma merkezi Finlandiya'da kurulmuştur. Bu merkez 3.000 personel ve 316 M€ (31.12.2012) döner sermayesi ile benzer konular üzerine 1981'den beri çalışmalar yapmaktadır (VTT Group, 2013).

Türkiye'de öz kaynakları işletme ve ürünleri değerlendirme politikası bakımından öncelikli çözüm bekleyen açmazların başında teknolojik transferinin gerçekleştirilmesidir. Bu fikir doğrultusunda motivasyon alınarak yapılan tez çalışmasında makine görüşü teknikleri kullanılarak kızılçam ahşap döşeme tahtalarının sadece budak faktörüne göre kalite sınıfının belirlenmesine yönelik deneysel-sayısal bir araştırma gerçekleştirilmiştir. Ülkemizde değişik konularda görüntü işleme teknikleri ile birçok araştırma yapılmıştır. Ancak döşeme tahtalarının kalite sınıfının görüntü işleme teknikleri kullanılarak belirlenmesine dair detaylı herhangi bir çalışmaya rastlanılmamıştır. Bu yüzden bu çalışma mevcut bilinen kereste kusurlarının makine görüşü tabanlı görüntü işleme teknikleri kullanılarak belirlenmesine yönelik bir yazılım çalışması olması açısından önem arz etmektedir. Bu bakımdan bu çalışmanın özellikle ahşap yer döşeme(masif yumuşak ağaç) tahtalarının üretiminde önemli bir yeri bulunmaktadır. Bu tez çalışmasının ek olarak en önemli özgün değerlerinden bir tanesi ise ahşap döşeme tahtalarının sadece budak faktörüne göre görüntü

işleme teknikleri kullanılarak kalite değerlerinin belirlenmesi, aynı şekilde diğer kusurlarında belirlenerek çalışmanın ileri bir boyuta taşınması noktasında bir başlangıç teşkil etmesidir.

Son zamanlarda birçok uygulamada makine görünüm avantajlarından yararlanılmaktadır. Makine görü sistemleri; kalite kontrol, yapı endüstrisi ve imalat gibi farklı alanları temel alan görüntüler üzerinde kullanılabildiği gibi ağaçların kalite sınıflarının belirlenmesinde de çok önemli rol oynamaktadır (Mahram vd., 2012).

Makine görü tabanlı ağaç kalite inceleme yöntemleri bilgisayara bağlı bir kamera aracılığıyla gerçekleştirilmektedir. Tezdeki adımlarımız özet olarak beş aşamadan oluşmaktadır:

1. Döşemelik tahta görüntülerinin kamera ile alınması.
2. Elde edilen görüntünün morfolojik işlemlerden geçirilmesi.
3. İlgilenilen budak gibi kusur görüntülerinin diğer ilgilenilmeyen alandan ayrıştırılması işlemi.
4. Her bir nesneyi tanımlayan parametre değerlerinin hesaplanması.
5. Her bir nesnenin neyi temsil ettiğinin belirlenmesi ve büyüklüklerine göre kalite sınıfının tanımlanma aşaması.

Belirtilen yöntemlerin uygulanmasında Oulu Üniversitesinden alınmış budak veritabanı ve ahşap veritabanı ile Isparta kereste fabrikalarında farklı ışıklandırma koşullarında elde edilmiş döşemelik tahta görüntüleri ve SDÜ Orman Fakültesi Orman Endüstri Mühendisliği Bölümü Laboratuvarlarına getirilen döşemelik tahta kesitleri kullanılmıştır. Başlangıçta yöntemler sadece budaklardan oluşan görüntülerin 7 farklı tip sınıfına kategorize edilmesinde kullanılmıştır. Sonrasında yöntemler sadece budak tipini belirleme görevini gerçekleştirmek değil aynı zamanda ahşap yüzeylerinde bulunan, kaliteyi olumsuz etkileyen tüm kusurların bulunması için çalışır hale getirilmiştir. Son olarak da uzman görüşlerine göre endüstriyel olarak döşemelik tahta budaklarının sınıflandırılması yapılmıştır.

2. KAYNAK ÖZETLERİ

Srikanteswara (1997), yaptığı çalışmada mevcut kümeleme yaklaşımlarını renkli ağaç görüntüleri üzerinde uygulama yapmıştır. Bu uygulama sonucunda hiç bir görüntünün bölümlenemediğini fark etmiştir. Bu sebeple histogram kullanılarak renkli ağaç görüntülerini kümeleyebilen bir yaklaşım gerçekleştirmeye çalışmıştır.

Ünsalan ve Erçil (1997), tahta yüzeylerin nitelik belirlenmesi problemi ele alınmıştır. Çeşitli doku analizi yöntemleri araştırılarak tahtanın öznitelikleri bulunmuş, elde edilen öznitelikler üzerinde farklı sınıflandırma yöntemleri test edilerek hatalı yüzeyler sınıflandırılmıştır. Bu amaçla görüntüler farklı görüntü işleme ve makine ile görüşü teknikleri ile analiz edilmiş ve öznitelikler bulunmuştur. Bulunan veriler istatistiksel örüntü tanıma ve yapay sinir ağları yöntemleri yardımı ile sınıflandırılarak karşılaştırılmıştır. Ulaşılan çıktılar, tahta yüzeylerin kalite kontrolü otomasyonunda, yapay görüntü işleme tekniklerinin kullanılmasının oldukça gerçekçi olduğu sonucunu ortaya koymuştur.

Bond (1998), yaptığı çalışmada en iyi sınıflandırma sonuçları elde edebilmek için ağaçların en iyi öznitelikleri olarak kabul ettiği renk, şekil ve yoğunluk parametre bilgilerini kullanarak sınıflandırma yapmıştır. Renkli ve x-ray görüntüleri üzerinden en iyi öznitelikleri tanımlamaya çalışmıştır. RGB ve HSI renk uzaylarında renk, şekil ve yoğunluk parametreleri çıkartılarak sınıflandırma sonucuna etkileri ayrı ayrı incelenmiştir. Her bir parametrenin sınıflandırmaya olan etkileri incelenmiştir.

Kauupinen (1999), yaptığı çalışmada ağaç yüzey incelemesi için görsel inceleme tekniklerini geliştirebilmek adına bir çalışma gerçekleştirmiştir. Geliştirme ve performans analiz süreci tartışılmıştır. Renkli öznitelikler üzerinden ağaçların görsel incelemelerinin yapılmasının gri seviye öznitelikler üzerinden ağaç incelemesinden daha iyi olduğunu belirtmişlerdir. Aynı zamanda, bu çalışmada renkli ağaç öznitelikleri kullanılmasına; düşük karmaşıklık, iyi ayırt edici güç ve bazı ııksal deęişimlere direnç kazanılması bakımından tercih edilmiştir.

Bharati (2002), yaptıkları çalışmada görsel inceleme sistemleriyle endüstriyel işlemlerin gerçek zamanlı izlenmesi ve geri besleme kontrollerinin sağlanmasını sağlayan yöntemler geliştirmiştir. Bu geliştirilen yöntemler çelik ürünleri ve orman ürünleri endüstrilerinde kullanılmıştır.

Niskanen (2003), yaptığı çalışmada gerçek zamanlı görsel inceleme yapabilmek için danışmansız izdüşüm yöntemleri kullanılmıştır. Danışmanlı öğrenme ile sınıflar eğitim örneklerinden otomatik olarak öğretilmektedir. Bu yaklaşımdaki ilk problemin eğitim görüntülerini etiketlemenin hatalı, tutarsız ve yorucu olmasından bahsedilmektedir. Bu yaklaşımdaki diğer problemin yeni bir eğitim görüntü koleksiyonunu etiketlemenin gerekmesinde karar sınırlarını değiştirmenin kolay olmamasıdır. Bu sorunları ortadan kaldırabilmek için verileri etiketlemeksizin danışmansız bir yaklaşım gerçekleştirmeye çalışmıştır.

Silven vd. (2003), ahşap kusurları tanımlamak ve tespit etmek için danışmansız kümeleme tabanlı bir yaklaşım öne sürmüşlerdir. Sert ahşap ve kusurları arasında ayırım için özdüzenleyici haritalar (SOM, self-organizing map) yöntemi kullanılmıştır.

Aydın (2004), yaptığı çalışmada ağaç malzeme kusurlarının tespit edilmesi konusunda yapılan çalışmalar hakkında bilgiler verilmiştir. Ahşap kusurlarının taranmasında ve tespit edilmesinde kullanılan çok sayıda yöntem olmasına rağmen, bu yöntemlerden hiçbirisi, tüm ahşap kusurlarının tespit edilmesi için yeterli olmadığını bunun yerine elektronik sensörler ile daha güvenilir ve hassas kusur tarama sistemleri geliştirileceğini belirtmişlerdir. Elektronik sensörler yardımıyla elde edilen şekil, renk ve yoğunluk bilgilerindeki farklılıklar ile ahşap kusurlarının tespit edilmesine yönelik bilgiler ve ahşap malzemelerin gruplandırılması için önemli parametrelerin belirlenebileceği ve böylece kusur tarama yöntemlerinin hassasiyeti ve yeteneği artırılabilirliğinden bahsedilmektedir.

Ünver ve Acar (2005), ülkemizde üretilen odun hammaddesi piyasadaki talebi karşılayamaz durumda olup endüstriyel odun hammaddesi talebinin %9'u ithal

edilmektedir. Bu nedenle odun hammaddesinin üretim safhasında meydana gelen miktar kayıpları yanında kalite kayıpları da büyük önem taşımaktadır. Odun hammaddesi üretimi çalışmalarında hem orman kaynaklarının sürekliliğinin korunması hem de ülke ekonomisine katkının artırılması önemlidir. Odun hammaddesinin kalitesinde meydana gelebilecek kayıpların en aza indirilmesi; üretim operasyonlarında gelişmiş tekniklerin kullanılması, sektör ihtiyacının dikkate alınması, uygun koşullarda depolanması ve eğitimli işçilerle çalışılmasıyla mümkün olacaktır.

Cavalin vd. (2006), gri ölçekli görüntülerden çıkartılmış öznitelikler kullanılarak ahşaplardaki kusurları tespit edebilme problemine yoğunlaşmışlardır. Öznitelik veri seti elde ediminde GLCM tekniği kullanılmıştır. Öznitelik veri seti oluşumunda yüzey düzgünlüğü, irilik ve düzenlilik gibi özellikler ölçülmüştür. Yapılan bu çalışmada, öznitelik veri setinin etkinliği ile yüzdelik histogramlar kullanılarak çıkarılmış öznitelik veri seti etkinliği karşılaştırılmıştır. SVM ve YSA yöntemleri elde edilen öznitelikleri sınıflandırabilmek için kullanılmıştır. Ahşap kusur tespiti için yapılan deneysel çalışmalarda, gri ölçekli görüntülerden elde edilen özniteliklerin renkli görüntülerden elde edilen özniteliklerinden daha başarılı olduğunu tespit etmişlerdir.

Murguia ve Ramirez (2006), üç farklı bulanık kümeleme tabanlı yönteminin ahşap kusurlarının yedi türünün sınıflandırılmasındaki performansları karşılaştırmıştır.

Mu ve Qi (2008), yaptıkları çalışmada X-ray ışınları ile elde edilmiş tahta görüntüleri üzerinde çukurları, budakları ve çürümeleri YSA ile sınıflandırmaya çalışmışlardır.

Yu-Hua Gu vd. (2009), otomatik olarak ahşap kusurlarını sınıflandırma konusuna yoğunlaşmışlardır. Ahşap malzemelerden çekilen görüntüler kullanılarak ahşap budaklarının 4 tipini sınıflandırabilmek için SVM yöntemi kullanılmıştır. Basit ve etkili öznitelikler, budak görüntüleri 3 farklı alana bölünülerek çıkartılmıştır. İstatistiki klasik filtrelemeler kullanılarak her bir

alanın ortalama renk özniteliği elde edilmiştir. SVM sınıflandırıcısı kullanılarak toplamda mevcut 1200 görüntünün 800'ü eğitim amaçlı, 400 tanesi de test amaçlı kullanılmıştır. 400 tane test budak görüntüsünde %96.5 sınıflandırma oranına ve hata oranı olarak da %2.25 değerlerine ulaşmışlardır. İlerideki çalışmalarında budak tiplerini genişleterek daha geniş veri setlerinde çalışmayı hedeflemektedirler.

Zhang ve Ye (2009), ahşap görüntülerinin boyutları yüksek olduğundan dolayı işlem yapmanın zor olduğunda bahsedilmektedir. Bu noktada veri kaybı olmaksızın görüntülerin işlenmesi gerekmektedir. Ahşap görüntüsü tanımlayabilmek için Sp-DNDR diye adlandırılan doğrusal olmayan boyut azaltımı temelli modelleme sistemi tasarlamışlardır.

Xiansheng vd. (2009), yaygın olan hint kamışı şerit kusurlarını tespit edebilmek için çevrim içi kusur inceleme yöntemi öne sürülmüştür. Bu yöntem farklı tip kusurlu görüntüleri işleyebilmek için geliştirilmiştir. Hint kamış türüne ait 6 farklı kusuru hızlı ve doğru bir şekilde bulabilmektedirler.

Marcano vd. (2009), Artificial Metaplasticity (AMP) nöronlar ve Shannonun bilgi teorisinin biyolojik metaplasticity özelliğinden esinlenilmiş yeni bir YSA eğitim yöntemi olduğundan bahsetmektedir. Gabor filtrelerinden elde edilmiş özniteliklerini temel alan AMP yöntemi ile budakların üç farklı budak tipine sınıflandırılmasını içeren bir çalışma gerçekleştirmişlerdir.

Athilakshmi vd. (2010), yüksek doğruluk ve güvenilirlik ile istatistiksel ve dokusal öznitelik çıkarım teknikleri kullanarak ağaç malzemelerinin kalite kontrolüne yoğunlaşmışlardır. Öznitelik çıkarımı, görüntü tanıma sürecinin en önemli adımlarından biridir. İyi tanımlanmış öznitelikler, tanıma sürecini daha etkili ve verimli hale getirmektedir. Ahşap malzemelerinin kalite kontrolü için birkaç teknik mevcuttur. Ancak, görüntü tabanlı ahşap malzemelerinin kalite kontrolü halen zor olan bir problemdir. Küçük kalite kontrol yöntemleri olmasına rağmen, birçok durumda bu yöntemler yararlı sonuçlar vermemektedir. Dokusal sınıflandırma için en popüler teknik olan GLCM

kullanılmıştır. Böylece işlenmiş görüntülerden öznitelikler, GLCM kullanılarak çıkartılmıştır.

Zheng ve Zhang (2010), klasik negatif olmayan matris çarpanlarına ayırma (NMF) için yeni bir yaklaşım sunmuşlardır. NMF sınır kısıtlamaları ile minimizasyon problemi olarak formüle edilmektedir.

Yu ve Kamarthi (2010), iki boyutlu ayırık dalgacık dönüşümünün katsayılarından öznitelikleri çıkarabilmek için yeni bir kümeleme tabanlı yaklaşım öne sürmüşlerdir. Her bir frekans kanalının matrisindeki dalgacık katsayıları danışmansız sınıflandırıcı ile örtüşmeyen kümelerle ayrılmıştır. Öne sürülen yöntem, baskın katsayıların pozisyonunu çevresinde yerleşmiş ayırık kümelerdeki hesaplanmış dalgacık katsayılarını matrislerine bölmektedir.

Shahnorbanun vd. (2010), Spiking öğrenme vektörü, danışmanlı öğrenme vektörü tarafından eğitilmiştir. Eğitim sonunda elde edilen ağda, genel sinirler yerine spiking nöronları işlem elementleri olarak kullanılmıştır. Bir spiking nöronu, biyolojik nöronların basitleştirilmiş modelidir. Bu yayında, ağaç kusurlarını sınıflandırabilmek için gerçekleştirilen spiking nöron ağları üzerinde çalışılmıştır. Değişik tipteki kusurları birbirlerinden ayırmaya uygun olduğundan bahsedilmektedir. Aynı zamanda, Spiking öğrenme vektör niceleme ağlarının sınıflandırma zamanı bakımından daha iyi olduğu anlatılmaktadır.

Shahnorbanun vd., (2010); Yu vd., (2010), farklı kalite ve sınıf belirlemelerin sorunsuz bir şekilde gerçekleştirilebilmesi için İskandinavya, Malezya gibi ağaç zengini ülkelerin ağaç kusurlarının otomatik tespiti, sınıflandırılması ve derecelendirilmesinin geliştirilmesine ve araştırılmasına yoğun bir şekilde çalışıldığını belirtilmektedir

Athilakshmi vd. (2010), bilgisayar teknolojisi, veri işleme teknolojisi ve sinyal işleme teknolojilerindeki son zamanlardaki gelişmeler tahribatsız bir şekilde tanıma problemlerine uygun çözüm fikirleri ve yöntemleri sunabilmemize imkan tanımaktadır. Ağaç örüntülerini temel alan ağaç türlerinin

tanımlanabilmesi için düşük maliyetli araçlar kullanarak ağaç tanıma sistemi tasarlamışlardır. Ağaçların kusurlarının tanınması için bir insanın eğitilmesi ve bu konuda uzmanlaştırılması uzun zaman almaktadır. Otomatik kusur tespit yöntemleri ise, orman ürünleri endüstrisinde verimliliği artırarak kaynaklardan daha iyi yararlanılmasını, işçilik maliyetlerinin azaltılmasını, daha akıllı, doğru ve güvenilir bir şekilde ahşap sınıflandırılmasını sağlamaktadır.

Jabo (2011), ahşap kusurlarının kalite sınıfını belirleyebilmek için bir yöntemleri sürmektedir. Bir danışmanlı sınıflandırıcı olan Adaboost yöntemi, görüntülerin eğitilmesi ve sonrasında leke tipli kusurların renklerinin çıkartılmasında kullanılmıştır. Bununla beraber dinamik programlama, sayısal görüntü, Hough dönüşümü gibi yöntemler ile görüntü nesnelerinden çıkartılan öznitelikler birleştirilmiştir. Jabo tarafından kullanılan Adaboost tabanlı yöntemler sınıflandırma oranını maksimum yapmak, aynı zamanda endüstri uygulamalarındaki en önemli faktör olan hesaplama zamanını minimize edebilmek için seçilmiştir. Deneyler kereste görüntülerinde uygulanmış ve sonuçlarda önerilen yaklaşımların etkinliği gösterilmiştir.

Mohan ve Venkatachalapathy (2012), ahşabın el ile seçilmesi ve sınıflandırma sürecinin, sıkıcı ve zaman alan bir işlem olduğundan bahsetmektedir. Yapılan çalışmada ahşaptaki budakları tespit etmeye ve sınıflandırabilmeye çalışmışlardır. Hilbert dönüşümü ve Gabor filtreleri kullanılarak budak görüntüleri ön işlemlerden geçirilmiştir. Ön işlemlerden elde edilen öznitelikler bagging tekniği ile karşılaştırılmış ve veri madenciliği yöntemleri kullanılarak sınıflandırılmıştır.

Mahram vd. (2012), ahşabı sınıflandırabilmek için ahşap budaklarını ve çatlaklarını tespit etmeye çalışmışlardır. Bunları yapabilmek için iyi tanımlanmış örüntü tanıma ve öznitelik çıkarma yöntemlerini temel alan etkili ve verimli bir sınıflandırma uygulamışlardır. Gri seviye iç içe matris (GLCM), yerel ikili örüntüleri (LBP) ve istatistiksel momentler olmak üzere üç farklı öznitelik çıkarma tekniği kullanmışlardır. Öznitelik boyutunu azaltabilmek için LDA, temel bileşen analizi (PCA) kullanılmıştır. Beş farklı ağaç budak türünü

sınıflandırabilmek için destek vektör makinesi (SVM) ve KNN sınıflandırıcılarını kullanmışlardır.

Johansson vd. (2013), yüksek hızlı endüstriyel bilgisayar tomografisi (BT) ile kerestelerin taranması kereste endüstrisinde yeni bir yaklaşımdır ve bu yaklaşım ile görüntülerdeki budakları bulmaya çalışan uygun bir yöntem olmadığından bahsedilmektedir. BT'li görüntülerin silindirik kabuklarında değişken eşik değerli budakları bölütleyebilmek için kütüklerin BT görüntülerinde budakları tespit etmeye çalışan bir yöntem geliştirmişlerdir.

Krähenbühl vd. (2013), ağaç köklerinin üç boyutlu X-ray BT görüntülerinde budak tespiti problemi ile çalışma yapmışlardır. Bu görüntü tipinin klasik medikal görüntülerden çok farklı olduğunu ve özel geometrik yapılar olduğunu belirtmektedirler. Belirtilen görüntüler üzerinden ağaç kusurlarını analiz ederek, otomatik olarak budakların bulunması üzerine çalışmışlardır.

3. MATERYAL VE YÖNTEM

3.1. Ahşap

Ahşap, heterojen yapıya sahip doğal polimerik bir malzemedir. Literatürde çevresel bazı etkiler ve doğal büyüme davranış tarzları kusur olarak adlandırılır. Bu kusurlar belirli uygulamalar için arzu edilmeyen odun özelliklerinin ortaya çıkmasına sebep olur. Kusurlar ahşabın görsel ve yapısal özelliklerini etkilemektedir. Bu kusurlar; ağacın büyüme koşullarına, çevresel koşullara, taşıma ve ahşaba uygulanan işlemlere bağlı olarak değişiklik göstermektedir. Bu kusurların tanımı ve hangi sınırlar dâhilinde kabul edilebileceği, sanayi kuruluşları arasında farklılıklar göstermektedir. Tomruk, kereste, parke, tahta vb. ağaç malzemeler, genellikle bir sınıflandırmaya tabi tutulduktan sonra ait olduğu kalite sınıfına göre satışa sunulmaktadır. Gerek kereste, gerekse tomruklarda bulunan kusurların tespit edilebilmesi, hem üretim hem de zaman açısından önemlidir (Aydın, 2004).

Ağacın doğal yapısı gereği kusurlar meydana gelebilmektedir. Bu kusurlardan bir tanesi de budaklardır. Budak, kereste hammaddesi içerisinde gömülü halde bulunan dal kısmıdır. Budaklar kerestelerin kalitesini kötü yönde etkilemektedir. Kerestenin bir parçasının değeri, kerestenin kalitesi ile doğrudan ilişkilidir. Kalite, budak sayısı ve onların dağılımları dikkate alınarak belirlenmektedir (Marcano vd., 2009). Budaklar, kereste inceleme sırasında bulunan en genel kusurlardır (Lampinen ve Smolander, 2009; Chacon ve Graciela, 2006). Bundan dolayı budaklar kereste sınıflandırmasında önemli bir rol oynamaktadır. Budaklar, şekil ve görünüm bakımından büyük farklılıklara sahiptir. Örneğin; kuru budaklar, sınırlar çevresinde dar karanlık halkalara sahiptir. Kaynamış budaklar birkaç farklı bölge içermektedir. Boynuz budağı, tahtaların kenarlarına yerleşmiş bir yaprak budağıdır (Lampinen vd., 1995). İnsan, budağı; şekli, boyutu, yapısı ve rengini temel alarak tanımlamaktadır.

Kullanılan yüzeyin düzgünlüğü ve tek cins olması verimliliği artırır. Ahşap üzerindeki kusurlar değerini ekonomik olarak olumsuz yönde etkiler. Bu kusur, ahşabın mukavemetini azaltan bir durum oluşturabileceği gibi kullanım

alanlarını da sınırlar. Bazı durumlarda uygun olmayan bir numune farklı durumlar için ideal olabilir. Bu durumlarda ahşabı yanlış sınıflandırmak endüstriyel olarak belirli bir düzeyde risk taşır (Ünsalan, 1997).

3.2. Ahşap Döşeme Çeşitleri

3.2.1. Klasik ahşap döşemeler

Doğrudan kirişler üzerine tahtaların yan yana çakılması ile yapılan bir uygulamadır. Tahtalar düz en birleştirme şeklinde yapılabileceği gibi kendinden kınışlı birleştirme şeklinde de yapılabilir. Klasik döşemelerde döşeme tahtaları oldukça geniştir ve genişlik ölçüleri arasında standart olmayabilir. Kendinden kınışlı olarak yapılan döşemelerde ise döşeme tahtaları eşit genişlikte standart olarak makinelerde hazırlanır.

Geniş tahtalarla düz en birleştirme şeklinde yapılan döşemelerde çiviler yüzeyden görünür. Kınışlı tahtalarla yapılan döşemelerde kullanılan çiviler kınış içerisinden çakıldığı için görünmez.

Üretileceği ağacın türüne göre; rabitalı sedir döşemesi, rabitalı çam döşemesi sedir tavan döşemesi, çam tavan döşemesi gibi çeşitli ürün grupları vardır. İstek olması durumunda çokta uygun olmayan köknar ağacından ayrıca kavak ağacı gibi ekonomik ağaçlardan rabitalı döşeme üretimi yapılabilmektedir. Rabitalı döşeme adı, lambri isimli ahşap parke üretiminde kullanılan rabita makinesinden gelir. İşlenen ağaç cinsine göre adlandırılır (Kanburoğlu, 2009).

Talep eden müşteri ve üretici firmanın isteği doğrultusunda her tür ağaç cinsine uygun rabitalı döşeme üretilir. İşlenen ağacın ismi ile adlandırılır. En çok işlenip pazarlanan rabitalı çam ve rabitalı sedir döşemesidir. Taban, duvar, tavan ürün çeşitleri üretilmektedir (Kanburoğlu, 2009).

3.2.2. Döşemelik lambri imalatı


Binalardaki ana oluşumlardan olan duvarlar, tavanlar ve tabanların ahşap, metal, plastik veya kumaş gibi malzemeler ile kaplanmasına lambri denilmektedir (Anonim, 2007).



Şekil 3.1 Profil ve rabita makinesinde lambri yapılması (Anonim, 2007)

3.2.3. Düz lambri imalatı

Düz ahşap lambri, profil veya weinig makinelerinde üretilir (Şekil 3.1). Üretimde değerlendirilecek tomrukların az kusurlu tercih edilir. Sağlam budaklı tomrukları da kullanılabilir. Dayanaksız tomruklardan yapılan lambrilerin verimli olmadığı belirtilmektedir. Lambri imalatında değerlendirilen en uygun tomruk çapları 25-35 cm arasında dağılım gösterir.



Şekil 3.2 Bir weinig makinesinde bıçakların konumu (Anonim, 2007)

Geniş yıllık halkalı tomruklar lambri imalatında kullanıldığında üretilen lambrilerde rutubet farklılıkları oluşur. Bu durumda lambrilerin boyutlarında genişleme veya daralma oluşabilmektedir. Döşemelik malzeme imalatında kullanılan tomruklar düzgün ve dolgun gövdeli olmalıdır ancak bu tomruklar lif kıvrıklığı içermemelidir. Lambri üretiminde çam gibi ibreli ağaç türlerinden

olmak üzere 5, 8, 10 ve 12cm genişliklerde kuru ağaç malzemeler kullanılmalıdır.

3.2.4. Fugalı lambri imalatı

Fuga, derz demektir. Diğer bir ifadeyle derz yada fuga lambrilerde eklem yerlerine ve yüzeylerine açılan yassı kanallardır. Bu kanallar weing makinelerinde lambrilerin eklem yerlerine yada orta kısımlarına dekoratif görüntü kazandırmak amacıyla açılır. Fugalı lambrilerin azami eni 12cm geçmemelidir (Şekil 3.3, Şekil 3.4).




Şekil 3.3 Çam keresteden yapılmış fugalı lambri örnekleri (Anonim, 2007)



Şekil 3.4 Fuga açılmış lambri örnekleri (Anonim, 2007)

3.2.5. Lambalı lambri imalatı

Lambalı lambri üretiminde kullanılan döşemelik malzemeler öncelikle yan yana getirilir. Bunların arka yüzlerine lamba ön yüzlerine de kordon açılır. Böylelikle lambrilerin ek yerlerinde açılan derin profiller dekoratif amaçlı farklı görüntüler oluşturur. Dekoratif görüntü oluşturulmasında freze ve daire testere makinelerinden yararlanılır. (Şekil 3.5, Şekil 3.6, Anonim, 2007)



Şekil 3.5 Lambrilerde weing makineleri ile lamba açılması (Anonim, 2007)



Şekil 3.6 Lambalı lambrilerin daire testere makinesinde yapılışı (Anonim, 2007)

3.2.6. Kafes döşeme imalatı

Eski ahşap bina zeminlerinde uygulanan bir yer döşeme yöntemidir. İlk aşamada zemine 10x10 cm ölçülerinde kalaslar belirli (50–60 cm) aralıklarla yerleştirilir. İkinci aşamada bu kalaslar üzerine 5x5 cm veya 5x10 cm ölçülerinde kayıtlar yerleştirilerek sabitlenir. Daha sonra bu kayıtlar üzerine döşeme tahtaları çakılır. Kayıt araları Şekil 3.7’de olduğu gibi samanlı cüruf ile yalıtım amaçlı doldurulabilir. Benzer uygulama ahşap iskeletli evlerde kat aralarında ana taşıyıcı kirişler üzerine ters yönde 5x10 cm kesit ölçülerindeki kayıtlar kullanılarak da yapılabilir.



Şekil 3.7 Kafes döşemede ızgaraların yerleştirilmesi (Anonim, 2007)

3.2.7. Parke döşemeler

Zemine uygulanan kör döşeme üzerine veya doğrudan şap zemin üzerine küçük boyuttaki ahşap parçalar ile yapılan döşeme şeklidir. Konutlarda uygulanabildiği gibi spor salonlarının döşenmelerinde de uygulanan bir yöntemdir. Döşeme parçaları zeminde farklı desenler oluşturacak şekilde düzenlenebilir. Bütün döşeme yöntemlerinde düzgünlüğe dikkat edilmelidir. Ancak özellikle parke döşemelerde kör döşeme yüzeyi ya da şap, çok düzgün olmalıdır. En çok kullanılan parke döşemesi Rabıtalı ahşap döşemelerdir.



Şekil 3.8 Parke döşeme teknikleri (Anonim, 2007)

3.2.7.1. Rabıtalı ahşap parke imalatında önemli hususlar

1. Rabıtalı ahşap parke ürünü imalatında kullanılan tomruk cinsi ve parke üretimi yapılan tomruk kısmı, sınıflandırmada etkin rol oynadığı söylenmektedir.
2. Rabıtalı ahşap parke döşemesini sınıflandırırken budak adeti ve budak büyüklükleri en önemli etkiye sahip olduğu belirtilmektedir.
3. Tomruğun kabuk olmayan kısmından üretilen rabıtalı ahşap parke, tomruğun dış kabuk kısmından üretilen rabıtalı ahşap parkeden daha değerli olmaktadır.
4. Tomruktaki farklı renklerdeki lekeler rabıtalı ahşap parke kalitesini ve sınıfını olumsuz yönde etkilemektedir.
5. Rabıtalı ahşap parke ürününün imalatında budakların düşmesi veya zayıflaması ahşap parke sınıflandırılmasında çok büyük önem taşımaktadır.

3.2.7.2. Rabıtalı ahşap parke sınıfları

Süper Rabıtalı Ahşap Parke

Süper rabıtalı ahşap parkeler yüzeylerinde budak kusurları veya herhangi bir leke bulunmamaktadır. Tomruğun en değerli kısmından üretilerek tasnifi yapılmaktadır.

1. Sınıf Rabıtalı Ahşap Parke

Birinci sınıf rabıtalı ahşap parkelerde budak genişliği küçük ve budak adeti az olduğu belirtilmektedir. Yeşil ve siyah renklerine sahip herhangi bir leke 1. Sınıf ahşap parkelerde bulunmamakta olduğu bildirilmektedir.

2. Sınıf Rabıtalı Ahşap Parke

İkinci sınıf ahşap parkelerde budak genişliği büyük ve aynı zamanda budak adeti birinci sınıfa göre daha çok olduğu bildirilmektedir. Bu parkelerde yeşil ve siyah renklerine sahip leke az miktarda bulunmakta olduğu bildirilmektedir.

3. Sınıf Rabıtalı Ahşap Parke

Üçüncü sınıf rabıtalı ahşap parkelerde budak genişliğı oldukça büyük ve adeti oldukça fazla olduğı bildirilmektedir. Bu tip parkelerde yeşil ve siyah renklerine sahip leke olabilmektedir.


Rabıtalı ahşap parke pazarlamasında, en çok satılan ürünler rabıtalı çam döşeme ile sedir döşeme çeşitli olduğı bahsedilmektedir. Rabıtalı çam döşeme ürünleri, sedir döşeme ürünlerine göre maliyetinin düşük olması nedeniyle daha çok tercih edilmektedir. Rabıtalı sedir döşeme ise rabıtalı çam döşemeden daha kaliteli, sağlam, dayanıklı ve değerli olduğı belirtilmektedir. Rabıtalı çam parkenin dezavantajları arasında ise yumuşak olması, güve yeme riskinin fazla olması ve daha kolay eskimesi gibi sebeplerden dolayı rabıtalı sedir ağacı döşemesine göre en büyük olumsuzlukları arasında bulunmaktadır. Aynı zamanda bunlara ek olarak rabıtalı sedir ağacı cilayı daha güzel göstermesi sebebiyle rabıtalı çam parkeye göre daha çok müşteri tarafından tercih edilebilmektedir. Ancak, rabıtalı çam döşemesi suya ve neme rabıtalı sedir döşemesinden daha az dayanıklı olduğı da bildirilmektedir (Kanburoğlu, 2009).



Şekil 3.9 Rabıtalı tavan taban döşemesi (Kanburoğlu, 2009)

3.3 Kızılçam (*Pinus brutia* Ten. henry)

Kızılçam, 5.8 milyon hektarı aşan yayılışı ile, ülkemiz koru ormanlarında en geniş alanı kaplayan bir ağaç türüdür (Anonim, 2012). Pinaceae familyasının pinus cinsine aittir. Artım ve büyüme özellikleri, yayılış alanı, oluşturduğu ekonomik değer bakımından ülkemizin en önemli orman alanıdır. Bu değer, ülkemizde yayılış alanı bakımından ilk sırada, hacim olarak da Anadolu karaçamından sonra ikinci sırada yer alması, kızılçam odununun çeşitli kullanım yerlerine sahip olmasını da sağlamıştır. Bu yüzden kızılçam ağaç türünün çok yönlü ele alınıp tanımlanması gerekmektedir (Çatal, 2009).



Şekil 3.10 Kızılçam orman alanı

Ülkemizde kızılçam en yoğun yayılışını Akdeniz bölgesinde yapmaktadır. Kızılçam yayılışını deniz seviyesinden başlayarak 1300 m yükseltiye kadar, bazı yörelerde deniz seviyesinden 1500 m'ye kadar yapmaktadır (Yaltırık ve Boydak, 1993). Burdur Gölhisar yöresinde güney bakıda 1595 m'ye kadar çıkarak saf meşcere kurmakta, aynı yükseltilerde kuzey bakılarda yerini Anadolu karaçamına bırakmaktadır (Kılıç ve Güner, 2000). Marmara, Ege, İç Anadolu, Güneydoğu Anadolu gibi diğer bölgelerde Akdeniz iklimine yakın özellikler gösteren yörelerde de doğal yayılış yapmaktadır (Saatçioğlu, 1976; Yaltırık ve Boydak, 1993).

3.4. Orman Ürünleri Standartları

Üretilen malın değerinde satılmasını sağlayacak ve anlaşmazlıkları önleyebilecek niteliklerdir (Günay, 1982). Standartlar üretim ve tüketimin temel unsurudur. Üretimde kayıp ve artık azaltılmak suretiyle yüksek verim elde edilmesi ve maliyet fiyatlarının düşürülmesi, taşıma maliyetlerinin azaltılması, stoklamanın kolaylaştırılıp ucuzlatılması için gereklidir. Tüketim ve değerlendirmede; kalite, güvenirlik, mukayese edilme, fiyat düşüklüğü, taşınabilme, sipariş kolaylıkları gibi çeşitli faydalar sağlamaktadır.

Alıcı ve satıcı arasında ortak bir anlam yaratan ve gerektiğinde malların görülmeden satışını sağlayan, bugünkü ticari kuralların kaçınılmaz bir unsuru haline gelmiş bulunan standartlar, tam olarak uygulanmak suretiyle işletmeleri piyasadaki saygınlığının zedelenmesine ve satışlarda anlaşmazlık çıkmasına meydan verilmemiş olacaktır (Günay, 1982).

Orman ürünleri standardizasyonu kurallarının, bu kuralları uygulayacak elemanlar tarafından aynı ölçüde anlaşılması da önemlidir. Bu bakımdan ilgili personelin standart konularında çok iyi eğitilmiş ve yetiştirilmiş olması gerekmektedir (Günay, 1982).

Bazı Standart Terimler

Günay, 1982'e göre kereste endüstrisinde en çok kullanılan standart terimlerden bazıları aşağıda verilmiştir.

Yuvarlak Odun: Uzun eksenli boyunca her noktasında en kesiti yaklaşık olarak daire biçiminde olan odundur.

İğne yapraklı yuvarlak odun: Yaprakları yaklaşık olarak iğne biçiminde olan, yapısında trahe bulunmayan ağaçlardan elde edilen odundur. Bunlara yumuşak yuvarlak odunda denir.

Yapraklı yuvarlak odun: Yaprakları yassı biçimde olan, yapısında trahe

bulunan ağaçlardan elde edilen yuvarlak odundur. Bunlara sert yuvarlak odun da denir.

Tomruk: Tomruklar kabukları temizlenmiş, orta çapı en az 19 cm olan ve uzunluğu en az 1.50 m olan yuvarlak odunlardan oluşan gruptur.

Kerestelik tomruk: Kereste üretimine uygun özelliklerde olan tomruktur .

Budak: Oduna gömülü olan dal kısmıdır.

Başlıca budaklar üç kategoride incelenir.

1. Odunla kapatılmış olmasına göre;

Açık budak: Açık budak diye belirtilen grup, yuvarlak odunun dış yüzeyinde görünen budak türüne verilen isimdir.

Kapalı budak: kapalı budak türü ise tomrukların dış yüzeyinin karakteristiklerinden anlaşılabilen ve görünmeyen budak türü olduğu belirtilmektedir.

2. Budak odunun çürüme durumuna göre;

Sağlam budak: Odunu çürük olmayan ve/veya mantar etkisine rağmen sertliğini kaybetmemiş budaktır.

Özürlü budak: Odunu çürüme nedeniyle çevresindeki odundan daha yumuşak olan ve çürüklük alanı budak en kesit alanının yaklaşık olarak 1/3 ünden çok olmayan budaktır.

Çürük budak: Odunu, çürük nedeniyle çevresindeki odundan daha yumuşak olan ve çürüklük alanı budak en kesiti alanının yaklaşık olarak 1/3 ünden çok olan budaktır.

3. Büyüklüklerine göre;

Nokta Budak: Çapı en fazla 1cm olan budaktır.

Küçük budak: Çapı 1 cm den büyük ve en fazla 2 cm olan budaktır.

Orta budak: Çapı 2cm den büyük ve en çok 4 cm olan budaktır.

İri budak: Çapı 4 cm den daha büyük olan budaktır.

3.4.1. TS 11970/Mart 1996 Standardı

Bu standart olarak Türk Standartları Enstitüsü tarafından 1996'da ahşap döşeme tahtasının endüstriyel imalat standartlarını belirlemek için yayınlanmıştır. Bu belirlenen ahşap döşeme tahtası, alt ve üst yüzü birbirine paralel olarak düzeltilmiş, kenar yüzlerine ve uçlarına ekleme profili açılmış veya açılmamış prizma şeklindeki bir döşeme elemanıdır.

Döşeme tahtası üst yüzü, döşeme tahtasının üste gelen en düzgün yüzeyidir. Döşeme tahtası alt yüzü, döşeme tahtasının ızgara çitasına gelen, döşendiğinde zemin tarafında kalan yüzeyidir. Döşeme tahtası ekleme profili, döşeme tahtasının bir yan ve bir baş yüzeyinde diğer bir döşeme tahtasının ekleme profiline (dişi kunişe) girecek şekilde açılmış döşeme tahtası boyunca devam eden çıkıntılı kısımdır.

Ahşap döşeme tahtası sınıflandırma işleminde tahta görünüşlerine göre I. Sınıf, II. Sınıf, III. Sınıf, IV. Sınıf olmak üzere dört sınıfa ayrılır. Bu çalışmada ahşap döşeme tahtalarını sınıflandırmak için TS 11970 standardının sağlam budak ve düşen budak özellikleri karşılaştırılmış, sağlam budak özelliklerinin uygulanabilirliğinin yüksek olmasından dolayı sağlam budak özellikleri dikkate alınmıştır.

Döşemelik ahşapların görünüş özelliklerine göre; Sağlam Budak özellikleri, Çizelge 3.1'de; Düşen budak özellikleri, Çizelge 3.2'de verilmiştir.


Çizelge 3.1 Sağlam Budak (TS 11970, 1996)

I.Sınıf	II.Sınıf	III.Sınıf	IV.Sınıf
Üst yüzeyde çapı 2 mm'ye kadar bulunabilir. 1m de 2 adet olabilir.	Üst yüzeyde çapı 8 mm'ye kadar bulunabilir. 1m de 2 adet olabilir.	Üst yüzeyde çapı 15 mm'ye kadar bulunabilir. 1m de 2 adet olabilir.	Üst yüzeyde çapı 20 mm'ye kadar bulunabilir. 1m de 2 adet olabilir.

Çizelge 3.2 Düşen Budak (TS 11970, 1996)

I.Sınıf	II.Sınıf	III.Sınıf	IV.Sınıf
Üst yüzde çapı 1 mm'ye, alt yüzde 5 mm kadar 1 metrede 2 adet bulunabilir. Yanlarda ve başlarda bulunmaz.	Üst yüzde çapı 1 mm'ye, alt yüzeyde 10 mm kadar 1 metrede 2 adet bulunabilir. Yanlarda ve başlarda bulunmaz.	Üst yüzde çapı 7 mm'ye, alt yüzeyde 15 mm kadar toplu olmadan 1 metrede 2 adet bulunabilir. Yanlarda kalınlığın yarısı çapında bulunabilir.	Üst yüzde çapı 10 mm'ye, alt yüzeyde 20 mm kadar toplu olmadan 1 metrede 2 adet bulunabilir.

Genişlikleri 20 mm den 150 mm kadar değişik boyutlarda döşemelik tahtalar üretilmektedir. Piyasada 60 mm-100 mm arasındaki döşemelik tahtalar daha çok mevcuttur. Döşemelik tahta ölçme işleminde ölçü birimi mm kullanılmıştır (1 cm= 10 mm).



Şekil 3.11 TS 11970 (1996) Budak Büyüklükleri

TS 11970'e göre 90 mm genişliğindeki bir tahtadaki yaklaşık budak büyüklükleri Şekil 3.11'de gösterilmiştir. Her bir şekil en büyük budak büyüklüğünü temsil etmektedir. Bu kategorilere girmeyen budaklar başka amaçlar için kullanılmaktadır. Sanayi kuruluşlarında bu standart isimleri Süper, I. Sınıf, II. Sınıf ve III. Sınıf olarak adlandırılmaktadır.

3.4.2. TS 11970 EN13990/Mart 2006 Standardı

TS 11970 EN 13990 Mart 2006 yılında TS 11970 yerine kabul edilmiştir. Ahşap yer döşemesi – Masif yumuşak ağaç yer döşeme levhaları için geliştirilen bir standarttır. Bu standart; iç mekânlarda yer döşemeleri olarak kullanılan masif yumuşak ağaçtan yapılmış lamba ve zıvanalı döşeme levhalarının sahip olması


gerekli özelliklerini kapsar. Bu standart, yer döşeme levhalarının boyutları, sınıflandırılması ve dağılımı ile ilgili özellikleri kapsar. Bu standartta belirtilen mamuller, imalat öncesi kaplanmış veya emprenye edilmiş tabii yumuşak ağaçtan üretilir. Bu standart kaplama hakkında bilgiler vermez.

Bu standarda göre başka şekilde belirtilmedikçe, sınıflandırma yüz kaplamasından önce yapılmalıdır. Bu standart döşemelik tahtaları Sınıf A ve Sınıf B olarak iki kategoriye ayırmaktadır.

Sınıf A: Siyah nokta budaklara, grup halinde değil ise 5'mm ye kadar ve sağlam kaynamış budaklara, 35mm+Tahta Genişliği*10/100 kadar müsaade edilir.

Sınıf B: Siyah nokta budaklara, 5'mm ye kadar, sağlam kaynamış budaklara, 50mm+Tahta Genişliği*10/100 kadar ve zaman zaman oynamış budaklar, çürük budaklar ve budak delikleri, 15mm ye kadar müsaade edilir (TS EN 13990, 2006).

TS EN 13990 standardındaki izin verilen budak büyüklüğü Şekil 3.12'de görsel olarak gösterilmiştir. Şekilden de görüldüğü gibi budak büyüklüğünün sınıflandırmaya etkisi yok denecek kadar azdır.



Şekil 3.12 TS EN 13990 (2006) Budak Büyüklükleri

3.5. Örüntü Tanıma

Endüstriye, sayısal aygıtların daha çok girmesiyle birlikte, görüntüde var olan nesneler hakkında bilgi edinme ve bu edinilen bilgilerden anlamlar çıkarma konusu popülerliğini gittikçe artıran bir bilim dalı haline gelmiştir. Yapılan uygulamalarda sürekli insanın algılama sistemi taklit edilmiştir, ancak hiçbir zaman tam anlamıyla insanın görme yeteneği bir makineye verilememiştir (Avcı, 2006). Akıllı aygıtlara görme yeteneği kazandırabilmek için bilim adamları düzenli bir biçimde birbirini takip ederek gelişen örüntü adını verdikleri yapıları tanımaya çalışmışlardır. Görüntüde birbirini takip eder biçimdeki nesneler; kereste kusurları, sıcaklık verisi, ses sinyali, uzaktan algılama verisi, bir görüntü içerisindeki karakterler, biyomedikal cihazlardan elde edilen görüntüler, parmak izleri gibi içerisinde bilgi içeren yapılar olabilir. Bu yapılardan anlamlı sonuçlar çıkarma işlemine örüntü tanıma denilmektedir (Çetiner, 2012).


3.5.1. Örüntü tanıma süreci

Endüstriyel ortamda ürün üretimini artırabilmek için örüntülerin yüksek oranlarda doğru ve hızlı sınıflandırılması gerekmektedir. Yüksek oranlarda doğru ve hızlı bir sınıflandırma oluşturabilmek için nesneler hakkında hızlı karar vermek gerekmektedir. Karar, insanın düşünme yeteneği incelendiğinde dış dünyadan alınan görüntüleri işleyip sembollerle tanımlayan ve bu semboller ile bilgi birikimini(veri seti) kullanarak nesneleri gördüğü zaman onlar üzerinde bir fikir oluşturmastır.


Bilgisayarlara insanın görme yeteneği kazandırılabilmesi için yöntemler geliştirilmiştir. Örneğin; bir kereste görüntüsündeki kusurlar örüntü kümesini ve bu kümedeki örüntülerin farklı kusurları temsil ettiği düşünülürse; bilgisayarların örüntüleri algılayabilmesi için bu kümedeki her bir örüntünün, bilgisayarın işleyebileceği bir vektörel form ile temsil edilmesi gerekmektedir. Bu vektörler, farklı bir dönüşüm yöntemi kullanılarak oluşturulmaktadır. Örüntüler, dönüşüm yapıldıktan sonra bilgisayarın işleyebileceği forma gelmektedir. Dönüşüm işlemi, kategorileri birbirinden ayıran ve kendi

kategorisini en iyi temsil eden özniteliklerin bulunması olarak düşünülebilir (Ölmez ve Dokur, 2009).

En iyi temsil eden öznitelikler en iyi sınıflandırma sonucunu verebilir. Sınıflandırma için görüntülerde öncelikle kategori sayısının belirlenmesi gerekmektedir. Bu sayı, makinenin örüntüleri kaç gruba ayıracağını göstermektedir. Kamera ile alınan görüntülerdeki budakların kategori sayısı {0 1 2 3 4 5 6} olarak belirlenmiştir. Bu kategorilere giren budak görüntüleri Şekil 3.13’de verilmiştir. Giriş olarak verilen bu görüntülere Şekil 3.14’deki işlem basamakları uygulanarak 7 tane farklı ürün sınıfına kategorize edilmesi sağlanmış olacaktır.

Yaprak Budak(0)	Kaynamış Budak(1)	Kuru Budak(2)	Kenar Budak(3)	Kanal (Boynuz) Budak(4)	Sağlam Budak(5)	Çürük Budak(6)
						

Şekil 3.13 Kullanılan Budak Kusurları



Şekil 3.14 Örüntü Tanıma Süreci

Örüntü tanıma süreci beş adım şeklinde düşünülebilir: görüntü elde edimi, görüntü iyileştirme, görüntü bölümleme ve örüntünün tespiti, öznitelik çıkarma ve örüntünün sınıflandırılması işlemidir.

3.6. Öznitelik Çıkarma

Ahşap kusurlarının makine görü tabanlı sınıflandırmasında ana problem öznitelik seçimidir. Kusurun pozisyonu, uygunluğu, çapı, uzatmaları, kusurun minimum kare parçasının boyutu, ortalama gri seviye gibi geometrik öznitelikler sınıflandırma için kullanılmıştır (Alapuranen ve Westman, 1992). Ancak, kusurun dış hatlarının şeklini temel alan bilgi bütün budak sınıflarını ayırmak için yeterli değildir, çünkü budaktaki kenar, budağın iç alanı ile ikisinin yapıları ve budağın sağlam olması önemlidir (Kim ve Koivo, 1990).

Literatürde açıkça belirtildiği gibi kusurun ayırt edilmesinde ahşap nesnelerinin belirtilen çizelgedeki değerleri çıkartılmıştır. Bu belirtilen çizelge üzerinde en fazla üzerinde durulan budak kusur tipinin diğer nesnelerden ayırt edilebilmesi için kullanılmıştır.

Çizelge 3.3 Ahşap nesnelerin özellik değerleri

Anlamı	1.budak	2.budak	3.budak
Alan	2113	2683	116
İncelik oranı	0,292	0,402	0,743
En boy oranı	0,559	0,667	1,13
Büyük eksen uzunluğu	44,759	44,759	44,759
Küçük eksen uzunluğu	21,184	21,184	21,184
Reel sayı (E)	1	1	1
Alan/Konveks Alan	0,972	0,972	0,972
Çap değeri	30,529	30,529	30,529
Dış Merkezlilik	0,881	0,881	0,881
Bölgedeki uç noktaların koordinatları	762	762	762
Uç noktaların ilk sütunun toplamı	3580	3580	3580
Uç noktaların ikinci sütunun toplamı	109,841	109,841	109,841
Çap	119,195	122,841	92,419
Ortalama	52,598	58,121	52,129
Standard sapma	2113	2683	116


Alan: Eş. (3.1)'de O_i nesnesinin i' inci alan değerini göstermektedir.

$$A_i = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} O_i(x, y) \quad (3.1)$$

Euler sayısı (E) veya e sayısı; olarak belirtilen farklı disiplinlerde önemli yeri bulunan ve tezde ayırt edici bilgi olarak kullanmaya çalıştığımız sabit bir reel sayı olarak değerlendirilmiştir. Bir nesnenin veya bir görüntünün e sayısı Eş. (3.2)'deki gibi tanımlanmaktadır.

$$E = C - H \quad (3.2)$$

Eş. (3.2)'de E değeri, C bağlantılı bileşen sayısından H değeri olan deliklerin sayısının çıkartılması ile elde edilmektedir.




Şekil 3.15 İki bölgenin Euler sayıları sırasıyla 0 ve -1(Marques, 2011)

İncelik oranı ikili bir görüntünün yuvarlaklık ölçümü olarak kullanılmaktadır Eş. (3.3)'de bu değerin hesabı gösterilmiştir.

$$T_i = \frac{4\pi A_i}{P_i^2} \quad (3.3)$$


T_i değeri maksimum değeri olan 1 değerini alabilirse şeklin çember olduğunu göstermektedir. $\frac{1}{T_i}$ değeri yoğunluk değerini göstermektedir.

Eş. (3.3)'de belirtilen eşitlikte A_i değeri alanı, P_i değeri ise çevre uzunluğunu göstermektedir.



Şekil 3.16 Yoğunluğun örnekleri a) Yoğun olan bölge örneği, b) Yoğun olmayan bölge örneği (Marques, 2011)

Şekil 3.17’da bir nesnenin dış merkezliliği bir nesnenin büyük ve küçük eksenlerinin oranı olarak tanımlanmaktadır.



Şekil 3.17 Bölgenin dış merkezlilik değeri A/B örneği (Marques, 2011)

En boy oranı: bir nesnenin sınırları belli alan içerisindeki boyutları arasındaki orandır (Marques, 2011).

$$\text{En boy oranı} = \frac{x_{\max} - x_{\min} + 1}{y_{\max} - y_{\min} + 1} \quad (3.4)$$

Aynı zamanda literatürde, kusurların renklerinin iyi ayırt edici öznelilikler içerebileceği belirtilmektedir (Lampinen vd., 1994). Bu renklerdeki değişimi

görebilmek için görüntü gri seviye formatına dönüştürülür ve renk histogramları çıkarılır. Renk histogramları, budak sınıflarının yapısı ve şekli ile yakından ilişkili olduğu görülebilir. Böylece histogramların yüzdeleri budak sınıflarının uygun bir şekilde ayrılmasını sağlamaktadır (Silven ve Kauppinen, 1994). Ancak budak sınıflarının tanımları çoğunlukla budakların ve onların parçalarının yapısını ve şeklini temel almaktadır. Bu yüzden sade renk öznitelikleri budak sınıflarının ana bilgisini içermemektedir. Öznitelik çıkartıcıları etiketlenilmemiş görüntü örneklerinin bilgisel içeriğine göre öznitelik oluşumunu gerçekleştirmektedir. Birleştirilmiş öznitelikler öznitelik birleştiricileri ile anlamsal ilişkiye sahip sinir ağları sınıflandırıcıları ile desteklenmektedir. Aynı zamanda sistem seçilmiş öznitelikler tarafından her bir uygulama için sınıf ayrılmasını iyi ayarlayan yeni öznitelikleri kolayca ekleyebilmektedir (Lampinen vd., 1995).

Daha doğru sınıflandırma sonuçları elde edebilmek için renk, şekil, yoğunluk, ortalama, standart sapma, alan, çap gibi 15 tane parametre ile temsil edilebilen ağaç öznitelik bilgilerinin otomatik kusur tespit yönteminde etkin bir şekilde kullanılması gerekmektedir. Bu parametreler farklı veritabanları üzerinde veri kaybı oluşturmaksızın eşikleme yapan iteratif yöntemle eşikleme yapıldıktan sonra, morfolojik yöntemler kullanılarak elde edilmiştir. Elde edilen bu parametreler iki boyutlu ayrık dalgacık dönüşüm yöntemleri, değişmez momentler, gri seviye eş oluşum matrisleri ve bu yöntemlerin melez bir şekilde kullanılması ile ilişkili öznitelik tiplerinin ahşap öznitelikleri arasındaki ayırt edicilik için her bir özneliğin katkısı ve önemi belirlenmiştir. TS 11970 standardına göre alan değerleri bazında yapısal olarak sınıflar oluştuktan sonra budak tipleri belirlenmiştir. TS EN 13990 standardına göre çap büyüklük değerine bakılarak yapısal olarak sınıflar oluştuktan sonra budak tipleri belirlenmiştir.

Görüntüde yer alan farklı her bir bilgi, öznitelik olarak tanımlanabilmektedir. Bu farklı her bir bilgi, görüntü piksellerine yansıyan karakteristik özniteliklerdir. Piksel gri tonlarındaki değişimler, arka zemin niteliği, budak tipleri ve bölgesel yoğunluk farklılıkları bunlara örnek olarak verilebilir. Öznitelik bilgisi çıkarımı

sırasında, budak yapısında yer alan yatay, dikey, köşegenel öznitelikleri ile elde edilen veriler kullanılabilir. Öznitelik çıkarma işlemlerinde moment değişmezleri yöntemi (IM), gri seviye eş oluşum matrisi (GLCM), dalgacık moment (DM), IM+GLCM ve DM+GLCM yöntemleri kullanılmıştır.

3.6.1. IM öznitelik çıkarma yöntemi

Örüntü analizi alanında en temel konu, boyut, konum, şekil, yapı, tip, ahşap eğriliği ve yönelimine bakılmaksızın kusurların ve nesnelerin tanınmasıdır. Hu (1962) tarafından matematiksel moment teorisi kullanılarak değişmez yedi momentli öznitelik çıkarım yöntemi geliştirilmiştir. Tezde, bu yöntem kullanılarak döşemelik tahta budak kusurlarının tanınması için örüntülerin sayısal öznitelikleri elde edilmiştir. Aynı zamanda, $M \times M$ boyutundaki görüntünün iki boyutlu momentleri gri fonksiyona sahip olduğu belirtilmektedir (Mercimek vd., 2005).

$f(x, y)$, $(x, y = 0, \dots, M - 1)$ gri fonksiyonu;

$$m_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{M-1} (x)^p (y)^q f(x, y) \quad (3.5)$$

$p, q = 0, 1, 2, 3 \dots$

$f(x, y)$ momentleri (a, b) toplamına dönüştürülmüştür, Eş. 3.6'deki gibi tanımlanmıştır.

$$\mu_{pq} = \sum_x \sum_y (x + a)^p \cdot (y + b)^q f(x, y), \quad (3.6)$$

Böylece m'_{pq} veya μ_{pq} merkezi momentleri $a = -\bar{x}$ ve $b = -\bar{y}$ yerine koyularak Eş. 3.7'den hesaplanabilmektedir;

$$\begin{aligned} \bar{x} &= \frac{m_{10}}{m_{00}} \text{ ve } \bar{y} = \frac{m_{01}}{m_{00}}, \\ \mu_{pq} &= m'_{pq} = \sum_{x=0}^{M-1} \sum_{y=0}^{M-1} (x - \bar{x})^p (y - \bar{y})^q f(x, y) \\ \mu_{pq} &= \sum_{x=0}^{M-1} \sum_{y=0}^{M-1} (x - \bar{x})^p (y - \bar{y})^q f(x, y) \end{aligned} \quad (3.7)$$

Ölçeklenmiş normalleştirme merkezi moment değışiklerine uygulandığında,

$$\eta_{pq} = \mu_{pq} / \mu_{00}^\gamma, \gamma = [(p + q)/2] + 1 \quad (3.8)$$

elde edilmiştir.

Özellikle (Hu, 1962), ölçekleme, pozisyon ve yönelime ölçeklenmiş sıralı 3 aracılığıyla normalleştirilmiş merkezi momentleriyle hesaplanan 7 değeri tanımlamıştır (Mercimek vd., 2005). Merkezi momentleri bakımından, 7 momentler Eş. 3.9-15 arasında verilmiştir:

$$M_1 = (\eta_{20} + \eta_{21}), \quad (3.9)$$

$$M_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2, \quad (3.10)$$

$$M_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2, \quad (3.11)$$

$$M_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2, \quad (3.12)$$

$$M_5 = (\eta_{30} - 3\eta_{12})^2(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2], \quad (3.13)$$

$$M_6 = (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\ + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \quad (3.14)$$


$$M_7 = (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\ - (\eta_{30} + 3\eta_{12})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \quad (3.15)$$

3.6.2. GLCM öznitelik çıkarma yöntemi

GLCM, M.Haralick tarafından ortaya atılmış bir öznitelik çıkarma yöntemi olup, renksiz (gri tonlu) bir görüntünün özniteliğini çıkarmaktadır. GLCM, iki komşu piksel arasındaki ilişkiyi tanımlamaktadır (Acar ve Özerdem, 2012). Bu piksellerden birincisi referans pikseli, ikincisi de komşu piksel olarak bilinmektedir (Horng vd., 2003). Matristeki dağılım, pikseller arasındaki açığa ve mesafe göre ayarlanmaktadır. N_g boyutlu bu matris bir kare matris olup, matristeki her bir elemanın d mesafesini i ve j piksel çiftin oluşum sayısını belirtmektedir (Roumi, 2009).

GLCM özniteliklerinin çıkartılabilmesi için görüntü pikseller arası mesafe,

görüntü piksel çiftlerinin yön bilgileri gibi parametrelerinin bilinmesi gerekebilmektedir. En çok bilinen ortak yönler $\theta=0,45,90,135$ ve bunların simetrik benzerleridir. Acar ve Özerdem (2012)'e göre Şekil 3.18'de pikseller arası uzaklık $d=1$, yön açısı $\theta=0$ ve gri seviye sayısı 8 olan bir eş oluşum matrisi örneği verilmiştir. Buradaki görüntü matrisi içindeki (1,1)'lik piksel çifti (1,1) ve (1,2) koordinatında bir defa tekrarlandığından dolayı, (1,1)'lik piksel çiftinin eş oluşum matrisindeki (1,1) koordinatındaki değeri, 1'e eşit olur. Aynı şekilde (6,2) piksel çifti, görüntü matrisi içinde 3 defa tekrarlandığından dolayı, eş oluşum matrisindeki değeri 3'e eşit olur. Bu adımlar görüntü matrisi içindeki diğer piksel çiftleri içinde aynı işlemler tekrarlanıp, görüntüye ait eş oluşum matrisi oluşturulur.



Şekil 3.18 Eş oluşum matrisinin elde edilmesi (Acar ve Özerdem, 2012).

Sırasıyla (3.16), (3.17) ve (3.18) nolu formüllerde GLCM nin satır ve sütunlarına ilişkin ortalama ve standart sapma eşitlikleri gösterilmiştir. Bu eşitlikler, $p(i,j)$ 'nin satır ve sütunların ortalama ve standart sapma değerlerinin olasılık yoğunluk fonksiyonunu ifade eder.

$$\mu_x = \sum_i \sum_j i \cdot p(i, j), \mu_y = \sum_i \sum_j j \cdot p(i, j) \quad (3.16)$$

$$\sigma_x = \sum_{i,j} (i - \mu_x)^2 \cdot p(i, j) \quad (3.17)$$

$$\sigma_y = \sum_{i,j} (j - \mu_y)^2 \cdot p(i, j) \quad (3.18)$$

Eş oluşum matrisleri ile görüntünün doku karakteristiğini içeren enerji, kontrast, entropi, korelasyon, homojenlik, ortalama ve standart sapma olmak

üzere yedi adet öz nitelik hesaplanmıştır (Horng vd., 2003; Roumi, 2009; Demirhan ve Güler, 2010). GLCM'den hesaplanabilen görüntü öz niteliklerinin bağıntıları Eş. (3.19-25) belirtilmiştir (Demirhan ve Güler, 2010; Leen ve Costas, 1999; Haralick, 1973; Manian ve Vbsquez, 1997).

i) Kontrast

$$\sum_{n=0}^{N_g-1} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p(i,j) |i-j| = n \right\} \quad (3.19)$$

ii) Homojenlik

$$\sum_{i,j} \frac{p(i,j)}{1+(i-j)^2} \quad (3.20)$$

iii) Korelasyon

$$\sum_{i,j} \frac{(i-\mu_i)(j-\mu_j)p(i,j)}{\sigma_i \sigma_j} \quad (3.21)$$

iv) Enerji

$$\sum_i \sum_j p(i,j)^2 \quad (3.22)$$

v) Entropi

$$-\sum_{i,j} p(i,j) \cdot \log(p(i,j)) \quad (3.23)$$

vi) Ortalama

$$m_{ij} = \frac{1}{MN} \sum_i^N \sum_j^M I(i,j) \quad (3.24)$$

vii) Standard Sapma


$$s_{ij} = \frac{1}{MN} \sum_i^M \sum_j^N (I_{ij} - m_{ij})^2 I_{ij} \quad (3.25)$$

3.6.3. DM öz nitelik çıkarma yöntemi

Bu çalışmada sinyalin alçak ve yüksek frekans bileşenlerine ayrılmasında Haar, Daubechies db[2-10], Bior, Coif, Symlet tipi ayrık dalgacık türleri kullanılmıştır. Belirtilen dalgacık türleri hakkında kısa bir bilgi verilmiştir (Beale vd., 2012).

3.6.3.1. Haar


Dalgacıklar ile alakalı tartışmalar, dalgacık ailesinin ilk ve en basit türü olan Haar ile başlamıştır. Haar sürekli değildir ve bir adım fonksiyonuna benzemektedir. Bu dalgacık yöntemi, Daubechies db1 olarak temsil edilmektedir (Şekil 3.19).



Şekil 3.19 Haar Dalgı Şekli (Beale vd., 2012)

3.6.3.2. Daubechies db

Ingrid Daubechies, dünyadaki dalgacık arařtırmalarındaki en dikkat çeken arařtırmacılarından biridir. Ortonormal diye adlandırılan dalgacıkları keřfetmiřtir. Böylece ayrıık dalgacık analizi uygulanabilmiřtir (Şekil 3.20).




Şekil 3.20 Daubechies Dalgı Şekli (Beale vd., 2012)

Daubechies ailesi dalgacıklarının isimleri dbN ile yazılmaktadır. Buradaki N sıradır ve db dalgacığın soy adını ifade etmektedir. Db dalgacığı yukarıda da bahsedildiğı gibi Haar olarak isimlendirilmiřtir. Şekil 3.20’de gösterildiğı gibi Haar dışında ailenin 9 üyesi daha vardır.

3.6.3.3. Bior


Bior dalgacık ailesi sinyal ve görüntünün tekrar oluřumu için gerekli olan doğrusal fazın özelliğini sunmaktadır. 2 dalgacık kullanarak, ayrışım için biri ve diğerkleri aynı tek birinin yerine tekrar oluřumu için ilginç özellikler üretilmiřtir (Şekil 3.21).



Şekil 3.21 Bior Dalgı Şekli (Beale vd., 2012)

3.6.3.4. Coif

R.Coifman'ın isteęinde I. Daubechies tarafından üretilmiřtir. Dalgacık fonksiyonu 0'a eřit olan $2N$ momentleri ve ölçeklendirme fonksiyonu 0'a eřit olan $2N-1$ momentleridir. 2 fonksiyon $6N-1$ uzunluęunu desteklemektedir (Şekil 3.22).




Şekil 3.22 Coif Dalgı Şekli (Beale vd., 2012)

3.6.3.5. Symlet

Symlet'ler db ailesindeki deęiřikler olarak Daubechies tarafından öne sürölmüş olan simetrik dalgacıklardır. İki dalgacık ailesinin özellikleri benzerdir (Şekil

3.23).



Şekil 3.23 Symlet Dalga Şekli (Beale vd., 2012)

Belirtilen farklı tip dalgacık türlerinin temelini ayırık dalgacık dönüşümü oluşturmaktadır. Ayırık dalgacık dönüşümünde tüm ölçek aralığında analiz yapmak yerine belirli ölçek grupları tespit edilerek, bu aralıkta analiz yapılması sağlanmaktadır.

Ayrık dalgacık dönüşümü için kullanılan fonksiyon Eş. (3.26)'de verilmiştir.

$$\psi_{m,n}\left(\frac{t-\beta}{\alpha}\right) = \alpha_0^{-m/2} \psi\left(\frac{t-n\beta_0\alpha_0^m}{\alpha_0^m}\right) \quad (3.26)$$

Burada m ve n tamsayı olarak dalgacığın sırası ile ölçek ve zaman eksenindeki öteleme parametreleridir. β_0 , sabit bir ötelenme adımını ifade eder ve değeri 1'den büyüktür, β_0 zaman eksenindeki ötelenme aralığı değeridir. Eş. (3.26)'de zaman eksenindeki ötelenme adımının α_0^m değerine bağlı olarak $n\beta_0\alpha_0^m$ şeklinde ifade edilebilir.

En sık kullanılan α_0 ve β_0 değerleri 2 ve 1 (Lampinen vd., 1995), ikinin katları kullanılarak oluşturulan yaklaşım ve dalgacık fonksiyonu sırasıyla Eş. (3.27)'deki gibi tanımlanabilmektedir:

$$\begin{aligned} \Phi_{m,n}(t) &= 2^{-m/2} \Phi(2^{-m}t - n) \\ \psi_{m,n}(t) &= 2^{-m/2} \psi(2^{-m}t - n) \end{aligned} \quad (3.27)$$

Bir i ayrık zaman adımına sahip N tane örnek içeren S_t zaman serisi için, ayrık dalgacık dönüşümü Eş. (3.28)'deki gibi tanımlanabilmektedir:


$$W_{m,n} = 2^{-m/2} \sum_{i=0}^{N-1} S_i \psi(2^{-m}i - n) \quad (3.28)$$

Eş. (3.28)'de $W_{m,n}$, $\alpha = 2^m$ ölçek ve $\beta = 2^m n$ zaman değerine sahip dalgacık dönüşüm katsayılarıdır.

Ayrık dalgacık dönüşümü, 1988 yılında Mallat tarafından filtreler kullanılarak geliştirilmiştir. Mallat yöntemi olarak da bilinen bu yöntem, iki kanal alt bant kodlayıcısı ile yapılan hızlı bir dalgacık dönüşümü yapan filtreleme yöntemidir (Misiti vd., 1997; Lee vd., 1999; Percival and Walden, 2002).


Ayrık dalgacık dönüşümü, sinyalleri, iki ana bileşene ayırmaktadır. Bu işlem filtreler kullanılarak yapılmaktadır. Bu ana bileşenlerden birincisi düşük frekanslı bileşenler yani alçak geçiren filtre çıkışlarıdır, bir diğeri ise yüksek frekanslı bileşenler yani yüksek geçiren filtre çıkışlarıdır.

Ayrık dalgacık dönüşümünde oluşan, ana bileşenlerden düşük frekanslı bileşenlerine yaklaşımlar (A), yüksek frekanslı bileşenlerine ise detaylar (D) denilmektedir. Ayrık dalgacık dönüşümü işlemine tabi tutularak ayrıştırma işlemi uygulanan $S(t)$ sinyali eşit sayıda alt frekans bileşenine yani yaklaşımlara (A) ve yüksek frekans bileşenine yani detaylara (D) Şekil 3.24'de gösterildiği gibi ayrıştırılmaktadır.



Şekil 3.24 Dalgacık dönüşümünde süzgeçleme işlemi (Demir, 2008).

Dalgacığın Mallat'ın öngördüğü çoklu çözünürlük analizi ve ikili örneklemeye uygun olması sinyallerin istenilen seviyede ve hızda incelenmesini sağlamaktadır (Rao ve Bopardikar, 1998; Strang and Nguyen, 1997). Şekil 3.25'de 3. seviyede bir $S(t)$ sinyalinin ayrışımı görülmektedir.



Şekil 3.25 Standart dalgacık analizi

$S(t)$ standart dalgacık dönüşümü ile alt bantlara ayrıldıktan sonra, sinyalin yaklaşım bileşeni, aynı işlem ile tekrar alt bantlarına ayrılmaktadır ve böylece istenen çözünürlüğe ulaşınca kadar devam edilmektedir.

Ayrık dalgacık dönüşümüne tabi tutulan sinyal $S(t)$ hiçbir kayba uğramaz, sadece ana dalgacıkla çarpılarak, bileşenlerine ayrıştırılmıştır. Buradaki A_3 yaklaşım bileşeni, temel bileşendir. Yaklaşımlar, yüksek ağırlıklı, düşük frekanslı bileşenlerdir. Detaylar ise düşük ağırlıklı, yüksek frekanslı bileşenlerdir. Dalgacık dönüşümünde amaç görüldüğü üzere, sinyali yaklaşım ve detaylarına ayrıştırmaktır. Elde edilen yaklaşım tekrar ikinci seviye yaklaşım ve detayına ayrıştırılır, bu işlem istenilen sonuç elde edilene kadar tekrarlanabilir. Sinyali istenilen çözünürlük seviyesinde bileşenlere ayırmak için bileşenlere ayırma işlemi ardışık tekrar etmekle mümkün olabilir (Misiti vd., 1997).

Orijinal $S(t)$ işareti önce yüksek geçirgen $g(t)$ filtresinden ve alçak geçirgen $h(t)$ filtresinden geçirilmektedir. Bu seviyeli bir ayrıştırma işlemidir ve matematiksel olarak Eş. (3.29) ve Eş. (3.30)'deki gibi ifade edilmektedir:

$$D(k) = \sum_t S(t)g(2k - t) \quad (3.29)$$

$$A(k) = \sum_t S(t)h(2k - t) \quad (3.30)$$

Eş. (3.29) ve Eş. (3.30)'te iki ile alt örneklemeden sonra sırasıyla yüksek geçirgen ve alçak geçirgen filtre çıkışları verilmiştir ve k filtre seviyesini gösterir. Bu şekilde budak görüntüleri filtrelerden geçirilerek öznelitekt vektörünün elde edilmesi sağlanmıştır.

3.6.3.6. İki boyutlu kesikli zaman dalgacık dönüşümleri

İki boyutlu alt bant analizi, 1-boyutlu analizin sırasıyla düşey ve yatay eksene uygulanmasıyla yapılmaktadır. Yatay ve düşey süzgeçlemenin sonucunda üretilen dört yeni alt uzayda bir adet yaklaşık görüntü; yatay, dikey ve köşegen yönlerde olmak üzere üç adette ayrıntı görüntüsü elde edilmektedir. Bunlar:

$$\Phi(x, y) = \Phi(x)\Phi(y) \quad (3.31)$$


$$\Phi^Y(x, y) = \psi(x)\Phi(y) \quad (3.32)$$

$$\psi^D(x, y) = \Phi(x)\psi(y) \quad (3.33)$$

$$\psi^K(x, y) = \psi(x)\psi(y) \quad (3.34)$$

biçiminde ifade edilir (Cetişli, 2005). Eş. (3.31, 3.32, 3.33 ve 3.34)' lerin de sırasıyla yaklaşım, yatay, dikey ve köşegenel katsayılar elde edilmektedir.

Bu işlemlerin sonrasında iki boyutlu ayırık dalgacık dönüşüm fonksiyonu, Daubechies 'db2' türünden 3. seviye bir filtreleme ile bir görüntünün yaklaşım ve diğer ayrıntı bilgileri temsili olarak yaprak budak için Şekil 3.26'de gösterilmiştir.



Şekil 3.26 Yaprak budak için dalgacık dönüşümü genel gösterimi

3.7. Sınıflandırma

Sınıflandırma ahşapların yüzeyindeki budak kusurunun fiziksel özelliklerine göre budak tipinin tanımlanma işlemini temel alır. Sınıflandırmada öğrenme ve test aşamaları olan danışmanlı yöntemler kullanılmıştır. Öğrenme aşamasında ön işlemlerden geçirilmiş her bir budak için farklı öznitelik çıkarma yöntemleri kullanılarak öznitelikleri çıkarılmaktadır. İkinci adımda önceden belirlenen hedef değerlerine göre sınıflandırma işlemi yapılmaktadır. Sınıflandırma aşamasında ise k komşu yöntemi (KNN), yapay sinir ağları (YSA), doğrusal diskriminant analizi (LDA) ve Naive Bayes (BAYES) sınıflandırıcılar kullanılmıştır.

3.7.1. KNN sınıflandırma yöntemi

KNN sınıflandırıcısı eğitilebilen danışmanlı bir yöntemdir. Amacı, yeni bir örnek geldiğinde var olan öğrenme verisi en yakın k komşusuna/komşularına bakarak örneğin sınıfına karar vermektir (Teknomo, 2006).

Bu modelde, KNN yöntemi test örneklerini sınıflandırabilmek için kullanılmıştır. Farklı momentler kullanılarak her bir budak görüntüsü için farklı öznitelik elde edilmiştir. Bu öznitelik değerleri bulgular ve tartışma kısmında çizelge halinde verilmiştir. Öklid mesafesi, test örnekleri ve k komşusu arasında hesaplanmıştır. Öklid mesafesi formülü Eş. (3.35)'de verilmiştir:

$$D(M) = \sqrt{\sum_{j=1}^N [f_j(x) - f_j(M)]^2} \quad (3.35)$$

öznitelik vektöründe N öznitelik sayısını göstermektedir. $f_j(x)$, X test örneğinin j^{th} özniteliğini temsil etmektedir. $f_j(M)$, M^{th} sınıfının j^{th} özniteliğini temsil etmektedir. Sonrasında test örneği X , KNN kullanılarak sınıflandırılmıştır. KNN yönteminde, bir test örneği pozitif değere sahip bir k komşu değeriyle sınıflandırılmaktadır. Bu tez çalışmamızda $k=1$ alınarak deneyler yapılmıştır.

3.7.2. LDA sınıflandırma yöntemi

LDA'nın temel fikri, dönüşüm sonrası en ayırt edilebilir öznitelik kümeleri kullanılarak kümelerin doğrusal dönüşümlerini bulmayı amaçlamaktadır (Yang vd., 2000).

M sınıflı bir problem için, S_b (sınıflar arasındaki dağılım matrisi) ve S_w (sınıflar içindeki dağılım matrisi) matrisleri arasında aşağıda Eş. (3.36) ve (3.37)'deki gibi tanımlanmaktadır:

$$S_b = S_b = \sum_{i=1}^M \Pr(C_i)(\mu_i - \mu)(\mu_i - \mu)^T = \Phi_b \Phi_b^T, \quad (3.36)$$

$$S_w = \sum_{i=1}^M \Pr(C_i) \sum_i = \Phi_w \Phi_w^T, \quad (3.37)$$

$\Pr(C_i)$, C_i sınıfının öncelikli olasılıklarıdır ve genellikle eşitlik önceliklerinin varsayımları ile $\frac{1}{M}$ atanır; μ ortalama vektörüdür; $\sum_i$ ise μ_i ortalama vektörü temsil eden C_i farklı sınıflarının örnek vektörlerinin ortalama dağılımıdır:

$$\sum_i = E[(x - \mu_i)(x - \mu_i)^T | C = C_i], \quad (3.38)$$

Sınıf ayrımı belirli kriterler ile ölçülebilmektedir. Genel kullanımı, örneklerin sınıf dağılım matrisleri içerisinde ve örneklerin sınıf dağılım matrisleri arasındaki determinant oranıdır:

$$J(A) = \arg \max \frac{|A S_b A^T|}{|A S_w A^T|}, \quad (3.39)$$

Burada A , $m \times n$ boyutlarında bir matristir ($m \leq n$). Eş. (3.39)'deki optimizasyon probleminin çözümü genelleştirilmiş öz değer problemini çözmektedir (Wilks, 1962):

$$S_b A^* = \lambda S_w A^*, \quad (3.40)$$

$$D_i(X) = A^{*T}(X - \mu_i), i = 1, 2, \dots, m, \quad (3.41)$$

Eş. (3.40), $S_w^{-1}S_b$ matrisi için öz değer problemini çözmekte ve S_w 'nin tersini hesaplamaktadır (Wilks, 1962). Fakat, bu yöntem sayısal olarak kararsızdır. Çünkü bu yüksek boyutlu matrislerin tersini içermektedir. Pratikte en sık kullanılan LDA yöntemi paralel köşegenlemeyi temel almaktadır (Fukunaga,1990). Bu yöntemin temel fikri S_w ve S_b 'nin her ikisini paralel köşegenleştiren A matrisini bulmaktadır (Yang vd., 2000).

3.7.3. BAYES sınıflandırma yöntemi

BAYES sınıflandırıcıları istatistiksel sınıflandırıcılardır. Özel bir sınıfa ait olarak verilen bir olasılık gibi, sınıf üyeliklerine ait olasılıklarını önceden söyleyebilirler. BAYES teoremi aşağıda verilen BAYES teoremini temel almaktadır. Sınıflandırma algoritmaları karşılaştırılarak yapılan çalışmalar naive(saf) Bayesian sınıflandırıcı olarak bilinen basit BAYES sınıflandırıcıyı bulmuşlardır.

BAYES, verilen bir sınıf üzerindeki bir özelliğe ait değerlerin etkisinin diğer özelliğe ait değerlerden bağımsız olduğunu farz eder. Bu kabul sınıf koşullu bağımsızlık olarak adlandırılmaktadır. Bu ise gerekli hesaplamaları basitleştirir, anlaşılabilirliği kolaylaştırır ve doğal olarak “saf” kelimesi ile ifade edilir. BAYES ağları, BAYES sınıflandırıcılardan farklı, öznitelik altkümeleri arasındaki ayrılıkların gösterilmesini sağlayan grafiksel modelleme yöntemidir. BAYES ağları da sınıflandırma için kullanılabilir (Hudairy, 2004).

3.7.4. YSA sınıflandırma yöntemi

İnsanoğlu yaradılışından beri doğa ile iç içe yaşamış ve ondan esinlenerek karşılaştığı problemler için çözüm yöntemleri geliştirmiştir. Bu yöntemler bilgisayar kullanılarak yapılan sayısal hesaplamaların hızla gelişmesiyle çok ilerleme kaydetmiştir. Geliştirilen yöntemlerin bazıları canlı organizmayı örnek alarak yapılmıştır (Şen, 2004). YSA' da bu şekilde insanın biyolojik nöron yapısını dikkate alınarak geliştirilen bir yöntemdir.

Biyolojik nöron yapısını içeren insan beynine bakıldığında, insanın en temel

parçası olduğu görülmektedir. İnsanın temel parçası olarak düşünme, hatırlama ve insanın önceki deneyimlere göre hareketini sağlayan kendine özgü sinir hücreleridir. İnsan beyinde yaklaşık 1011 sinir hücresi vardır. Her bir biyolojik sinir hücresinin yaklaşık 10.000 kadar komşu bağlantısı vardır. Bu bağlantılar sinirlerden uyarı alır. İnsan beyninin çalışma frekansı 100 Hz, ağırlığı yetişkin bir insanda yaklaşık 1.3 kg. dır (Erdem ve Uzun, 2005).

Üç katmanlı bir sistem olarak bilinen ve her bir biyolojik sinir hücresinin 10.000 kadar komşu bağlantısı olduğu sistem örüntü tanıma sistemlerinde sınıflandırma yöntemlerinin temelini oluşturacak şekilde modellenmiştir (Saraç, 2004).


3.7.4.1. Yapay sinir ağlarının ana öğeleri

YSA, birbirine bağlı çok sayıda işlem elemanlarından oluşmuş, genellikle paralel işleyen yapılar olarak adlandırılmaktadır. Bir YSA, birbiriyle bağlantılı, çok sayıda düğümlerden oluşur. YSA, insan beyni gibi, öğrenme, hatırlama ve genelleme yeteneğine sahiptir.

İnsan beyinde öğrenme 3 şekilde olur:

1. Yeni aksonlar üreterek,
2. Aksonların uyarılmasıyla,
3. Mevcut Aksonların güçlerini değiştirerek.

Her aksonun üzerinden geçen işaretleri değerlendirebilecek yetenekte olduğu savunulmaktadır. Aksonun bu özelliği, bir işaretin belli bir sinir için ne kadar önemli olduğunu göstermektedir. YSA temel birimi işlem elemanı ya da düğüm olarak adlandırılan yapay bir sinirdir. Bir yapay sinir, biyolojik sinirlere göre daha basit olmasına karşın, biyolojik sinirlerin 4 temel işlevini taklit ederler (Şekil 3.27).



Şekil 3.27 Yapay bir sinir düğüm (Elmas, 2011)

Girişler x_i sembolüyle gösterilmiştir. Bu girişlerin her biri ağırlık w ile çarpılır. Basitçe, bu ürünler eşik değeri b_j ile toplanır ve sonucu oluşturmak için etkinlik işlevi (aktivasyon fonksiyonu) ile işlem yapılır ve y_i çıkışı alınır. YSA bu temel yapıdan türetildiğini kabul ederek biyolojik sinirlerinin 4 temel görevinin YSA' da ki karşılığı elde edilmiştir.

Girişler

Girişler, bir yapay sinir hücresine gelen bilgilerdir $(x_1, x_2, \dots, x_n)$. Bu bilgiler dış ortamlardan ya da diğer sinir hücrelerinden gelebilir. Dış ortamlardan gelen bilgiler, ağırlık öğrenmesi istenen örneklerinden oluşmaktadır (Baş, 2006).

Ağırlıklar

Ağırlıklar $(w_1, w_2, w_3, \dots, w_n)$, gelen bilgilerin hücre üzerindeki etkisini belirleyen değerlerdir. Yapay sinir ağı içinde girdilerin hücreler arasında iletimini sağlayan tüm bağlantıların farklı ağırlık değerleri bulunur. Böylelikle ağırlıklar her işlemci elemanın her girdisi üzerinde etki yapmış olur. Ağırlıklar değişken veya sabit değerler olabilirler.

Bir ağırlığın değeri; küçük olması, o girişin yapay sinir için önemli olmaması ya

da zayıf bağlanması veya büyük olması, o girişin yapay sinir için güçlü bağlanması ya da önemli olması anlamına gelmektedir (Elmas, 2011).

Toplama işlevi

Toplama işlevi v_i , sinirde her bir ağırlığın ait olduğu girişlerle çarpımının toplamalarını eşik b_j değeri ile toplayarak etkinlik işlevine göndermektedir.

Etkinlik işlevi

Toplama işlevinden gelen girdiyi işleyerek yapay sinir hücresinin çıkışını belirler. Etkinlik işlevi genellikle doğrusal olmayan bir fonksiyondur. Doğrusal fonksiyonların tercih edilmemesinin nedeni, doğrusal fonksiyonlarda girdi ile çıktının doğru orantılı olmasıdır. Bu durum ilk yapay sinir ağları denemelerinin başarısızlıkla sonuçlanmasının temel nedenidir (Minsky ve Papert, 1969).

Etkinlik işlevi, toplama işlevinden gelen girdiyi dönüştürerek istenilen değerler arasında sınırlandırmaktadır. Bu değerler kullanılan etkinlik işlevinin tipine göre genellikle $[0,1]$ veya $[-1,1]$ arasındadır. Bu değer etkinlik işlevinin, dolayısıyla yapay sinir hücresinin çıktı değeri olarak ya dış ortama ya da girdi olarak başka bir yapay sinir hücresine iletilmektedir. Etkinlik işlevi olarak tercih edilen fonksiyonların şekilleri verilmiştir.

Toplama işlevi sonucu elde edilen fonksiyon:

$$v_i = \sum_{j=1}^n w_{ij}x_j + b_j \quad (3.42)$$

olmak üzere:

1. Doğrusal etkinlik işlevi fonksiyonu:

Doğrusal etkinlik işlevi fonksiyonu ağın son kısmında kullanılmıştır. Bu fonksiyon gelen net girdileri doğrudan hücre çıkışı olarak vermektedir.

Eşitliği şu şekilde gösterilebilir:

$$y = f(v) \quad (3.43)$$

elde edilmektedir.

2. Sigmoid tipi etkinlik işlevi fonksiyonu:


Uygulamalarda en çok kullanılan etkinlik işlevi fonksiyonlarından biridir. Fonksiyonun en aktif bölgesi 0.2 ile 0.8 arasındadır. Tez çalışmasında log-sigmoid etkinlik işlevi fonksiyonu kullanılmıştır.

Log-sigmoid etkinlik işlevi fonksiyonu ağız gizli katmanlarında kullanılmıştır. Log- sigmoid etkinlik işlevi fonksiyonu; sürekli ve doğrusal olmayan, türevi alınabilir bir fonksiyon olması nedeniyle tezde kullanılan etkinlik işlevi fonksiyonudur. Bu fonksiyon, ağ girişinin her değeri için 0 ile 1 arasında bir değer üretmektedir.

Eşitliği şu şekilde gösterilebilir:

$$y = f(v) = \frac{1}{1+e^{-v}} \quad (3.44)$$

Etkinlik işlevi fonksiyonu YSA' ların farklı modelleri için farklı olabilir. Yapılan çalışmada kullanılan etkinlik işlevi fonksiyonlarının grafikleri Şekil 3.28'de verilmiştir.



Şekil 3.28 Etkinlik işlevi fonksiyonları: a) Doğrusal etkinlik işlevi fonksiyonu, b) Log-sigmoid etkinlik işlevi fonksiyonu

Çıkış işlevi

Çıkış y_i , etkinlik işlevi sonucunun sınırlara veya dış dünyaya gönderildiği yerdir. Bir sinirin bir tek çıkışı vardır. Sinirin bu çıkışı, kendinden sonra gelen herhangi

bir sayıdaki diğer sinirlere giriş olabilmektedir.


3.7.4.2. Yapay Sinir Ağlarında Öğrenme

Donald Hebb, 1949 yılında sinapsların şartlara uyum sağlama yeteneğini incelemiş ve Hebb kuralı adı verilen öğrenme kuralını ortaya çıkarmıştır. Bu kuralda temel fikir iki sinir bağlantısı arasındaki kuvvet (ağırlığın değeri), sinirlerin aynı zamanda etkinleştirilmesine bağlıdır.

Hebb, sinir faaliyetlerini örnek alarak bunların hafızadaki basit bir yerde yerleşebileceğini varsaymıştır ve bu kurama göre sinirlerin birbirlerini ortaklaşa uyardıklarını ve bu uyarım neticesinde aralarındaki sinaptik bağlantı kuvvetinin (ağırlıkların) kendi etkinlikleri çarpımı oranında artacağını ortaya koymuştur.

Hebb'in ortaya koyduğu sinirler arasındaki metabolik değişme ve sinaptik kuvvetin yani öğrenme değişkenleri ve ağırlıkların nasıl ayarlanacağı konusunu ele almışlardır ve bunlara uygun öğrenme yöntemi geliştirmişlerdir (Elmas, 2011). Bu öğrenme yöntemleri danışmansız ve danışmanlı olmak üzere iki gruba ayrılmaktadır.

Şekil 3.29'de temel öğrenme yöntemleri içerisinde tezde üzerinde çalışılan konuya en uygun yöntem danışmanlı yöntemdir. Bu danışmanlı yöntem içerisinde de dört farklı öğrenme kuralı kullanılmıştır.




Şekil 3.29 Temel öğrenme yöntemi

YSA'da gerçek çıkış istenen çıkışla kıyaslanmaktadır. Rasgele değişen ağırlıklar ağ tarafından öyle ayarlanır ki, bir sonraki döngüde gerçek çıkış ile istenen çıkış arasında daha yakın karşılaştırma üretilebilsin. Öğrenme yöntemi, bütün işlem elemanlarının anlık hatalarını azaltmak veya yok etmeye çalışmaktadır. Bu hata azaltma işlemi, kabul edilebilir seviyeye ulaşana kadar ağırlıklar sürekli olarak değiştirilmektedir.

Danışmanlı öğrenmede, YSA kullanılmadan önce eğitilmektedir. Eğitme işlemi, sinir ağına giriş ve çıkış bilgileri vermekle oluşmaktadır. Yani, her bir giriş kümesi için gerekli olan çıkış kümesi ağa verilmesi gerekmektedir.

Danışmanlı öğrenmede (Şekil 3.30) giriş ve çıkış çiftlerinden oluşan eğitim bilgileri bulunmaktadır. Ağ giriş bilgisine göre üretilen çıkış değerini, istenen değerle karşılaştırarak ağırlıkların değiştirilmesi için gerekli değeri hesaplamaktadır. Girilen değerle istenen değer arasındaki fark hata değeri olarak ortaya çıkmaktadır. Bu hata değeri belirlenen hata değerinden küçük oluncaya kadar eğitime devam edilmektedir. Hata değeri istenen değer altına düştüğünde tüm ağırlıklar sabitlenerek eğitim işlemi sonlandırılmaktadır.



Şekil 3.30 Danışmanlı öğrenme

Eğer verilen girişe karşılık amaçlanan çıkış üretileniyorsa, ağın çıkış değerindeki hatayı minimize edecek şekilde bağlantı ağırlıklarının değiştirilmesi sağlanmaktadır.

Geri yayımlı öğrenme


Geri yayılım ağı, Geoffrey Hinton ve James McClelland tarafından geliştirilmiştir. Geri yayımlı öğrenen ağlar hiyerarşik yapıdadır. Giriş, çıkış ve en az bir gizli katman olmak üzere üç katmandan oluşurlar. Gizli katman ve gizli katmandaki düğüm sayısı değiştirilebilmektedir. Düğüm sayısının artması ağın hatırlama yeteneğini artırmakla birlikte öğrenme işleminin süresini uzatmaktadır. Düğüm sayısının azaltılması eğitim süresini kısaltmakta fakat hatırlama yeteneğini azaltmaktadır. Giriş katmanındaki her bir düğüm gizli katmandaki her düğüme, gizli katman birden fazla ise bu katmandaki her bir düğüm kendisinden sonra gelen katmandaki her düğüme ve gizli katman çıkışındaki her düğüm çıkış katmanındaki her düğüme bağlıdır. Bir katmandaki hiçbir düğüm kendi katmanındaki diğer bir düğüme bağlı değildir. Her katmanın çıkış değerleri bir sonraki katmanın giriş değeridir. Bu şekilde giriş değerlerinin ağın girişinden çıkışına doğru ilerlemesine ileri besleme denilmektedir (Elmas, 2011).

Geri yayılım yöntemi çok katmanlı ağlarda kullanılan delta kuralı için geliştirilmiştir. İleri besleme mekanizması içinde kullanılan bağlantılar aracılığıyla geri yayılım ağ hatası ileri besleme aktarım işlevinin türevi tarafından geriye doğru yayılmaktadır. Öğrenme işlemi, ağda basit iki yönlü hafıza birleştirmeye dayanmaktadır.

Geri yayılım öğrenme yöntemi, türevi alınabilir etkinlik işlevlerini çok katmanlı herhangi bir ağa uygulayabilmektedir. Bu yöntem sistem hatasını azaltma esasına dayanan en uygun şekle sokma işlemidir. Bu yöntemde ağırlık ayarlamaları geriye doğru yapıldığı için geri yayılım ismi kullanılmaktadır.

Öğrenme fazında, giriş örnekleri ağa belli bir sırada sunulmaktadır. Her bir çalışma örneği çıktı örneği hesaplanana kadar katman katman ileri yayılmaktadır. Hesaplanan çıktı daha sonra olması beklenenle karşılaştırılıp aradaki fark hata olarak kabul edilmektedir. Hatalar, katman katman sinaptik ayarlamaların yapıldığı geri besleme bağlantılarında girdiler olarak kullanılmaktadır. Şekil 3.31’de geri yayılım çalışması için değiştirilmiş çok

katmanlı ileri beslemeli bir ağı göstermektedir. Geriye doğru olan bağlantılar sadece öğrenme fazı için kullanılırken, ileri doğru olan bağlantılar hem öğrenme amacıyla hem de işlevsel fazlar için kullanılmaktadır.




Şekil 3.31 Geri yayılım ağ yapısı

Geri yayılım öğrenme kullanıldığında, sonraki katmanların hataları kullanılarak gizli katmanın ağırlıkları ayarlanmaktadır. Böylece çıkış katmanında hesaplanan hatalar, son gizli katman ile çıkış katmanı arasında ağırlıklar ayarlanmaktadır. Aynı biçimde, bu işlemler ilk gizli katmana kadar tekrarlanmaktadır. Bu yolla hatalar, ilgili katmanın ağırlık düzeltmeleri yapılarak geriye doğru yayılmaktadır. Tamamlanan çalışma süresi içinde toplam hata en aza indirilinceye kadar bu işlemler tekrarlanmaktadır.

Çok katmanlı yapay sinir ağı

Birden fazla yapay sinir hücresi bir araya gelerek yapay sinir ağını oluşturmaktadır. Bu hücrelerin bir araya gelmesi rasgele olmamaktadır. Ağdaki sinir hücreleri katmanlar içine yerleştirilmektedir. Çoğunlukla hücreler 3 katman halinde ve hücreler her katman içinde paralel olacak şekilde bir araya gelerek ağı oluşturmaktadır. Her katmandaki düğümler sadece kendinden bir önceki katmanda bulunan düğümlerden giriş alabilmektedir. Bir düğüm kendinden sonraki bir sinir hücresine bağlanırken kendine asla bağlanamamaktadır. Son katmandaki işaretler ağı çıkışını oluşturmaktadır (Elmas, 2011). Şekil 3.32’de 3 katmanlı bir YSA modeli gösterilmiştir.



Şekil 3.32 Çok katmanlı sinir ağı

Geri yayılım işleminde, iki gizli katmandan oluşan çok katmanlı ileri beslemeli ağ için kullanılan ağ değişkenleri aşağıda ifade edilmiştir.

v_{ij} : i giriş katman siniri ile j gizli katman siniri arasındaki ağırlık bağlantısı ($i=1,2,...,n$) ($j=1,2,...,n$),

w_{ij} : i gizli katman siniri ile k çıkış katman siniri arasındaki ağırlık bağlantısı ($k=1,2,...,m$),

x^p : n boyutlu p girdi çalışma model ($p=1,2,...,p$),

z_i^p : x^p girdisini kullanan i gizli katman sinirinin çıktısı,

v_i^p : i çıkış katmanında gerçekleşmesi beklenen/istenen çıktı,

$$H_i = \sum_j v_{ij} x_j \quad i \text{ gizli katman sinirine gelen net girdi} \quad (3.45)$$

$$I_k = \sum_i w_{ik} H_i \quad k \text{ çıktı katmanı sinirine gelen net girdi} \quad (3.46)$$

$$y_i = f(H_i) \quad i \text{ gizli katman sinirinde üretilen çıktı} \quad (3.47)$$

$$y_k = f(I_k) \quad k \text{ çıktı katmanında üretilen çıktı} \quad (3.48)$$

Burada f rastgele, sınırlı ve türevi alınabilir bir işlevdir. Bu nedenle, k çıktı birimi için, x girdisine karşılık aşağıdaki tepki beklenmektedir.

$$y_k = f(I_k) = f\left(\sum_i w_{ik} v_i\right) = f\left(\sum_i w_{ik} f\left(\sum_j v_{ij} x_j\right)\right) \quad (3.49)$$

Bu çıktılar sonucunda doğrusal olmayan f işlevinden dolayı v_i , x girdi modelinin doğrusal olmayan bir işlevidir.

3.7.4.3. Geri yayılım yöntemi

İleri beslemeli q tane katmanlı bir ağ için geri yayılım yöntemi:

q : katman numaraları (1,2,...Q).

H_i^p : q'inci katmandaki i biriminin girdisi,

y_i^q : q'inci katmandaki i biriminin çıktısı,

w_{ij}^q : (q-1)'inci katmandaki i birimini, q'inci katmandaki j birimine bağlayan ağırlıktır.

1. w'ye reel değerli küçük rasgele sayılar başlangıç değeri olarak atanır.
2. Rasgele bir $\{x^p, t^p\}$ (giriş, hedef) çalışma modeli seçilip ve q katmanındaki her bir j birimi için ileri yönde sonuç değerleri hesaplanır. Böylece çıkış,

$$y_i^q = f\left(\sum_i y_i^{q-1} w_{ij}^q\right) \quad (3.50)$$

olmaktadır. 1.nolu katmanın girdileri 0 üssüyle etiketlenmiştir, yani;

$$y_i^0 = x_i \quad (3.51)$$

3. Son Q katmanında hesaplanan i birimleri için y_i^Q ve y_i^p değerlerine karşılık gelen delta miktarları hesaplanmakta ve çıkış birimleri için hata değeri Eş. (3.52)'deki gibi hesaplanır:

$$\delta_i^Q = (v_i^Q - y_i^p) f'(H_i^Q) \quad (3.52)$$

4. $q=Q, Q-1, \dots, 2$ katmanlarındaki tüm i birimleri için gizli katman birimleri yani geriye yayılımla deltaları için hata değerleri hesaplanmaktadır.

$$\delta_i^{q-1} = f'(H_i^{q-1}) \sum_i \delta_i^q w_{ij}^q \quad (3.53)$$

5. Bütün ağırlıklar w_{ij} 'leri kullanılarak güncellenmektedir.

$$w_{ij}^{yeni} = w_{ij}^{eski} + \Delta w_{ij}^q \quad (3.54)$$

$$\Delta w_{ij}^q = \eta \delta_i^q y_i^{q-1} \quad (3.55)$$

Burada η sabit öğrenme katsayısıdır.


6. Toplam hata kabul edilebilir bir düzeye gelene kadar her bir p modeli için ikinci adıma dönüp, işlemler tekrarlanır.

Eşitliklerde kullanılan η öğrenme katsayısı, her zaman birden küçük ve pozitif değerler almalıdır. Pozitif değerler delta vektörünü ideal vektöre yaklaştırılırken, sistemin kararlı olmasını birden küçük değerler sağlamaktadır (Elmas, 2011).

3.7.4.4. Modelleme

Tez çalışmasında giriş, gizli ve çıkış katmanından oluşan çok katmanlı YSA modeli kullanılmıştır. Ahşap üzerinde karşılaşılabilecek budaklara ait öznitelikler elde edildikten sonra YSA ile tanımlanabilmeleri için bir YSA modeli oluşturmak üzere işlemler tasarlanmıştır. Her bir budak YSA eğitimi için 7x180x108 öznitelik sayısının yarısını giriş teşkil edecek şekilde bir satır matrisi, çıkışlar ise 7 tane budak kusur tipini gösteren çıkış sınıfları belirlenmiştir. Elde edilen girdi ve çıktı dosyaları YSA eğitiminde kullanılarak ağ eğitimi gerçekleştirilmiştir. Gerçekleştirilen yönteme ilişkin blok diyagramı Şekil 3.33'de verilmiştir. Böylece girişe verilen bir budak öznitelik vektörünün başarı ile tanınmasını sağlayan bir model elde edilmiştir. Model 1260x108 öznitelik sayısının yarısını giriş teşkil edecek şekilde bir giriş matrisi, 20 gizli nöron, 180 çıkış katmanındaki nöron sayısıdır. Deneysel çalışmalar sırasında çıkış katmanındaki nöron sayısı belirlenmesinde her bir budak tipine ait 180 tane örnek teşkil eden budak görüntüleri olduğundan dolayı bu değer atanmıştır. Çıkışta ise sınıf sayısının belirlenmesinde 7 farklı budak tipinin

tanımlanmaya çalışılmasından dolayı belirtilen sayıda çıkış sınıfı tanımlanmıştır.



Şekil 3.33. YSA eğitimi blok diyagramı

3.8. ROC Analizi

ROC analizi, tanı testlerinde tanısal yeterliliği belirlerken kullanılan ve bu tanı testlerinin başarı oranının tek bir değer ile ifadesidir (Obuchowski ve McClish, 1997; Faraggi ve Reiser, 2002; Obuchowski etc. 2004). ROC eğrisinin altında kalan alan (Area Under Curve) en yaygın kullanılan ölçüm şeklidir (Hanley ve McNeil, 1982; Dirican,1991; Dirican, 2001; Obuchowski, 2005). AUC ne kadar büyük ise kusur tipi tahmin edilmesi o kadar doğru kabul edilir. AUC'nin olası değerleri tanı konulamaz 1/2'den mükemmel tanı konulabilir 2/2'e kadar değişim göstermektedir (Hanley ve McNeil, 1982; Grove, 2006).

Bu değişim aralıkları,

- 0.90-1 aralığı mükemmel (A),
- 0.80-0.90 aralığı çok iyi (B),
- 0.70-0.80 aralığı iyi (C),
- 0.60-0.70 aralığı orta (D),
- 0.50-0.60 aralığı kötü (F)

aralıklarında değişmektedir (Tape, 2013).

4. ARAŞTIRMA BULGULARI

Tez çalışmasında 4 farklı veritabanı kullanılmıştır. Birinci veritabanında sadece 7 farklı budak tipine sahip görüntüler bulunmaktadır. İkinci veritabanında rasgele ışık ortamlarında çekilmiş döşemelik tahta görüntüleri bulunmaktadır. Üçüncü veritabanında ise ahşap görüntüleri bulunmaktadır. Dördüncü veritabanında ise döşemelik tahtaları mevcuttur.

Döşemelik tahta ve ahşap görüntüleri TS 11970 (1196) ve TS EN13990 (2006) standartlarına göre sınıflandırılmıştır.

4.1. Veritabanlar

4.1.1. Budak veritabanı

Şekil 4.1’de gösterilen veritabanı Oulu Üniversitesi Ağaç Teknolojileri Laboratuvarı tarafından etiketlenerek yayınlanmıştır. Tez çalışmasında deneysel çalışmalar ilk olarak bu veritabanı üzerinde gerçekleştirilmiştir.



Şekil 4.1 Kullanılan budak veritabanından bazı örnekler

Bu veritabanında 438 etiketlenmiş budak görüntüsü bulunmaktadır (Silven, 2009). Bu budak görüntüleri aynı zamanda 7 farklı budak tipine sahiptirler.

Tez çalışmasında budak görüntüleri yaklaşık olarak %98'lük bir başarı ile 7 farklı sınıfa ayrılmıştır.

4.1.2. Döşemelik tahta veritabanı

Şekil 4.2'de gösterilen veritabanı, Isparta yeni sanayi kereste fabrikalarından farklı ışık ortamlarında çekilmiş olan görüntülerden oluşmaktadır. Bu veritabanında 177 tane etiketlenmiş döşemelik tahta görüntüsü bulunmaktadır.

Deneyisel çalışmalarda ikinci olarak kullanılmış olan bir veritabanıdır.



Şekil 4.2 Isparta yeni sanayi kereste fabrikalarından farklı ışık ortamlarında çekilmiş olan görüntüler

4.1.3. Ahşap veritabanı

Şekil 4.3’de gösterilen veritabanı, Oulu Üniversitesi Ağaç Teknolojileri Laboratuvarı tarafından etiketlenerek yayınlanmış bazı ahşap görüntülerini göstermektedir. Bu veritabanında 839 tane etiketlenmiş ahşap görüntüsü bulunmaktadır (Silven, 2009).

Deneysel çalışmalarda üçüncü olarak kullanılmış olan bir veritabanıdır.



Şekil 4.3 Ahşap veritabanından bazı örnekler

4.2. Gerçek Renk Gri Skala Dönüşümü

RGB renk bölgesinde her bir renk ayrı ayrı üç farklı matriste tutulmaktadır.


Gerçek rengin gri ölçekli görüntüye dönüşümü, Eş. (4.1)’de verilmiştir:

$$Y = 0.2989 * R + 0.5870 * G + 0.1140 * B \quad (4.1)$$

Gerçek renk bileşenlerine sahip bir görüntünün işlenmesi, görüntü üzerinde

gerçekleştirilen işlemlerin işlem süresini uzatması açısından gerçek zamanlı işlemlerde tercih edilme noktasında inceleme yapılmıştır. Tez çalışmasının ilerideki çalışmalarında gerçek zamanlı olarak kusurların tespit edilmesi amaçlandığından dolayı gri ölçekli ya da ikili görüntüler üzerinde çalışılması gerektiğinin önemi fark edilmiştir.

Budak, döşemelik tahta ve ahşap veritabanlarından alınmış farklı görüntülerin gri ölçekli formata dönüşümü uygulandıktan sonraki görüntüleri Şekil 4.4’de verilmiştir.



Şekil 4.4 Renkli görüntüyü gri formata çevirme: a) orijinal görüntü, b) gri ölçeklenmiş görüntü

4.3. Eşik Değeri Belirleme ve Deney Sonuçları

Sayısallaştırılmış görüntüler genelde gri tonludur. Temiz bir görüntü için basit

histogram tabanlı eşikleme yaklaşımı, görüntüleri iki tonlu hale çevirmeye yeterlidir. Piksellerin gri değerli histogramı göze çarpan iki tepeye sahiptir. İyi bir eşikleme değeri bu tepeler arasında yer alan ortalama gri seviyedir (Singh vd., 2010). Eşik değerinin iyi olabilmesi için dinamik olması gerekmektedir. Yoksa otomatik olarak kusur tespit eden sistemlerde bu elde edilen eşik değeri iyi bir sonuç vermemektedir. Bu anlamda farklı eşikleme yöntemleri budak tanıma yönteminde kullanılmıştır. Farklı eşikleme yöntemlerinde en iyi olanı deneysel çalışmalar sonrasında tespit edilmiştir.

Eşik değerinin dinamik olmasında parlaklık ve karşıtlık ayarlamalarından yararlanılmıştır. Yapılan uygulamada farklı konumlarda, farklı çözünürlükte çekilmiş budak görüntülerinin tamamında aynı etkiyi oluşturabilecek ve aynı zamanda arka plandaki, istenmeyen kısımları ortadan kaldıracabilecek bir yapı geliştirilmeye çalışılmıştır. Bahsedilen değişimlerden dolayı tek bir görüntüye uygulanan eşik değeri, diğer görüntüler için istenen etkiyi göstermeyebilir. Bu durumdan dolayı budak görüntülerinin gri seviye formatına çevrildikten sonra ikili formata dönüştürme yapıldığında istenilen bölgeyi ön plana çıkaran bir görüntü bazı denemelerde elde edilememiştir. Bunun yanı sıra veri kayıpları yaşanmıştır. Bu sorunları ortadan kaldırmak için farklı yöntemler denenmiştir. Bu yöntemler; ilk olarak Gonzalez ve Woods (2008) tarafından gerçekleştirilen iteratif global eşikleme yöntemi, ikinci olarak Otsu yöntemi, üçüncü olarak da minimum çapraz entropisi (minCE) yöntemi uygulanmıştır. Bu yöntemler, tez çalışmasında ilk adım olması ve diğer adımların temelini oluşturması açısından önem taşımaktadır.

Literatürde Çayırılı (2006), yapmış olduğu tez çalışmasında bahsedildiği gibi gri ton değerlerinin ağırlıklı ortalamasını ve standart sapmasını hesaplayarak görüntünün genel görünümüyle ilgili iki adet özellik elde edilebilmektedir. Gri ton değerlerinin ağırlıklı ortalaması görüntünün ortalama parlaklığının, standart sapması da karşıtlığın bir ölçüsüdür. Görüntünün parlaklığını ayarlamak için görüntü piksellerinin gri ton değerlerine sabit c sayısı eklenebilir. Bu durumda dönüşüm fonksiyonu Eş. (4.2)'de verilmiştir.

$$N(x,y) = T(M(x,y)) = M(x,y) + c \quad (4.2)$$

şeklindedir (Bellanger, 2000).


$$g(x,y) = T[f(x,y)] \quad (4.3)$$

Eş. (4.3.)’de $f(x,y)$ giriş görüntüsü, $g(x,y)$ işlenmiş görüntü ve $T, (x,y)$ ‘nin bazı komşuları üzerinde tanımlanmış f fonksiyonu üzerinde uygulanan operatördür. T , Eş. (4.4.)’e göre bir gri seviye dönüşüm fonksiyonu olur (Gonzalez and Woods, 2002).

$$N(x,y) = T(M(x,y)) \quad (4.4)$$

Eş. (4.2) ve Eş. (4.4) ifadesinde $N(x,y)$ ve $M(x,y)$ değişkenleri herhangi bir (x,y) noktasında sırasıyla $f(x,y)$ ve $g(x,y)$ ’nin gri seviyesini gösterirler. $N(x,y)$ ve $M(x,y)$ karanlıktan aydınlığa doğru gri seviyeyi göstermektedir.

Parlaklık ve karşıtlık ayarlamaları yardımıyla Şekil 4.5’de görüntülerin otomatik eşik değeri belirlenerek ikili formattaki görüntüsü elde edilmiştir.



Şekil 4.5 Parlaklık ve karşıtlık değerine göre eşiklenmiş görüntüler:
a) orijinal görüntü, b) eşiklenmiş görüntü

Bu ikili formattaki görüntüde tespit edilen kusur bölgesinin kırmızı değeri 70'den küçük olmasına bakılarak parlaklık ve karşıtlık değerlerinin toplamı 0.60 katsayısı ile büyük ve eşit ise 0.30 katsayısı ile çarpılması sonucu eşik değeri elde edilmiştir. Elde edilen sonuçlar Çizelge 4.1'de verilmiştir.

Çizelge 4.1 Eşik değeri karşılaştırılması

	Eşik Değeri
Şekil 4.2 b sol	87.13
Şekil 4.2 b orta	93.67
Şekil 4.2 b sağ	86.02

4.3.1. Global eşikleme

İkincil olarak global eşikleme yöntemi kullanılarak TS 11970 standardına göre en uygun eşik değerini belirleyebilmek için deneysel çalışmalar yapılmıştır. Bu eşikleme yöntemi Gonzales ve Woods (2008) tarafından gerçekleştirilmiştir. Belirtilen iteratif eşikleme yöntemi budak tanıma sisteminde başarılı sonuçlar vermiştir.


Kullanılan iteratif yöntem 4 aşamadan oluşmaktadır:

1. Döşemelik tahta görüntüsünün histogramının elde edilmesi
2. Uygun eşik değeri T'nin seçilmesi
3. T değerine göre ikili görüntünün elde edilmesi
4. Sonuçlar kabul edilebilir seviyede ise görüntünün kaydedilmesi, aksi takdirde 2-4 arası işlemlerin tekrarlanması sağlanması gerekir.


Iteratif eşik değer belirleme yöntemi ile her bir görüntü için hesaplanan eşik değeri Çizelge 4.2'de ve iteratif yöntem uygulanarak eşiklenmiş görüntüler Şekil 4.6, Şekil 4.7 ve Şekil 4.8'de verilmiştir.

Çizelge 4.2 İteratif yöntem ile eşik değeri karşılaştırılması

	Eşik Değeri
Şekil 4.3	0.54
Şekil 4.4	0.56
Şekil 4.5	0.55



Şekil 4.6 Parlaklık ve karşıtlık değerine göre eşiklenmiş görüntüler:
a) Orijinal görüntü, b) Eşiklenmiş görüntü



Şekil 4.7 Parlaklık ve karşıtlık değerine göre eşiklenmiş görüntüler:
a) Orijinal görüntü, b) Eşiklenmiş görüntü



Şekil 4.8 Parlaklık ve karşıtlık değerine göre eşiklenmiş görüntüler:
a) Orijinal görüntü, b) Eşiklenmiş görüntü

4.3.2. Minimum çapraz entropisi yöntemi ile eşikleme sonuçları

Bilgi teorisinde (Shannon, 1948), bir görüntüyü kodlaması gereken sembolün ortalama sayısının alt sınırını ifade eden temel kodlama teorisine entropi denilmektedir:

$$H(P) = - \sum_{i=1}^k p(x_i) \log p(x_i) \quad (4.5)$$

Eş. (4.5)'de olasılıklar bağımsız ve toplamı 1 olacak şekilde olasılık dağılımı $P = p(x_1), p(x_2), \dots, p(x_k)$ ile k tane sembol olduğunu göstermektedir. Entropi ile ilgili farklı tanımlamalar bulunmaktadır. Teahan'a göre entropi bir sembolün seçiminde belirsizliğin katkısının ne kadar olduğunu ölçümüdür. Dunham'a göre entropi aynı zamanda eldeki bilginin sayısal hale dönüştürülmesidir (Dunham, 2003). Fiske'ye göre ise entropi beklentisizliğin en büyük değere çıkartılmasıdır (Fiske, 1988). Eş. (4.5), L olasılık dağılımı ile en genel durum için genişletilebilir:

$$H(L) = \lim_{m \rightarrow \infty} - \frac{1}{m} \sum p(x_1, x_2, \dots, x_m) \log p(x_1, x_2, \dots, x_m) \quad (4.6)$$

Görüntü uzunluğu çok geniş olduğunda entropiyi sınırlandırmak için Eş. (4.6)'daki formül uygulanabilmektedir. Genellikle doğru olasılık dağılımı L bilinmemektedir. Ancak, $H(L)$ üst sınırı L'ye bir yaklaşım olarak bir M modeli kullanılarak elde edilebilmektedir.


$$H(L, M) = - \sum p_M(x_1, x_2, \dots, x_m) \log p_M(x_1, x_2, \dots, x_m) \quad (4.7)$$

Burada doğru model $p(x_1, x_2, \dots, x_m)$ ve olasılıklar $p_M(x_1, x_2, \dots, x_m)$ modeli tarafından hesaplanmaktadır. $H(L, M)$ karşılık entropisi olarak adlandırılmaktadır ve daima $H(L)$ entropisine eşit veya daha büyüktür.

Çizelge 4.3 minCE yöntemi ile elde edilen eşik değerleri

	Eşik Değeri
Şekil 4.6. sol	135
Şekil 4.6 orta	133
Şekil 4.6 sağ	121

Şekil 4.9 b)'deki minCE yöntemi ile elde edilen sonuç, gri formattaki görüntü piksel değerleri eşik değerden küçük olanlar beyaz renge, büyük olanlar siyah renge dönüştürülerek ikili formata çevrilmiştir. Otomatik olarak elde edilen eşik değerleri Çizelge 4.3'de verilmiştir.



Şekil 4.9 minCE yöntemine göre eşiklenmiş görüntüler: a) Orijinal görüntü, b) Eşiklenmiş görüntü

4.3.3. Otsu yöntemi ile eşikleme sonuçları

İkili tonlama veya eşikleme renksiz (gri tonlanmış) bir resmin ikili (siyah-beyaz) uzaya dönüştürülmesidir. İkili görüntüler, genel olarak renksiz(gri) görüntü 0-255 arasında bir değerlere sahip olan tezde işlemleri daha da hızlandırmamızı sağlayan 0 ve 1 değerlerine sahip piksellerden oluşan görüntülere denilmektedir. İfade edilen 1 ve 0 rakamlarından oluşan pikseller için seçilecek olan bir T değerine göre, görüntü Eş. 4.8.'te belirtilen ifadeler doğrultusunda oluşturulmaktadır (Boztoprak, 2007).

$$yeniresim(x,y) = \begin{cases} 0 & \text{eğer } resim(x,y) < T \\ 255 & \text{eğer } resim(x,y) > T \end{cases} \quad (4.8)$$

Oluşturulan T değeri görüntü üzerindeki istenen nesneler için kritik önem

taşımaktadır. Nobuyuki Otsu (1979) yılında geliştirilen ve görüntü eşiklemek için öne sürülen otsu metodu (Anonim, 2013) ile görüntü üzerinden hesaplanmaktadır. Belirtilen otsu yönteminde 0 ve 1'lerden oluşan iki sınıf arasındaki beklenen değeri maksimum yapacak değeri bulmaya çalışılmaktadır. Beklenen değer belli bir sayı dizisi olabilir. Beklenen değer dizinin aritmetik ortalaması etrafındaki dağılımını yorumlanabilmesini sağlayabilecek bir ölçüdür. Değerlerin dizi içerisindeki ortalamaya yakın olup olmadığı beklenen değere bakılarak görülebilmektedir. Eş. (4.9)'da N uzunluklu dizi için beklenen değer hesaplama formülü verilmiştir (Boztoprak, 2007).

$$\sigma^2 = \sum_{i=0}^{N-1} (x_i - \bar{x}) Pr(x_i) \quad (4.9)$$

$Pr(x_i)$ ifadesi x_i nin gelme olasılığını temsil eder. N uzunluklu dizi için bu değer $1/N$ dir. $M \times N$ boyutlarına sahip bir görüntü için histogram değerlerinden oluşan dizi hesaplandıktan sonra i değerinin gelme olasılığı $histogram[i]/(M \times N)$ dir. Sınıflar arası beklenen değer Eş. (4.10-14)'deki formüller ile bulunmaktadır.

$$\sigma_s(t) = \sigma - \sigma_b(t) = w_1(t) * w_2(t) (\mu_1(t) - \mu_2(t)) \quad (4.10)$$


$$w_1(t) = \sum_0^t Pr(i) \quad (4.11)$$

$$w_2(t) = \sum_0^{255} Pr(i) \quad (4.12)$$

$$\mu_1(t) = \sum_0^t Pr(i) X(i) \quad (4.13)$$

$$\mu_2(t) = \sum_0^{255} Pr(i) X(i) \quad (4.14)$$

Eş. (4.10-14)'daki formüllerde u sınıf ortalamalarını, w sınıfların olma olasılığını temsil etmektedir. $X(i)$ i . renk seviyesidir. Yazılan yöntem, $t = 0$ ilk değer ile başlayarak 255' e kadar her değer için sınıflar arası beklenen değeri hesaplamakta ve en son maksimum beklenen değeri veren T değerini eşik değeri olarak döndürmektedir (Abacı, 2012). Otsu yöntemi renksiz görüntüler üzerinde çalıştığından renkli görüntüler $gri = 0.2989 * kırmızı + 0.5870 * yeşil + 0.1140 * mavi$ formülü ile gri seviyeye tonlanmış ardından hesaplamalar yapılmıştır.



Şekil 4.10 Otsu yöntemine göre eşiklenmiş görüntüler: a) Orijinal görüntü, b) Eşiklenmiş görüntü

Otsu yöntemi ile elde edilen eşik değerleri görüntüyü gri formattan ikili formata çevirirken Çizelge 4.4'deki sonuçlar kullanılmıştır.


Elde edilen sonuçlar doğrultusunda döşemelik ahşapların TS 11970 standardına uygun olarak kalite sınıfı belirlenmesinde eşik değer belirleme yöntemleri değerlendirilmiştir. Deneysel çalışmalar sonucunda en iyi sonucu iteratif eşik değer belirleme yöntemi vermiştir. Iteratif eşik değer belirlemeden sonra en iyi başarıyı parlaklığa göre yapılan eşik değeri belirleme yöntemi sağlamıştır. Ancak bu yöntem bazı döşemelik ahşap görüntülerinde önemli bilgilerin kaybına sebep olmuştur. Bu yüzden TS 11970 ve TS EN 13990 standartlarına göre kalite sınıfı belirleme de iteratif yöntem kullanılmıştır.

Çizelge 4.4 Otsu yöntemi ile elde edilen eşik değerleri

	Eşik Değeri
Şekil 4.7 sol	0.46
Şekil 4.7 orta	0.54
Şekil 4.7 sağ	0.52

4.4. Bağlantı Bileşen Analizi ile Etiketlenmiş Görüntülerin Deney Sonuçları

Siyah beyaz bir görüntü içerisindeki nesnelerin birbiri ile hiçbir piksel komşuluğu olmayanların farklı renklere boyanmasına etiketleme denir. Böylece görüntü içerisindeki bu nesnelerin birbirinden ayrılması sağlanmıştır (Sonka vd., 2008). Boyama işlemini gerçekleştirebilmek için, siyah beyaz bir görüntü sol üst köşesi (0,0) orijin noktasından itibaren başlamak suretiyle piksel piksel taranmaktadır. Taranan görüntü üzerinde arka alan siyah ve nesneler beyaz renktedir. Eşitlik tablosundaki bilgiler ışığında tarama sonucuna göre hangi etiketlerin aynı nesneyi temsil ettiği tespit edilmektedir. Görüntü içerisinde birbirleri ile piksel komşulukları olmayan tüm nesneler tarama işlemi tamamlandıktan sonra etiketlenmiş ve aynı zamanda farklı bir renge boyanmış olmaktadır. Etiketleme işlemi sonunda birbirine piksel komşuluğu olmayan görüntü içerisinde bulunan etiket numaraları farklı bölgelerin sayısının tespiti görüntü içindeki kaç nesne olduğunu bildirmektedir. Bu işlemler sonucunda görüntü içerisindeki nesneler otomatik olarak tespit edilmiş olmaktadır.




Şekil 4.11. TS 11970 standardına göre işlem adımları: a) Orijinal görüntü b) İteratif yöntemle eşiklenmiş görüntü c) Görüntünün birden çıkarılması, d) Görüntünde beyaz kısımlarının doldurulması.

Etiketleme işlemi yaparak görüntü içerisinde birbiri ile bağlantılı tüm nesnelerin sayısının ve boyutunun bulunması sağlanmıştır. Aynı zamanda bağlantı bileşen analizi ile istenmeyen bölgelerin ortadan kaldırılması sağlanmıştır (Şekil 4.11).

Görüntünün birden çıkarılması ile kenar budaklar yok olmaktadır. Bundan dolayı bu işlem basamağı kenar budaklı görüntülerde uygulanamamıştır.

4.5. Medyan Filtreleme ile Gürültü Temizleme Deney Sonuçları

Medyan filtreleme, doğrusal olmayan bir işlemdir, lineer filtreleme tekniklerinden daha seçici bir sonuç elde etmeye yarar, dürtü gürültülerinin temizlenmesinde klasik bir yaklaşımdır. Medyan filtreleme yönteminde, görüntüdeki piksel komşularının arasındaki ortanca değere bakılmaktadır. Bu ortanca değeri hesaplanırken önce piksel komşuluk değerleri sıraya konulmaktadır. Bu sıralamaya göre ortadaki değer alınarak sonuç olarak kabul edilmektedir. Ortanca değeri tam olarak elde edebilmek için tek sayıda komşu seçilmektedir. Bunun aksine çift sayıda komşulukta ortada kalan iki pikselin aritmetik ortalaması alınmaktadır. Uzaysal çözünürlüğü bozmadan, tezde bağımsız nokta veya küçük gürültüleri temizleyebilmek için tercih edilmiştir.




Şekil 4.12 Medyan filtreleme a) İki tonlu görüntü b) Gürültüler temizlenmiş görüntü

Burada aynı zamanda morfolojik işlemler de uygulanmıştır. Bu morfolojik işlemlerle beyaz bölgelerin içindeki siyahlıklar giderilmektedir.


4.6. Ahşap Görüntüleri Üzerindeki Nesnelerin İşaretlenmesi

Şekil 4.12'deki görüntüde nesneler etiketlendikten sonra her bir nesnenin merkezi koordinatları, alanı ve dış sınır çizgi özellikleri elde edilmiştir. Bu özelliklere göre Şekil 4.13'de açık bir şekilde görüldüğü gibi nesnelerin etrafında dikdörtgen şeklindeki kutucukların oluşması sağlanmıştır.



Şekil 4.13. Ahşap üzerindeki budak olma ihtimali olan nesnelerin etiketlenmesi

4.7. TS 11970 Standardına Göre Deney Sonuçları



Şekil 4.14. TS 11970 göre deney sonuçları

Şekil 4.13'deki görüntü üzerinde kutulanmış nesnelerin alan, çap değerleri hesaplanmıştır. Hesaplanan alan değer aralıklarına göre;

1. 2000'den büyük alanlar (İnşaatlık)
2. 1500 ile 2000 arası olanlar (3.Sınıf)
3. 1000 ile 1500 arası olanlar (2.Sınıf)

4. 500 ile 1000 arası olanlar (1.Sınıf)
5. 500'den küçük olanlar (Süper)

olmak üzere 5 farklı alan aralığı tanımlanmıştır.

Bu alan aralıklara giren budak büyüklükleri TS 11970 standartça döşemelik tahta için Süper, 1.Sınıf, 2.Sınıf, 3.Sınıf ve İnşaatlık olarak tanımlanan kalite sınıfının müsaade ettiği yaklaşık budak kusur büyüklükleridir. Şekil 4.14'de bu alan aralıklarına girmiş olan nesnelerin renkli orijinal görüntüdeki karşılığında kırmızı değerine bakılmaktadır. Bu bölgede kırmızı değeri deneyler sonunda ortalaması 138 ve standart sapması 28'den büyük ise büyük çoğunlukla nesne budak olduğu görülmüştür. Bizde bu bölgeyi budak olarak tanımladık. Belirtilen bölge iteratif eşikleme ile ikilileştirilmiştir. Daha sonrasında bağlantı bileşen analizi ile bu bölgenin öznitelikleri çıkarılmıştır.

4.8. Budak Tip Belirleme


Döşemelik tahta görüntülerinde yapılan deneyler sonucunda Eş.4.15-17 deki formüller elde edilmiştir.

$$g(x,y) = \begin{cases} T_1, f(x,y) \geq 70 \\ T_1, f(x,y) < 70 \end{cases} \quad (4.15)$$

$$T_1 = ((\mu_1 + \mu_2) * 0.30) \quad (4.16)$$

$$T_2 = ((\mu_1 + \mu_2) * 0.60) \quad (4.17)$$

$f(x,y)$ döşemelik tahta görüntüsü, μ_1 parlaklık değeri, μ_2 karşıtlık değeri, T_1, T_2 eşik değeri, $g(x,y)$ iki tonlu yeni görüntüyü temsil etmektedir.



Şekil 4.15 Tip tanımlaması: a) Orijinal görüntü, b) Etiketlenmiş görüntü, c) Örüntü tanıma adımlarının tamamının uygulandığı görüntü

Döşemelik bir tahta görüntüsünde kusurlu bölge bulunması ve kusurlu bölgenin budak olup/olmadığı belirlenmiştir. Bu budak kusurunda 3. seviye iki boyutlu ayrık dalgacık yöntemi ile elde edilmiş öznitelikler kullanılarak KNN yöntemi ile


tip tanımlanması yapılmıştır. Şekil 4.15’de budak bölgelerinin öznelilikleri çıkartıldıktan sonra KNN yöntemine göre elde edilen sınıflandırma sonuçları verilmiştir.

Şekil 4.16’de görüntü üzerinde oluşabilen boşluk, delik, çukur gibi yapıların doldurulması sağlanmaktadır. Bu sayede parçalı olabilecek kusurların birleştirilmesi sağlanmaktadır.




Şekil 4.16 Döşemelik tahtanın ön işlemleri: a) Orijinal görüntü, b) Gri seviye görüntü, c) Eşiklenmiş görüntü, d) Deliklerin doldurulmuş görüntü

Şekil 4.17’de etiketleme yapılarak alan değerleri 500 mm²’den büyük olan bölgelerin dışındaki alanların kaldırılması sağlanmaktadır. Bu sayede standartlarda belirtilen ihmal edilebilir kusur bölgelerinin çıkartılması sağlanmış olmaktadır.




Şekil 4.17 Etiketleme sonuçları: a) Delikleri doldurulmuş görüntü,
b) 500 mm²'den küçük olan bölgeleri kaldırılmış görüntü

Şekil 4.18'de muhtemel kusur bölgesi olabilecek bütün bölgeler etiketlenmektedir. Budak kusuru etiketlenmiş bu görüntü bölgeleri içerisinde aranmış ve çerçeve içerisine alınmıştır. Kutulanan budak kusurunun alan, çap değerleri hesaplanarak TS 11970 standartça budak kusuru ve sayısına bakılarak kalite sınıfı belirlenmiştir.



Şekil 4.18 Etiketleme işlemi a) Etiketlenmiş görüntü, b) Görüntü nesnelerinin merkez değerlerine numaralar verilmesi

Bu aşamadan sonra budak tipini tanımlamak için Şekil 4.19'de belirtilen standartlara uygun olarak tespit edilen budak bölgesi otsu eşikleme ile ikilileştirilmiştir.




Şekil 4.19 Otsu eşikleme: a) Belirtilen standartlara uygun olarak tespit edilen bir budak bölgesi, b) Otsu eşikleme yöntemi ile ikilileştirilmesi

Otomatik kusur tanıma sisteminde budak kusur bölgesi bölümlenmiştir. Bölümlendikten sonra budak kusuru etrafındaki gereksiz pikseller tanıma oranını düşürdüğünden dolayı, bu pikselleri atarak sadece budak kusur

bölgesini dikdörtgen kutu şeklinde kırpma işlemi yapılmıştır. Ancak bu sefer de her budak kusur boyutu birbirinden farklı olduğundan dolayı, boyut eşitlemek amacıyla çalışmalar yapılmıştır. Boyut eşitleme problemini çözmek amacıyla, tüm budak kusur bölgeleri kırpıldıktan sonraki boy ve enleri tespit edilerek ortalamaları bulunmuştur. Sonuç olarak bütün budak kusur bölgesi kırpıldıktan sonra ortalama boy ve en değerleri 80x52'e ölçeklenmiştir. Bu ölçekleme değeri önemlidir, rasgele bir değer verilememektedir. Bu ölçekleme değeri ile ölçeklenmiş görüntülerin eğitimi sırasında öznitelikleri çıkartılmaktadır. Bu sebepten dolayı eğitim sırasında hangi boyutta ölçekleme yapıldı ise o boyuttaki görüntülerin test işlemi sırasında özniteliklerinin çıkartılması gerekmektedir.


Şekil 4.20'de öznitelikleri çıkarıp, budak tip tanımlaması, çap ve genişliğe göre kalite belirlemesi yapılmadan kusur bölgelerini belirleme işleminin sonucu gösterilmiştir.



Şekil 4.20 Toplu olarak kusurlarının tespiti ve alan değerlerinin gösterilmesi


Belirtilen standartlara uygun olarak tespit edilen budak bölgesi ölçekleme işlemi sonrasında iki boyutlu ayırık dalgacık yöntemi ile 108 tane yaklaşım katsayıları elde edilmiştir. Elde edilen bu yaklaşım katsayıları öznitelik vektörünü oluşturmaktadır. Öznitelik vektörüne göre KNN yöntemi ile bölgenin budak tip tanıma işlemi gerçekleştirilmiştir.

Şekil 4.21'de toplu olarak kusurlarının tespiti, tip tanımlaması ve TS 11970 standardına göre kalite belirlemesi gerçekleştirilmiştir.



Şekil 4.21 Toplu olarak kusurlarının tespiti, tip tanımlaması ve TS 11970 standardına göre kalite belirlemesinin yapılması

Şekil 4.22’de toplu olarak kusurlarının tespiti, tip tanımlaması ve TS EN 13990 standardına göre kalite belirlemesi gerçekleştirilmiştir. TS EN 13990 standardında genişlik oranına bağlı olarak hesap sonucunda A sınıfı, B sınıfı ya da inşaatlık malzeme olduğuna karar verilmektedir.



Şekil 4.22 Toplu olarak kusurları tespiti, tip tanımlaması ve TS EN 13990 standardına göre kalite belirlemesinin yapılması

Şekil 4.23’de TS EN 13990 standardına göre kalitesi belirlenmiş döşemelik tahta gösterilmektedir.



Şekil 4.23 TS EN 13990 standardına göre kalitesi belirlenmiş döşemelik tahta

Şekil 4.24’de TS 11970 standardına göre kalitesi belirlenmiş döşemelik tahta gösterilmektedir.



Şekil 4.24 TS 11970 standardına göre kalitesi belirlenmiş döşemelik tahta

Şekil 4.23 ve Şekil 4.24’da açıkça görülebileceği gibi TS EN 13990 standardına göre A sınıfı bir malzeme olan bir tahta, TS 11970 standardına göre inşaatlık sınıfından bir malzeme olabilmektedir.

Şekil 4.25’de TS EN 13990 standardına göre kalitesi belirlenmiş ahşap gösterilmektedir.



Şekil 4.25 TS EN 13990 standardına göre kalitesi belirlenmiş ahşap

Şekil 4.26'de TS 11970 standardına göre kalitesi belirlenmiş ahşap gösterilmektedir.



Şekil 4.26 TS 11970 standardına göre kalitesi belirlenmiş ahşap

Şekil 4.25 ve Şekil 4.26'de açıkça görülebileceği gibi TS EN 13990 standardına göre A sınıfı bir malzeme olan bir tahta, TS 11970 standardına göre 1. sınıf bir malzeme olabilmektedir.

Tespit edilen kusur tanıma süreleri farklı veritabanlarına göre ölçülmüş ve Çizelge 4.5'da verilmiştir.


Çizelge 4.5 Kusur tanıma süreleri

Kullanılan Veritabanı / Sayı	Kullanılan Standart	Kusur Sayısı	Budak Sayısı	Tanımlanan Budak Sayısı	Tanım Oranı %	Tanım Süresi (Saniye)
Ahşap/1	13990	2	2	2	98	0.6235
"/2	13990	5	3	3	98	0.6661
"/3	13990	2	2	2	98	0.6323
"/4	13990	2	2	2	98	0.6074
"/5	13990	4	4	2	50	0.7457
"/6	13990	5	4	4	98	1.3337
"/7	13990	1	1	0	50	0.0280
"/8	13990	0	0	0	98	0.0232
Ahşap/1	11970	2	2	2	98	0.6236
"/2	11970	5	3	3	98	0.6400
"/3	11970	2	2	2	98	0.6325
"/4	11970	2	2	2	98	0.6319
"/5	11970	4	4	2	50	0.7418
"/6	11970	5	4	4	98	1.3238
"/7	11970	1	0	0	50	0.0346
"/8	11970	0	0	0	98	0.0322
Döşemelik Tahta/1	13990	13	2	2	98	0.4843
"/2	13990	7	2	2	98	0.3129
"/3	13990	6	2	2	98	0.3054
"/4	13990	4	3	2	66	0.6946
"/5	13990	5	2	3	66	0.2874
"/6	13990	8	2	2	98	0.2950
"/7	13990	3	1	1	98	0.1793
"/8	13990	5	2	1	50	0.2883
"/9	13990	12	1	0	50	0.3910
"/10	13990	13	1	2	50	0.4713
"/11	13990	9	1	0	50	0.2468
Döşemelik Tahta/1	11970	13	2	2	98	0.4665
"/2	11970	7	2	2	98	0.3232
"/3	11970	4	3	2	66	0.6498
"/4	11970	8	2	2	98	0.3351
"/5	11970	5	2	3	66	0.3044
"/6	11970	13	1	2	50	0.4984
"/7	11970	5	2	3	66	0.2658
"/8	11970	5	2	1	50	0.9534
"/9	11970	3	1	1	98	0.1691
"/10	11970	5	2	1	50	0.2418
"/11	11970	12	1	0	50	0.4121
"/12	11970	16	2	2	50	0.3414

Ortalama toplam tanıma oranı % 78,97436 dir.

4.9. YSA Kullanılarak Budak Görüntülerinin Sınıflandırılması


Ağaç kalite sıralaması, makine görü yöntemlerini temel almaktadır. Görüntü analizi ve sınıflandırma yöntemleri, “ağaç çürüğü”, “ mavi leke” ve “yarık” gibi kusurları kapsayan yöntemlerdir. Kereste tahtalarından çekilen ahşap görüntüleri kullanılarak ağaç budakları 7 sınıfa ayrılmaktadır. Bu ayırma işlemi için ilk olarak, iki boyutlu ayrık dalgacık yöntemi ile budak görüntülerinin öznitelikleri çıkartılmıştır. Sonrasında çıkartılan bu öznitelikleri, danışmanlı bir sınıflandırıcı olan geri yayımlı çok katmanlı YSA’ı ile sınıflandırılmıştır. Öznitelik çıkartılmasında Haar, Daubechies db[2-10], Bior, Coif, Symlet tipi dalgacık türlerinin sınıflandırmaya olan etkileri belirlenmiştir. Öne sürülen yöntemler, sınıflandırma oranını maksimum yapmak için seçilmiştir. Aynı zamanda endüstri uygulamalarında hesaplama zamanının önemi göz önünde bulundurularak işlem süresi bakımından inceleme yapılmıştır.



Şekil 4.27 Sistemin blok diyagramı: a) Orijinal görüntü, b) Öznitelik vektörü, c) Öznitelik vektör girişine göre ağ yapısının oluşturulması, d) Budak kusurunun bağlantı bileşen analizi ile kutulanması (Ruz, vd., 2009).


YSA sınıflandırma yöntemi ile budak görüntülerinin sınıflandırma blok şeması Şekil 4.27’de verilmiştir. Blok diyagramda giriş görüntüsü üzerinde öncelikli olarak budakların yerleri bulunmaktadır. Bulunan budak görüntüleri üzerinde ön işlem adımları uygulandıktan sonra etiketleme yöntemi ile budak bölgelerinin sınırları belirlenmektedir. Belirlenen bu bölgelerin ayrık dalgacık yöntemleri ile öznitelik vektörü 3 katmanlı 630 girişli 108 öznitelik sayısı, 20 gizli nöronlu, 180 çıkış katmanındaki nöron sayısı ve 7 sınıf sayısı olmak üzere elde edilen bir ağ yapısı ile sınıflandırılmaya çalışılmaktadır.

Uygulamada; orijinal budak görüntüleri Oulu Üniversitesinin budak veri tabanından (Silven , 2009) alınmıştır. Alınan her sınıf içerisindeki budak görüntüleri ağı eğitebilmek için eşitlenmiştir.



Şekil 4.28 YSA genel yapısı

Şekil 4.28’de giriş, gizli ve çıkış katmanındaki nöron sayısı verilmiştir. 108 öznitelik sayısı, 20 gizli nöron sayısı (sistemin çıktısını içerisinde saklamaktadır), 180 her bir sınıf için tanımlanmış veritabanı içindeki görüntüler, 7 istenen sınıf türü yani çıktısı anlamına gelmektedir. Ağ’ın eğitimi sonucunda eğitilen ağ kaydedilmiştir. Bu kaydedilen ağa göre, test budak görüntüleri kullanılarak Şekil 4.29’deki adımlara göre işlendiğinde % 92 oranında tanıma sağlanmıştır.



Şekil 4.29 Tanıma adımları

4.9.1. Eğitim yönteminin seçimi

Bir problem için, en hızlı olan eğitim yöntemini tespit etmek çok zordur. Bu birçok faktöre bağlıdır. Bu faktörler problemin karmaşıklığı, eğitim setindeki veri noktalarının sayısı, ağdaki sapma değerlerin ve ağırlıkların sayısı, hedeflenen hata değeri ve ağın örüntü tanımada mı yoksa fonksiyon yaklaşımında mı kullanıldığı gibi etmenlere bakılması gerekmektedir. Bu noktada değişik eğitim yöntemlerinde karşılaştırma yapılmıştır. İleri beslemeli ağlar örüntü tanıma probleminde eğitilmiştir. Uygulamamızda örüntü tanıma üzerine çalıştığımızdan dolayı 4 farklı eğitim yönteminin budak öznitelik vektörlerini sınıflandırmalarındaki başarıları karşılaştırılmıştır. Bu anlamda problemde bu belirtilen yöntemlerin hangisi en başarılı olduğu tespit edilmiştir.


Farklı eğitim yöntemleri kullanılarak elde ettiğimiz ağ eğitim sonuçları Çizelge 4.6'da verilmiştir. Burada öznitelik sayısı 108, adım sayısı 4000 olarak uygulanmıştır.

Çizelge 4.6 Budakların sinir ağları ile sınıflandırma sonuçları

Yöntem	Eğitim süre(sn)	Eğitim (%)	Test (%)
Ölçeklenmiş Eşlenik Eğitim (trainscg)	508.12	97.6190	91.2698
Esnek geri yayılım (trainrp)	242.35	78.7302	76.9841
Powell-Beale ile Eşlenik Eğitim (traincgb)	628.07	96.3492	89.6825
Polak-Ribière ile Eşlenik Eğitim (traincgp)	424.87	97.1429	91.7460


Ayrıca, görüntüler üzerinde dalgacık moment ailesine ait türlerde 3. seviye yaklaşım, yatay detay, dikey detay ve köşegenel detay öznitelikleri çıkartılarak grafikleri Şekil 4.30 - Şekil 4.36 aralığında verilmiştir.

Yaprak budak görüntüleri içindeki ilk budak görüntüsü, iki boyutlu ayrık dalgacık dönüşümü kullanılarak Daubechies 'db2' türünden 3. seviye yaklaşım, yatay detay, dikey detay ve köşegenel detay özniteliklerinin gösterimi Şekil 4.30'da verilmiştir.




Şekil 4.30 Yaprak budak için sinyalin yaklaşım ve detay katsayılarının:
a) Grafikselsel gösterimi, b) Enerjisinin şekilsel gösterimi

Kaynamış budak görüntüleri içindeki ilk budak görüntüsü, iki boyutlu ayrık dalgacık dönüşümü kullanılarak Daubechies 'db2' türünden 3. seviye yaklaşım, yatay detay, dikey detay ve köşegenel detay özniteliklerinin gösterimi Şekil 4.31 verilmiştir.




Şekil 4.31 Kaynamış budak için sinyalin yaklaşım ve detay katsayılarının:
a) Grafikselsel gösterimi, b) Enerjisinin şekilsel gösterimi

Kuru budak görüntüleri içindeki ilk budak görüntüsü, iki boyutlu ayrık dalgacık dönüşümü kullanılarak Daubechies 'db2' türünden 3. seviye yaklaşım, yatay detay, dikey detay ve köşegenel detay özniteliklerinin gösterimi Şekil 4.32'de verilmiştir.




Şekil 4.32 Kuru budak için sinyalin yaklaşım ve detay katsayılarının:
a) Grafiks gösterimi, b) Enerjisinin şekilsel gösterimi

Kenar budak görüntüleri içindeki ilk budak görüntü, iki boyutlu ayrık dalgacık dönüşümü kullanılarak Daubechies 'db2' türünden 3. seviye yaklaşım, yatay detay, dikey detay ve köşegenel detay özniteliklerinin gösterimi Şekil 4.33'de verilmiştir.




Şekil 4.33 Kenar budak için sinyalin yaklaşım ve detay katsayılarının:
a) Grafiks gösterimi, b) Enerjisinin şekilsel gösterimi

Boynuz budak görüntüleri içindeki ilk budak görüntü, iki boyutlu ayrık dalgacık dönüşümü kullanılarak Daubechies 'db2' türünden 3. seviye yaklaşım, yatay detay, dikey detay ve köşegenel detay özniteliklerinin gösterimi Şekil 4.34'da verilmiştir.




Şekil 4.34 Boynuz budak için sinyalin yaklaşım ve detay katsayılarının:
a) Grafiks gösterimi, b) Enerjisinin şekilsel gösterimi

Sağlam budak görüntüleri içindeki ilk budak görüntü, iki boyutlu ayrık dalgacık dönüşümü kullanılarak Daubechies 'db2' türünden 3. Seviye yaklaşım, yatay detay, dikey detay ve köşegenel detay öz niteliklerinin gösterimi Şekil 4.35'de verilmiştir.



Şekil 4.35 Sağlam budak için sinyalin yaklaşım ve detay katsayılarının:
a) Grafiks gösterimi, b) Enerjisinin şekilsel gösterimi

Çürük budak görüntüleri içindeki ilk budak görüntü, iki boyutlu ayrık dalgacık dönüşümü kullanılarak Daubechies 'db2' türünden 3. seviye yaklaşım, yatay detay, dikey detay ve köşegenel detay öz niteliklerinin gösterimi Şekil 4.36'de verilmiştir.



Şekil 4.36 Çürük budak için sinyalin yaklaşım ve detay katsayılarının:
a) Grafiks gösterimi, b) Enerjisinin şekilsel gösterimi

Çizelge 4.7’de belirtilen dalgacık dönüşüm yöntemlerini kullanılarak çıkartılan özniteliklerinin, Polak-Ribiére ile eşlenik eğim eğitim yöntemi ile sınıflandırma sonuçları verilmiştir. Burada öznitelik sayısı 108, adım sayısı 4000 olarak belirlenmiştir.

Çizelge 4.7 Dalgacık türüne göre eğitim süresi, eğitim ve test tanıma oranları

Yöntem	Eğitim süre(sn)	Eğitim (%)	Test (%)
Db1 (Haar)	519.6	90.1587	83.9683
Db2	493.9	95.0794	88.0952
Db3	452.8	92.8700	85.5600
Db4	549.5	94.7619	88.5714
Db5	585.4	95.5556	89.3651
Db6	580.9	94.2857	88.4127
Db7	585.6	77.6190	73.9683
Db8	615.7	93.4921	86.8254
Db9	677.8	76.5079	73.4921
Db10	721.4	89.0476	84.7619
Bior1.3	623.6	96.9841	91.2698
Bior1.5	590.9	94.7619	89.5238
Bior2.2	530.4	97.6190	91.1111
Bior2.4	594.6	96.1905	89.3651
Bior2.6	592.4	96.3492	88.4127
Bior2.8	619.0	92.0635	84.9206
Bior3.1	534.0	92.8571	85.5556
Bior3.3	516.0	97.9365	90.6349
Bior3.5	576.9	97.1429	89.8413
Bior3.7	654.3	93.4921	87.7778
Bior3.9	692.4	97.4603	92.2222
Bior4.4	565.0	97.3016	90.3175
Bior5.5	575.7	94.1270	89.8413
Bior6.8	638.1	94.2857	88.5714
Coif1	511.7	94.7619	86.3492
Coif2	620.4	94.7619	89.0476
Coif3	715.3	90.4762	85.2381
Coif4	774.1	95.3968	87.1429


Coif5	809.5	93.3333	86.8254
Sym2	576.3	96.0317	89.6825
Sym3	610.9	85.8730	83.8095
Sym4	570.6	97.1429	90.6349
Sym5	650.4	93.9683	89.6825
Sym6	670.9	86.6667	82.0635
Sym7	696.2	95.8730	90.6349
Sym8	767.2	92.6984	88.0952

Geri yayımlı çok katmanlı YSA, basit ve etkili öznitelikleri kullanılarak ağaç budaklarının 7 farklı budak tipini sınıflandırabilmek için test edilmiştir. Testlerin değerlendirme sonuçları göstermiştir ki en yüksek eğitim başarı oranı Bior 3.3'den çıkartılan öznitelikleri kullanılarak sağlanmıştır. Trainscg eğitim yöntemi ile eğitimde %97.61, testte %91.26 başarı oranına, traincgp'e göre eğitimde %97.14, testte %91.74 oranına erişilmiştir. Uygulama sonucuna göre eğitimde Bior3.3 (%97.93), testte Bior3.9 (%92.22) başarı oranı yakalanmıştır. Genel olarak Bior3.9 eğitimde (%97.46) ve testte (%92.22) başarı oranına ulaşılmıştır. Bu sonuçlara göre; kerestelerin budak tipine göre sınıflandırılması %92 oranında başarı ile gerçekleştirilmiştir.

4.10. Farklı Sınıflandırıcılar Kullanılarak Budak Görüntülerinin Sınıflandırılması

KNN, LDA, YSA ve BAYES sınıflandırıcılarının DM, IM, GLCM, IM+GLCM ve DM+GLCM momentleriyle ayrı ayrı elde edilmiş budak özniteliklerinin sınıflandırmasında başarı oranlarını analiz edebilmek için bir çalışma yapılmıştır.

Bu çalışmada kullanılan sınıflandırıcılar önce ayrılmış örnekler arasında farklılığı veya tiplerini belirleyebilmek için eğitilmektedir. Bir sınıflandırıcının görevi özel bir nesne ya da görüntüde ilgilenilen alanı temsil edip etmeyeceğini gösterebilmektir. Bunu başarılı bir şekilde yapabilmek için sınıflandırıcının önceden örnek görüntüler ile eğitilmesi gerekmektedir. Ayrıntılı çalışma adımları Şekil 4.37’de verilmiştir.



Şekil 4.37 Öne sürülen çalışmanın adımları

DM, IM, GLCM, IM + GLCM ve DM + GLCM; görüntülerden öznitelikleri çıkartabilmek için kullanılmıştır. Belirtilen öznitelik çıkarım yöntemlerinden edilen öznitelik sayıları Çizelge 4.9’da verilmiştir.

Çizelge 4.8 Öznitelik çıkarım yöntemlerinden elde edilen öznitelik sayıları

Öznitelik Çıkarım Yöntemleri	Öznitelik Sayısı
DM+GLCM	116
DM	108
IM+GLCM	15
GLCM	8
IM	7

Belirtilen öznitelik çıkarma yöntemlerinden elde edilen özniteliklerin sınıflandırma yöntemlerindeki tanıma başarılarının tespiti :

$$\text{Doğruluk} = (\text{tanımlanmış budak sayısı} / \text{budak kümelerindeki toplam budak sayısı}) * 100 \quad (4.18)$$

Eş. 4.18'deki ifadeye göre sınıflandırıcıların doğruluk oranları tespit edilmiştir.

DM öznitelikleri ile elde edilen budak tanıma sonuçları Çizelge 4.10 ve 4.11'de verilmiştir.

Çizelge 4.9 1260 tane budak görüntüsünün DM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri

Yöntem	Eğitim Zamanı (sn)	Test Zamanı (sn)	Doğrulama Zamanı (sn)	Tanıma Oranı (%)	Toplam Zamanı (sn)
KNN	104.9212	7.9981	0.0035	98,00	112.9229
LDA	37.1588	25.5675	0.0038	86,74	62.7313
YSA	510.1191	25.3990	0.0186	93,09	535.5370
BAYES	34.6636	7.6586	0.0051	58,64	42.3274

Çizelge 4.10 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları

Yöntem	0(%)	1(%)	2(%)	3(%)	4(%)	5(%)	6(%)
KNN	98.00	98.00	98.00	98.00	98.00	98.00	98.00
LDA	98.00	82.77	46.66	98.00	98.00	98.00	77.77
YSA	97.77	98.00	86.66	98.00	98.00	73.33	93.88
BAYES	97.77	68.88	8.88	63.88	88.88	46.66	35.55

IM öznitelikleri ile elde edilen budak tanıma sonuçları Çizelge 4.12 ve 4.13'de verilmiştir.

Çizelge 4.11 1260 tane budak görüntüsünün IM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri

Yöntem	Eğitim Zamanı (sn)	Test Zamanı (sn)	Doğrulama Zamanı (sn)	Tanıma Oranı (%)	Toplam Zamanı (sn)
KNN	98.2031	12.1760	0.0030	98,00	110.3822
LDA	113.0480	11.5843	0.0039	32,77	124.6364
YSA	485.0677	21.2852	0.0033	54,99	506.3563
BAYES	121.3531	7.8057	0.0051	24,60	129.1641

Çizelge 4.12 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları

Yöntem	0(%)	1(%)	2(%)	3(%)	4(%)	5(%)	6(%)
KNN	98.00	98.00	98.00	98.00	98.00	98.00	98.00
LDA	84.44	57.77	7.22	26.66	19.44	26.66	7.22
YSA	93.33	68.33	50.55	93.88	0.00	6.66	72.22
BAYES	0.00	13.33	10.00	30.00	97.22	8.33	13.33

GLCM öznitelikleri ile elde edilen budak tanıma sonuçları Çizelge 4.14 ve 4.15’de verilmiştir.

Çizelge 4.13 1260 tane budak görüntüsü GLCM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri

Yöntem	Eğitim Zamanı (sn)	Test Zamanı (sn)	Doğrulama Zamanı (sn)	Tanılma Oranı (%)	Toplam Zamanı (sn)
KNN	30.3164	10.9115	0.0034	99,84	41.2315
LDA	29.5735	11.1153	0.0034	62,29	40.6924
YSA	389.6903	20.7774	0.0029	86,82	410.4707
BAYES	33.1165	7.4639	0.0038	46,18	40.5842

Çizelge 4.14 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları

Yöntem	0(%)	1(%)	2(%)	3(%)	4(%)	5(%)	6(%)
KNN	98.00	98.00	98.00	98.00	98.00	98.88	98.00
LDA	80.55	76.11	61.11	77.22	67.22	31.11	42.77
YSA	93.33	89.44	78.33	96.11	98.00	50.55	98.00
BAYES	85.00	68.88	10.55	60.55	53.33	2.22	42.77

IM+GLCM öznitelikleri ile elde edilen budak tanıma sonuçları Çizelge 4.16 ve 4.17’de verilmiştir.

Çizelge 4.15 1260 tane budak görüntüsünün IM+GLCM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri

Yöntem	Eğitim Zamanı (sn)	Test Zamanı (sn)	Doğrulama Zamanı (sn)	Tanılma Oranı (%)	Toplam Zamanı (sn)
KNN	104.6876	9.4676	0.0041	98,00	114,1595
LDA	98.7360	10.0861	0.0042	65,15	110,8264
YSA	482.6670	20.9254	0.0030	88,33	503.5954
BAYES	112.3865	6.0639	0.0041	43,56	118.4546

Çizelge 4.16 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları

Yöntem	0(%)	1(%)	2(%)	3(%)	4(%)	5(%)	6(%)
KNN	98.00	98.00	98.00	98.00	98.00	98.00	98.00
LDA	82.77	47.77	57.77	78.88	70.55	46.11	72.22
YSA	91.11	90.00	77.22	98.88	97.22	63.88	98.00
BAYES	61.11	47.22	3.88	45.55	97.22	7.22	42.77

GLCM+DM öznitelikleri ile elde edilen budak tanıma sonuçları Çizelge 4.18 ve

4.19’da verilmiştir.

Çizelge 4.17 1260 tane budak görüntüsünün GLCM+DM öznitelikleri ile eğitim, test, doğrulama ve geçen toplam zaman süreleri

Yöntem	Eğitim Zamanı (sn)	Test Zamanı (sn)	Doğrulama Zamanı (sn)	Tanım Oranı (%)	Toplam Zamanı (sn)
KNN	42.7544	15.9909	0.0036	98,00	58.7491
LDA	43.5165	16.9801	0.0053	87,37	60.5021
YSA	439.5829	21.0701	0.0029	94,99	460.6561
BAYES	42.1311	7.6326	0.0039	58,16	49.7676

Çizelge 4.18 Budakların sınıflandırma tipine göre yüzdelik tanıma oranları

Yöntem	0(%)	1(%)	2(%)	3(%)	4(%)	5(%)	6(%)
KNN	98.00	98.00	98.00	98.00	98.00	98.00	98.00
LDA	97.77	79.44	82.77	87.22	98.00	72.22	92.22
YSA	98.33	96.66	98.88	98.00	98.00	71.11	98.00
BAYES	93.88	68.88	7.77	63.88	91.66	45.55	35.55

Çizelge 4.20’de farklı sınıflandırıcı ve öznitelik çıkarma yöntemlerinin birlikte kullanılması ile elde edilen sonuçlar verilmiştir.

Çizelge 4.19 Deney Sonuçları

		Sınıflandırma Yöntemleri				Öznitelik Tabanlı Ortalama
		KNN (%)	BAYES (%)	YSA (%)	LDA (%)	
Öznitelik Çıkarma Yöntemleri	DM	98,00	58,64	93,09	86,74	84,11
	IM	98,00	24,6	54,99	32,77	52,59
	IM+GLCM	98,00	43,56	88,33	65,15	73,76
	DM+GLCM	98,00	58,16	94,99	87,37	84,63
	GLCM	98,00	46,18	86,82	62,29	73,32
Sınıflandırma Tabanlı Ortalama		98,00	46,22	83,64	66,86	

Özet olarak Çizelge 4.10-4.20 aralığındaki tablolarda eğitim/test sürelerinin yaklaşık olarak aynı olmasına karşın sınıflandırma doğruluğu açısından KNN sınıflandırıcısının diğer sınıflandırıcılardan daha başarılı olduğu gözlemlenmiştir. KNN sınıflandırıcısı, GLCM yöntemi ile çıkartılan özniteliklerinin sınıflandırılmasında %98 başarı oranına erişmiştir. DM, IM, IM+GLCM ve DM+GLCM öznitelik çıkarma yöntemleri ile edilen öznitelikler ise KNN sınıflandırma yöntemi ile elde edilen sonuçları LDA, YSA ve BAYES sınıflandırıcıları ile elde edilen sonuçlara göre daha yüksek başarı oranı vermiştir.

4.11. Döşemelik Tahtalardaki Budakların Analizi

İçinde bulunduğumuz Akdeniz bölgesinde yaygın olarak Kızılçam ağaçları bulunmaktadır. Bu ağaçlardan döşemelik tahtadan kaplama levhaya, keresteden doğramaya, reçineden sepi maddelerine kadar değişen birçok ürün elde edilmektedir. Bu ürünlerden biri de döşemelik tahtalardır. Karadeniz bölgesinin sık ağaçlı ormanlarında genellikle sarıçam ağacı yetişmektedir. Fakat sarıçam ağacının elyafı yumuşak olduğu için çürümesi ve deformasyonu daha çabuk olmaktadır. Bu yüzden doğa şartlarında reçineli olduğundan daha dayanıklı olan Kızılçam ağaçlar kereste ürünleri imalatında daha çok tercih edilir. Kızılçam budaklarının reçinesi yüksek olduğundan dolayı kolay kolay çürümez, ancak budak reçinesi kaybolmaya başladığı andan itibaren çürüme başlamaktadır. Reçineli ağaçlar özellikle Karadeniz gibi rutubetli yerlerde yayla evleri gibi mesken inşaatında daha çok tercih edilmektedir. Uzmanlar bu endüstriyel nitelikli ağaçları döşemelik tahtalarda kullanmaktadırlar. Bu kızılçam döşemelik tahtaların budakları uzmanlar Düşer ve Kaynar budak olarak iki kategoriye ayırmaktadırlar.

Isparta Yeni Sanayi Sitesinde bulunan kereste fabrikalarından alınmış döşemelik tahta kesitleri incelenmek üzere SDÜ Orman Fakültesi Orman Endüstri Mühendisliği Bölümü Laboratuvarlarına getirilmiştir. Bu kesitler uzman görüşleri ile kızılçam döşemelik tahtaların budakları görüntü işleme teknikleri ile analiz edilmiştir. Bu analiz sonucu geliştirilen sistem sonuçları uzman görüşleri arasındaki benzerlikleri ve farklılıkları analiz etmek için değerlendirmeye tabi tutulmuştur.

4.11.1. Uzman kişilerce döşemelik tahtaların sınıflandırılması

Bu alanda uzman dört farklı kişinin görüşüne başvurulmuştur.

Uzman 1:

Yrd. Doç. Dr. Ahmet Ali VAR, Süleyman Demirel Üniversitesi, Orman Fakültesi, Orman Endüstri Mühendisliği, Doğu Yerleşkesi, 32260, Isparta.

Uzman 2:

Atilla HİLAL, Hilaller Orman Ürünleri, Yeni Sanayi Sitesi 32 BlokNo:95, Isparta.

Uzman 3:

Mehmet TEKİN, Özdamar Kereste İmalat Ticaret ve San. Ltd. Şti, Yeni Sanayi Sit. Bl. No:12, Isparta.

Uzman 4:

Altınar GÜÇ, Güçlü Kereste Fabrikası, Yeni Sanayi Sitesi 33. Blok No:36, Isparta.

Kızılçam döşemelik tahtalarındaki budak kusurları belirtilen uzman kişiler tarafından, birbirinden bağımsız olarak, farklı zamanlarda değerlendirmeye tabi tutulmuştur. Bu değerlendirme sonucunda her uzmanın tespit ettiği budak sınıfları sonuçları Çizelge 4.24.'te verilmiştir.

4.11.2. Uzman sistemlerce döşemelik tahtaların sınıflandırılması

Kızılçam döşemelik tahta kesitlerindeki budak kusurları kusur tespit etme yöntemleri ile kusurlu bölgeler belirlenmiştir. Bu kusurlu bölgeler farklı ön işleme adımları ile etrafında herhangi bir boşluk kalmayacak şekilde parçalara ayrılmıştır. Bu parçalar üzerinde, elde edilen budak bölgelerinden bir veri seti oluşturulmuştur. Bu veri seti eşit bir şekilde eğitim ve test kümelerine ayrılmıştır. Test setinde kullanılan veriler, eğitim setinde kullanılmamıştır. Bu şekilde elde edilen sonuçlarda verilerin ezberlenmesi problemi ortadan kaldırılmıştır.

Düşen budak görüntüleri, 107 tane döşemelik tahta kesitinden elde edilmiştir. Elde edilen toplam düşen budak sayısı 442 tanedir. Kaynar budak görüntüleri, 114 tane döşemelik tahta kesitinden elde edilmiştir. Elde edilen toplam kaynar budak sayısı 81 tanedir. Bu görüntüler üzerinden yeniden boyutlandırma, görüntü eşikleme gibi ön adımlardan geçirildikten sonra elde edilen son görüntü üzerinden IM ve GLCM öznitelik çıkarma yöntemleri kullanılarak işlem yapılmıştır. Bu yöntemler sonunda, her bir budak görüntüsü için IM


yönteminden 7 ve GLCM yönteminden 8 tane öznitelik elde edilmiştir. Bu öznitelikler birleştirilmiştir. Birleştirilen bu özniteliklerden 10 döngüde, 4000 iterasyon, 20 gizli nöron, 442 çıkış nöronu olmak üzere 2 sınıflı ileri beslemeli geri yayımlı bir ağ yapısı oluşturulmuştur. Elde edilen ağ yapısı üzerinden eğitim işlemlerinde kullanılmayan test örnekleri test edilmiştir. Budak kusurları Tabloda Düşer Budak [0], Kaynar Budak [1] ve Düşer/ Kaynar Budak [0/1] olarak ifade edilmiştir.

Çizelge 4.24 Deney Sonuçları

Görüntü	Uzman1	Uzman2	Uzman3	Uzman4	kNN	YSA
	0	0	0	0	0	0

Deney sonuçları EK A'de verilmiştir.

Çizelge 4.24'deki sonuçlara göre dört farklı insan tarafından 249 görüntüde budak kusuru (Düşen/Kaynar Budak) 2 farklı kategori için % 79 aynı sınıfa adadıkları görülmüştür (Şekil 4.38). Uzman kişilerin tanımlama sonuçları ile KNN ve YSA yöntemleri tanımlama sonuçları karşılaştırıldığında, sonuçların birbirine yakın olup olmadığı ROC eğrisi ile belirlenmiştir.



Şekil 4.38 Aynı sınıf uzman görüşü

Uzman kişilerin tanımlama sonuçları ile KNN ve YSA yöntemleri tanımlama sonuçları karşılaştırıldığında, sonuçların birbirine yakın olup olmadığı ROC eğrisi ile belirlenmiştir.

Tez çalışmasında başvurulmuş uzman görüşlerinin ortalaması (OUG) Eş. 4.19’de verilmiş olan formül ile hesaplanmıştır.


$$OUG = (uzman1 + uzman2 + uzman3 + uzman4)/4 \quad (4.19)$$

KNN ve YSA yöntemleri ile yapılan Budak tip tanımlama sonuçları Ortalama Uzman Görüşlerine göre tanısal yeterliliğini belirlemek için ROC analizine tabi tutulmuştur.

Çizelge 4.20 Uzman görüşleri ve sistem sonuçlarına göre ROC değerleri


Sınıflandırıcı	Pozitif	Negatif	AUC
KNN	40	209	0,7187
YSA	52	197	0,6394

Test sonuç değişkenlerinin daha geniş değerleri, pozitif gerçek durum için daha güçlü kanıt göstermektedir. Pozitif gerçek durum değeri ise 1’dir. ROC analizine göre KNN yöntemi sonuçları eğrinin altında kalan alan yaklaşık olarak 0,72 çıkmıştır (Şekil 4.39). Bu bağlamda bu değer yeterli olduğu söylenebilmektedir. Diğer bir deyişle uzman görüşleri ile KNN sonuçları birbiri ile dikkate değer bir uyum sağlamıştır.



Şekil 4.39 Uzman görüşleri ve sistem sonuçlarına göre KNN yöntemi için ROC değerleri

Uzman görüşleri, YSA sonuçları ile karşılaştırıldığında eğrinin altında kalan alan, diğer deyişle ROC değeri 0,64 çıkmıştır (Şekil 4.40). Bu bağlamda uyumun vasat olduğu söylenebilmektedir. Diğer bir deyişle uzman görüşleri ile YSA sonuçları birbirleri ile orta seviyede uyum sağlamıştır.



Şekil 4.40 Uzman görüşleri ve sistem sonuçlarına göre YSA yöntemi için ROC değerleri

ROC eğrilerinden de anlaşılacağı gibi KNN yönteminin YSA yöntemine göre daha başarılı olduğu görülmektedir.

5. TARTIŞMA VE SONUÇ

Kızılçam döşemelik tahtalar üzerinde gerçekleştirilen bu tez çalışması ile sanayide üretim yapan firmaların ve bu konuda çalışma yapan akademisyenlerin görüşleri doğrultusunda kusur tanımlamada insanlar tarafından yapılan hataların ortadan kaldırılmasını sağlayacak farklı bilgisayar destekli yöntem ve teknikler kullanılarak yaygın budak kusur türleri bulunup sınıflandırılmaya çalışılmıştır.

Kereste endüstrisi döşemelik tahta imalatında tahtalardaki budak kusurlarının bulunması, incelenmesi, ön işlemlerden geçirilip, öznitelik çıkarılması, seçilmesi, dönüştürülmesi ve sınıflandırılması gibi örüntü tanıma, sinyal işleme, veri madenciliği disiplinleri ile ilgili araştırmalara katkıda bulunabilecek görüntü işleme tabanlı yazılım sal bir çalışma ortaya konmuştur.

Çalışmada farklı otomatik kusur tespit yöntemleri kullanılarak döşemelik tahtalardaki budaklar görsel olarak incelenmiştir. Ayrıca döşemelik tahtalardaki budak kusurlarının tespitinin yapılmasında bu konuda uzman kişilerin görüşleri de incelenmiştir. Böylece döşemelik tahtaların sınıflandırılmasında insan kaynaklı hataların azaltılmasına yönelik bir görüntü işleme tabanlı yazılım yöntemi geliştirilmiştir.

Geliştirilen yöntemde döşemelik tahtaların kalite faktörüne göre sınıflandırılmasında TS 11970 (1996) ve TS EN13990 (2006) standartlarına göre belirlenmiş kurallar uygulanmıştır. Uygulamada döşemelik tahtalar %98’lik bir doğrulukla gerçekleştirilmiştir. Fakat TS EN13990 (2006) standarttı TS 11970 (1996) standardına göre budak kusurunun sınıflandırmaya etkisi yaklaşık olarak % 5.7 olduğu görülmüştür.

Belirtilen standartlara göre sınıflandırma sonuçları elde edilmeden önce, döşemelik tahtalar bazı ön işlemlerden geçirilmiştir. Otsu yöntemi ile elde edilen eşik değerlerine göre döşemelik tahtaların TS 11970 (1996) standardına uygun olarak kalite sınıfı belirlenmeye çalışılmıştır. Fakat, deneysel çalışmalar

neticesinde ön ve arka plandaki kusurları en belirgin şekilde ortaya çıkmasını sağlayacak iteratif eşik değeri belirleme yöntemi olduğu tespit edilmiştir.

Ön işlem adımından sonra morfolojik yöntemler ile döşemelik tahtalar üzerinde budak kusur yerleri tespit edilmiştir. İlerleyen adımlarda ise farklı öznelik çıkarma yöntemlerinin farklı sınıflandırıcılardaki başarı çizelgeleri çıkartılmıştır. Uygun ışık, parlaklık, karşıtlık ve aynı açıda çekilmiş budak veritabanları temel alınarak yapılan budak tip belirleme işlemleri gerçekleştirilmiştir. Belirtilen şartlar altında dalgacık türüne göre etkili öznelikler kullanılarak ağaç budakları 7 farklı budak tipinde test edilmiştir. Test değerlendirme sonuçları göstermiştir ki Bior 3.3. öznelikleri ile en yüksek eğitim başarı oranı sağlanmıştır. Trainscg eğitim yöntemi ile eğitimde %97.61, testte %91.26 başarı oranına, traincgp'e göre eğitimde %97.14 , testte %91.74 oranına erişilmiştir. Uygulama sonucuna göre eğitimde Bior3.3 (%97.93), testte Bior3.9 (%92.22) başarı oranı yakalanmıştır. Bu sonuçlara göre; kerestelerin budak tipine göre sınıflandırılması %92 oranında başarı ile gerçekleştirilmiştir.

Isparta Yeni Sanayi Sitesinde bulunan kereste fabrikalarından rutubete ve çürümeye dayanaklı düşer ve kaynar olmak üzere iki budak türüne sahip kızılçam ağacından elde edilmiş döşemelik tahta kesitleri temin edilerek budak görüntüleri alınmıştır. Elde edilen görüntüler uzman görüşlerine göre kızılçam döşemelik tahtaların budakları görüntü işleme teknikleri ile tanımlanmıştır. Bu tanımlama sonuçları ile uzman görüşleri karşılaştırılmış; analiz sonucunda uygun değerler elde edilmiş ve döşemelik tahta görüntüleri yüksek oranda başarı ile budak yerleri tespit edilerek tanımlanmıştır. Bunun yanı sıra uygun değerlere sahip olmayan farklı açılardan görüntüsü alınmış döşemelik tahtaların budak tipi belirlemesinin zor olduğu ama yerinin tespit edilebildiği görülmüştür. Aynı zamanda uygun değerlere sahip döşemelik tahtalardaki budak görüntüleri 7 farklı tipe %92 başarı oranı ile sınıflandırılmıştır. Ancak, uygun değerlere sahip olmayan döşemelik tahta görüntülerindeki budak kusurları 2 farklı tipe %72 başarı oranında tespit edilmiştir.

Uygun deęerlere sahip olmayan dşemelik tahtalar zerinde yapılan Uzman grşlerine gre sistem sonularına bakıldığında; KNN ynteminin ROC deęeri yani eęrinin altında kalan alan yaklaşık olarak 0,72 çıkmıştır. Bu bağlamda bu deęerin yeterli olduęu sylenebilmektedir. Dięer bir deyişle uzman grşleri ile KNN sonuları birbiri ile dikkate deęer bir uyum saęlamıştır. Uzman grşleri, YSA sonuları ile karşılaştırıldığında ise eęrinin altında kalan alan, dięer deęişle ROC deęeri yaklaşık olarak 0,64 çıkmıştır. Bu bağlamda YSA sonularının Uzman grşne gre yeterli olmadığı sylenebilmektedir.

Alapuranen ve Westman (1992), yaptıkları alıřmada aęa kusurlarını grsel olarak inceleyebilecek prototip bir yazılım sistemi geliřtirmeye alıřmışlardır. Bu sistemde, blmlemenin ok katmanlı blgesel geliřim tipi olarak tanımlanan yeni hiyerarşik vektr baęlantılı bileřenli blmleme yaklařımını kullanmışlardır. Bu blmleme yaklařımı klit, metrik ve RGB renk vektr farklılıkları ve sınıflandırmada geometrik, renk ve yapısal znitelikler kullanılmıştır. Tezde ise bunlara ek olarak dalgacık moment, GLCM, IM, belirtilen zniteliklerin birlikte kullanılması ve morfolojik etiketleme ile elde edilen fiziksel znitelikler kullanılmıştır. Alauranen ve Westman (1992), muhtemel kusurları sınıflandırabilmek iin saf KNN ve 3 komşulu KNN sınıflandırıcı kullanmışlardır. Tezde ise 4 farklı sınıflandırıcı kullanılmıştır. Alauranen ve Westman (1992), kontrplak tahtaları kullanılarak yaptıkları sistemi test etmişlerdir. Belirtilen tahtalar zerindeki deneysel alıřmalarda kusur tipine gre %85-90 oranında doęruluk oranı elde etmişlerdir. Pratikte, sınıflandırıcının eęitim ařamasında en zor problemlerinden biri farklı kusur tiplerinin geniř bir şekilde deęişken olma olasılığıdır. Bu sebeple ortaya ıkan problemleri ortadan kaldırabilmek iin en geniř k deęerleri semişlerdir. k komşu deęerini 3 seerek 600 kusurun doęru bir şekilde sınıflandırılması rk budaklarda %92, saęlam budaklarda %88 bařarı oranı elde etmişlerdir. Tezdeki alıřmada ise k komşu deęeri 1 seilerek budak veritabanında %98'lik, dşemelik veritabanında %72'lik bařarı elde edilmiştir. %98 oranı ile %72'lik bařarı oranı arasında meydana gelen bořluęu doldurabilmek iin uygun teknoloji ile donatılmış ahřap izleme sisteminin kurulması gerekmektedir.

Srikanteswara (1997), yaptığı çalışma ile karşılaştırıldığında tezde kümeleme tabanlı danışmansız bir yaklaşım yerine danışmanlı KNN, YSA gibi sınıflandırıcılar kullanılmıştır. Mevcut GLCM, IM, DM'ye ek olarak melez öznitelik çıkarım yöntemleri kullanılmıştır. Bu yöntemlerden başarılı sonuçlar elde edilmiştir.

Ünsalan ve Erçil (1997), tahta yüzeylerin nitelik belirlenmesi problemini incelemişler, ancak tezde yapılan çalışmaların aksine budak veya diğer kusur tiplerinin tip tanımlaması konusuna değinilmemiştir. Yaptıkları deneysel çalışmada çeşitli doku analiz yöntemleri araştırarak tahta öznitelikleri ve hatalı yüzeylerin sınıflandırılması için farklı yöntemler sınıamışlardır. Tezde ise budak ve tahta yüzey veritabanında yöntemler ayrı ayrı incelenmiştir.

Bond (1998), yaptığı çalışmada renk, şekil ve yoğunluk parametre bilgilerini kullanmak ile yetinirken, tezde yapılan çalışmada fiziksel parametreler, GLCM, DM, IM, GLCM+IM, DM+GLCM gibi yöntemler ile elde edilen öznitelikler kullanılmıştır. Bond (1998), budak sınıflandırmada %90'lık, tez de yapılan çalışmada KNN sınıflandırma yöntemi ile %98'lik bir başarı oranı elde edilmiştir.

Kauupinen (1999), yaptığı çalışmada renkli öznitelikler ile gri seviye öznitelikler kullanarak ağaç incelemesi yapmıştır. Gri seviye öznitelikler ile daha iyi sonuçlar elde ettiğinden bahsetmektedir. Bu tespit tezde, budak kusur tespitinde RGB renk kanalları üzerinde çalışmamızı sağlayan önemli bir bilgi olmuştur.

Bharati (2002), çalışmasında gerçek zamanlı görsel inceleme yaparken tezde önceden elde edilmiş görüntüler üzerine deneysel çalışmalar yapılmıştır. Daha sonra yapılacak çalışmalarda görsel inceleme sistemleriyle endüstriyel işlemlerin gerçek zamanlı izlenmesi, geri besleme kontrollerinin sağlanmasını sağlayan yöntemler ile tezdeki çalışmaların birleştirilmesi akademik ve sanayi alanlarında öneme sahip olacağı görülmektedir.

Niskanen (2003), Bharati'nin yaptığı çalışmaya benzer şekilde gerçek zamanlı çalışabilecek bir sistem geliştirmeye çalışmıştır. Tezde yapılan çalışmaların aksine danışmanlı öğrenme ile sınıflar eğitim için ayrılan örneklerden otomatik olarak öğretilmeye çalışılmaktadır. Bu yaklaşımda ilk problemin eğitim görüntülerini etiketlemenin hatalı, tutarsız ve yorucu olmasından bahsedilmektedir. Tez de ise budak veritabanındaki tüm görüntüler etiketli bir şekilde önceden ayrılmıştır. Bu ayrılmış görüntüler üzerinden elde edilen ağ ile test işlemleri ve tahta yüzeyinden budak kusuru tespit edilerek kopartılan görüntüden budak kusur tip tanımlaması yapılmaya çalışılmıştır. Niskanen (2003) ise verileri etiketlemeksizin danışmansız bir yaklaşım gerçekleştirmeye çalışmıştır.

Silven vd. (2003), çalışmasında tezdeki çalışmaların aksine bazı ahşap kusurları tanımlamak ve tespit etmek için danışmansız kümeleme tabanlı bir yaklaşım öne sürmüşlerdir. Sert ahşap ve kusurları arasında ayırım için deneysel çalışmalar gerçekleştirmiş, ancak tezde bahsedilen kusur tipleri için herhangi bir yöntem geliştirmemişlerdir.

Aydın (2004), tezdeki yazılım tabanlı çözüm önerilerinin aksine sensörlerin kombinasyonu ile daha güvenilir ve hassas kusur tarama sistemleri geliştirmeye çalışmıştır. Bir anlamda sensörler ile odunda doğal oluşan renk, şekil ve yoğunluk farklılıkları esasına göre odun kusurlarını ve bu kusurların yerlerini belirlemek için deneysel çalışmalar yapmıştır. İleride yapılacak çalışmalarda hem sensörler aracılığıyla hem de tezde gerçekleştirilen yazılım tabanlı çözümler ile sonuçlar doğrulama yaptırılarak kusur bölgeleri ve tip tanımlamaları daha yüksek başarı oranı ile gerçekleştirilebileceği düşünülmektedir.

Cavalin vd. (2006), tezdeki çalışmaların aksine gri ölçekli görüntülerden çıkartılmış öznelilikler kullanılarak ahşaplardaki kusurları tespit edebilme problemine yoğunlaşmışlardır. Öznelilik veri seti elde ediminde sadece GLCM tekniği kullanılmıştır. Tezde ise GLCM, IM, DM, GLCM+IM, GLCM+DM teknikleri kullanılmıştır. SVM ve YSA yöntemleri elde edilen öznelilikleri

sınıflandırabilmek için kullanılmıştır. Tezde ise YSA, KNN, BAYES ve LDA kullanılmıştır. Ahşap kusur tespiti için yapılan deneysel çalışmalarda, gri ölçekli görüntülerden elde edilen özniteliklerin renkli görüntülerden elde edilen özniteliklerinden daha başarılı olduğunu tespit etmişlerdir. Bu doğrultuda tezde gerçekleştirilen deneysel çalışmalarda da gri ölçekli ve ikili görüntüler üzerinden öznitelik çıkarma yapılmıştır.

Mu ve Qi (2008), yaptıkları çalışmada X-ray ışınları ile elde edilmiş tahta görüntüleri üzerinde çukurları, budakları ve çürümeleri tespit etmeye çalışmışlardır, tezde ise normal kamera ile elde edilmiş görüntüler üzerinde YSA, KNN, BAYES ve LDA ile sınıflandırmaya çalışılmıştır. İleride yapılacak çalışmalarda X-ray gibi farklı frekanslarda bilgi verecek kamera sistemleri kurarak kalite inceleme gerçekleştirilebilir.

Yu vd. (2009), yaptıkları çalışmada kereste tahtalarından elde edilmiş görüntülerdeki kusurları 4 farklı budak tipine ayırmaya çalışmıştır. Tez de ise 7 ve 2 farklı budak kusur tipi üzerine yoğunlaşmıştır.

Athilakshmi vd. (2010), kalite kontrol sistemlerinde en önemli bölüm olan öznitelik çıkarım yöntemine odaklanmıştır. Tez de uygulanan GLCM, IM, DM ve birleşimlerinden oluşan melez yöntemler ile en etkili ve verimli sonuçlar elde edilmeye çalışılmıştır. Görüntüleri baz alarak yapılacak kalite kontrol sistemlerinde çözülmeyi bekleyen sorunlar yaşanmıştır. Bu sorunlar görüntünün çözünürlük, renk, aydınlık, ışık ortamı gibi çevresel sebeplerden dolayı sonuçların etkilendiği tespit edilmiştir. Tezdeki deneysel çalışmaların tamamında yüksek doğruluk ve esneklikte öznitelik çıkarım yöntemleri kullanılarak döşemelik tahta yüzeylerindeki kusurlardan en önemlisi olan budakların tip tanımlaması yapılmaya çalışılmıştır. Bu deney sonuçlarını daha da hızlandırabilmek için PCA gibi boyut azaltma teknikleri, Fisher'in öznitelik seçim yöntemleri gibi onlarca öznitelik arasında en iyileri seçmemizi sağlayacak yöntemlere gereksinim duyulmaktadır. Bir adım olarak yapılan tezde ileride yapılacak çalışmalarda bu boyut azaltma ve öznitelik seçim yöntemlerine ağırlık verilmesi uygun olabilir.

Yu ve Kamarthi (2010), tezde kullandığımız iki boyutlu ayrık dalgacık dönüşümünün katsayılarından yararlanmışlardır.

Mahram vd. (2012), etkili bir örüntü tanıma sistemi oluşturabilmek için öznitelik çıkarım yöntemlerini temel almıştır. Tez de farklı öznitelik çıkarım yöntemleri kullanılarak ahşap yüzeyindeki kusurları belirleme ve tanımda etkili olduğunu görmemizi sağlamıştır. Mahram vd. (2012), çalışmasında GLCM, LBP ve istatistiksel momenler kullanmıştır. Yüksek boyutlu ağaç yüzeyleri ile çalışırken boyut azaltabilmek için PCA ve LDA yöntemleri öznitelik vektörün boyutunu azaltabilmek için kullanılmıştır. Tezde ise öznitelik boyut azaltma teknikleri kullanılmamıştır. İleride yapılacak çalışmalarda yüksek boyutlu öznitelik vektörlerinin sonuçlarını daha da kısaltabilmek için kullanılması düşünülebilir. Mahram vd. (2012), çalışmasında SVM, KNN sınıflandırıcıları kullanmışlardır. Öne sürdükleri yaklaşımlarında GLCM+LBF, GLCM+ istatistiksel momentler, LBF+istatistiksel momentler keşfedilmiştir. Tezde ise YSA, KNN, BAYES, LDA sınıflandırıcıları kullanılmıştır. Çizelge 4.10 'dan Çizelge 4.20'ye kadar DM+GLCM, DM, IM+GLCM, GLCM ve IM öznitelikleri ile elde edilen özniteliklerin sınıflandırma sonuçları verilmiştir.

Johansson vd. (2013), tezdeki normal kameradan elde edilmiş görüntüler yerine yüksek hızlı endüstriyel bilgisayar tomografisi (BT) ile elde edilmiş kerestelerin taranması yaklaşımında bulunmuşlardır. Johansson vd. (2013), %88-94 oran değerleri arasında budak tespit oranına ulaşırken, tezde %98 oranında budak yer tespiti yapılabilmektedir. Johansson vd. (2013), yaptıkları çalışmada tezde yaptığımız çalışmaların aksine tip tanımlaması konusuna değinilmemiştir.

Krähenbühl vd. (2013), tezdeki normal kameradan elde edilmiş görüntülerin aksine ağaç köklerinin üç boyutlu X-ray BT görüntülerinde budak tespiti problemi ile çalışma yapmışlardır. Bilimsel araştırma içeren, ancak herhangi bir sonuç vermeyen bir çalışma yapmışlardır. Çalışmalarının özgünlüğü görüntülerin üç boyutlu X-ray BT görüntülerinden oluşmasından kaynaklanmaktadır.

Chen vd. (2014), yaptıkları çalışmada matematiksel morfoloji ve renk farklılığını temel alan ağaç panelinin bölümlene yöntemini sunmuştur. Yaptıkları çalışmada HSI(renk, doygunluk, yoğunluk) kanallarından renk ve yoğunluk kanallarının morfolojik kenar tespitine odaklanmışlardır. Doğru kenarlarının elde edilmesi sırasında oluşan küçük piksel bloklarını kaldırabilmek için medyan filtreleme kullanmışlardır. Kenar tespitinde renk modeli kanalının karakteristik özelliklerinden yararlanılmış ve sonrasında bölgesel genişleme bölümlemesi kenar bilgisini temel almaktadır. Böylece kerestelerin kusurlu bölümleri ortadan kaldırılmıştır. Tezde ise en iyi sonuçları RGB kanalları üzerinden elde edilmiştir. Bu renk kanalları üzerinde özellikle kırmızı kanal üzerinde odaklandığımız budak faktörüne bağlı olarak kusur tespitinde en belirleyici karakteristik özellikleri vermiştir. Tezde medyan filtreleme ise ortalama olarak bütün görüntülerde elde edilen büyüklük değerinden daha küçük alan değerine sahip alanları ortadan kaldırabilmek için kullanılmıştır. Sınırların tespitinde morfolojik yöntemler ile elde edilen sınır ve koordinat bilgileri kullanılmıştır.

İleride yapılabilecek bir çalışma ile döşemelik tahtalardaki kusurların otomatik tespiti ve bu tespit edilen kusurların yok edilme işlemleri; mikroişlemci, mikro denetleyici ve programlanabilir mantık devreleri yardımıyla tezde başarılı olan DM+GLCM öznelik çıkarım ve KNN sınıflandırma yöntemi kullanılması uygun olabileceği tahmin edilmektedir. Bu yöntemler için uygun ışıklandırma ortamının sağlanması, yüklenebilecek yazılım için akıllı aygıtlarda yeterli hafızaya sahip olması gibi genel özelliklerin mevcut olması beklenir. Bunun yanı sıra CMYK, HSI, HSV, YUV, YIQ, YPbPr, xvYCC, HSL gibi renk kanalları üzerinden kusurların her biri için ayrı bir matematiksel denklem ile bu kusurların tespit edilebileceği tahmin edilmektedir.

KAYNAKLAR

- Abacı, B., 2012. Otsu Metodu ile Adaptif Eşikleme. Erişim Tarihi: 16.07.2013. <http://www.cescript.com>.
- Acar, E., Özerdem, M. S., 2012. Kızıltepe Tarımsal Alan İmgelerinin Ekinin Ürün Gelişimine Göre Sınıflandırılması. Türkiye Bilişim Vakfı, Bilgisayar Bilimleri ve Mühendisliği Dergisi, 5, 21-30.
- Alapuranen, P., Westman, T., 1992. Automatic Visual Inspection of Wood Surfaces. 11th International Association for Pattern Recognition, 1, 371 - 374.
- Anonim, 1987. El Kitab Dizisi:2 Kızılçam, Ormancılık Araştırma Enstitüsü Yayınları, Ankara.
- Anonim, 2007. Mesleki Eğitim ve Öğretim Sistemini Güçlendirme Projesi, Ahşap Teknolojisi, Ahşap Duvar Döşeme, Ankara.
- Anonim, 2012. Türkiye Orman Varlığı, Orman İdaresi ve Planlama Dairesi Başkanlığı Yayın No.: 85, Envanter Serisi No.: 12, Ankara.
- Anonim, 2013. Otsu Metodu. Erişim Tarihi:18.07.2013, http://en.wikipedia.org/wiki/Otsu%27s_method.
- Athilakshmi, R., Wahi, A., Nagarajan, B., 2010. Defect Identification of Lumber Through Correlation Technique with Statistical and Textural Feature Extraction Method. Proceedings of the International Conference on Communication and Computational Intelligence, 524-528, India.
- Avcı, A., 2006. Wavelet Dönüşümü ile Doku Öznitelikleri Çıkarılan Görüntülerin Rezonans Algoritması Kullanılarak Bölütlenmesi, Karadeniz Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 66s, Trabzon.
- Aydın, İ., 2004. Orman Ürünleri Sanayinde Otomasyon Araştırması. Kafkas Üniversitesi, Artvin Orman Fakültesi Dergisi, 1-2(40-47), Trabzon.
- Baş, N., 2006. Yapay Sinir Ağları Yaklaşımı ve Bir Uygulama. Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 114s, İstanbul.
- Beale, M.H., Hagan, M.T., Demuth, H.B., 2012. Neural Network Toolbox™ User's Guide. Erişim tarihi:12.01.2011. www.mathworks.com.
- Bharati, Manish H. 2002. Multivariate Image Analysis and Regression for Industrial Process Monitoring and Product Quality Control. Doctor of Philosophy, McMaster University, Chemical Engineering, Hamilton,

Ontario.

- Bond, Brian H. 1998. Characterization of Wood Features Using Color, Shape, and Density Parameters. Doctor of Philosophy, Wood Science and Forest Products, Virginia Polytechnic Institute, State University, Blacksburg, Virginia.
- Boztoprak, H., 2007. Gerçek Zamanlı Tasıt Plaka Tanıma Sistemi. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 70s, Isparta.
- Cavalin, P., Oliveira, L. S., Koerich, A. L., Britto, A. S., 2006. Wood Defect Detection Using Grayscale Images and an Optimized Feature Set. Institute of Electrical and Electronics Engineers, Industrial Electronics Society, - 32nd Annual Conference, 3408-3412.
- Cetişli, B., 2005. El Yazısı Karakter Tanıma Dalgacık Moment Özniteliklerinin Yenilenen Anfis ile Sınıflandırılması. Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 135s, Eskişehir.
- Chacon, M.I., Graciela, R., 2006. Wood Defects Classification Using a SOM/FFP Approach with Minimum Dimension Feature Vector. Lecture Notes in Computer Science, Springer, 3973, 1105-1110.
- Chen, L., Wang, K., X., YongHua, Wang, J., 2014. The Segmentation of Timber Defects Based on Color and Themathematical Morphology. Optik 125, 965– 967, Elsevier.
- Çatal, Y., 2009. Batı Akdeniz Bölgesi Kızılçam (*Pinus Brutia Ten.*) Meşcerelerinde Artım ve Büyüme. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi, 281s, Isparta.
- Çayırılı, M., 2006. Yanma Olayının Modellenmesi ve Görüntü İşleme Yoluyla Yanma Performansının Optimizasyonu. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 69s., Isparta.
- Çetiner, H., 2012. Görüntü İşleme Teknikleri Kullanarak Optik Karakter Tanımlama. Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 76s, Isparta.
- Demir, Ö., 2008. EEG Dalgalarının Dalgacık Dönüşümü ile Değerlendirilmesi, Dumlupınar Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 56s, Kütahya.
- Demirhan A., Güler İ., 2010. Özörgütlemeli Harita Ağları ve Gri Düzey Eş Oluşum Matrisleri ile Imge Bölütleme. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 25(2), 285-291.
- Dirican A. 1991. ROC Eğrisi Çözümlemesi ile Tanı Testlerinin Değerlendirilmesi ve Bilgisayar Uygulaması. İstanbul Üniversitesi, Sağlık

- Bilimleri Enstitüsü, Biyoistatistik ve Demografi Programı, Doktora tezi.
- Dirican, A. 2001. Tanı Testi Performansının Değerlendirilmesi ve Kıyaslanması. Cerrahpaşa Tıp Dergisi. 32, 25-30.
- Dunham, H.D., 2003. Data Mining: Introductory and Advance Topics. Upper Saddle River, NJ: Prentice Hall, 350p.
- Elmas, Ç., 2011. Yapay Zeka Uygulamaları. Seçkin Yayıncılık, 424s, Ankara.
- Erdem, O.A., Uzun, E. 2005. Turkish Times New Roman, Arial, and Handwriting Characters Recognition by Neural Network. *Journal of the Faculty of Engineering and Architecture Of Gazi University*, 20(13-19).
- Faraggi D, Reiser B. 2002. Estimation of the area under the ROC curve. *Stat Med*. 21, 3093-3106.
- Fiske, C.S., 1988. On Combing Maximum Entropy Trip Matrix Estimation with User Optimal Assignment, *Transportation Research* 22B, 69-79.
- Fukunaga, K., 1990. Introduction to Statistical Pattern Recognition., Academic Press, 592p, New York.
- Gonzalez, R. C. , Woods, R. E., 2008. Digital Image Processing. Prentice Hall, 3rd Edition, Upper Saddle River, 976p.
- Gonzalez, R. C., Woods, R. E., 2002. Digital Image Processing. Prentice-Hall, Int. Inc., Upper Saddle River, pp. 779, New Jersey, USA.
- Grove WM. 2006. Mathematical Aspects of Diagnosis. United States of America, 50-75.
- Grönlund, U., 1995. Quality Improvements in Forest Products Industry. Dissertation. Doctoral Thesis, Lulea University of Technology, pp. 234, Sweden.
- Günay, Z., 1982. Orman Ürünleri Standartları (Yuvarlak Odunlar). Saydam Matbaacılık Ofset ve Tipo Tesisleri, Ankara.
- Hanley JA, McNeil BJ. 1982. The Meaning and Use of the Area Under a Receiver Operating Characteristic Curve. *Radiology*. 143, 29-36.
- Haralick R.M., Shanmugam K., Dinstein I., 1973. Textural Features for Image Classification. *Institute of Electrical and Electronics Engineers, Transactions on Systems, Man and Cybernetics, Transactions on Systems, Man, and Cybernetics-3*(6), 610 - 621.
- Horng, M. H., Huang, X. J., Zhuang, J. H., 2003. Texture Feature Coding Method for Texture Analysis and It's Application. *Journal of Optical Engineering*, 42 (1), 228-238.

- Hu, M., 1962. Visual Pattern Recognition by Moment Invariants. *Information Theory, IRE Transactions*, 8(2), 179-187.
- Hudairy, H., 2004. Data Mining and Decision Making Support in The Governmental Sector. Louisville University, Msc. Thesis, 1-5, Kentucky.
- Jabo, S., 2011. Machine Vision for Wood Defect Detection and Classification. Chalmers University of Technology, Msc. Thesis, 92p, Sweden.
- Johansson, E., Johansson, D., Skog, J., Fredriksson, M., 2013. Automated knot detection for high speed computed tomography on *Pinus sylvestris* L. and *Picea abies* (L.) Karst. using ellipse fitting in concentric surfaces. *Computers and Electronics in Agriculture*, 238-245, Elsevier.
- Kanburoğlu, A., 2009. Rabitalı Döşeme Tavan Taban Lambri. <http://parkedekorasyon.blogspot.com>. Erişim Tarihi: 04.04.2012.
- Kauppinen, H. 1999. Development of a Color Machine Vision Method for Wood Surface Inspection. Master's Thesis, University of Oulu, Faculty of Technology, Department of Electrical Engineering, Oulu, Finland.
- Kılıç, M., Güner, Ş.T., 2000. Gölhisar Kızılçam Meşceresi. *Orman Mühendisliği*, 37 (5), 18-21.
- Kim, C.W., Koivo, A. J., 1994. Hierarchical Classification of Surface Defects on Dusty Wood Boards. *Pattern Recognition Letters*, 15,713-721.
- Kim, C. W., Koivo, A.J., 1990. Hierarchical Classification of Surface Defects on Dusty Wood Boards. 10th International Conference Pattern Recognition, 775-779.
- Krähenbühl, A., Kerautret, B., Debled-Rennesson, I., Longuetaud, F., Monthe, F., 2013. Knot detection in X-ray CT Images of Wood. *International Symposium on Visual Computing*(2), 1-10, Greece.
- Lampinen, J., Smolander, S., 1996. Self-organizing Feature Extraction in Recognition of Wood Surface Defects and Color Images. *International Journal of Pattern Recognition and Artificial intelligence*, 10(2), 97-113.
- Lampinen, J., Smolander, S., Korhonen, M., 1995. Wood Surface Inspection System Based on Generic Visual Features. *International Conference on Artificial Neural Networks*, 1-6, Finland.
- Lampinen, J., Smolander, S., Silven, O., Kauppinen, H., 1994. Wood defect Recognition:A Comparative Study. *Workshop on Machine Vision in Advanced Production*, 1-7, Finland.
- Lee, J.J., Lee, S.M., Kim, I.Y., Min, H.K., Hong, H.S., 1999. Comparison Between Short Time Fourier and Wavelet Transfrom for Feature Extraction of Heart Sound. *Institute of Electrical and Electronics Engineers Tencon*,

102, 18-55.

- Leen-Kiat S., Costas T., 1999. Texture Analysis of SAR Sea Ice Imagery Using Gray Level Co-Occurrence Matrices. Institute of Electrical and Electronics Engineers, Transactions on Geoscience and Remote Sensing, 37(2).
- Mahram, A., Shayesteh, M. G., Jafarpour, S., 2012. Classification of Wood Surface Defects with Hybrid Usage of Statistical and Textural Features. 35th International Conference on TSP, 749-752.
- Manian V., Vbsquez R., 1997. A Framework for SAR Image Classification: Comparison of Co-Occurrence and a Gabor Based Method. Institute of Electrical and Electronics Engineers, International On Geoscience and Remote Sensing, 1, 335 – 337.
- Marcano- Cedeno, A., Quintanilla-Dominguez, J., Andina, D., 2009. Wood Defects Classification Using Artificial Metaplasticity Neural Network. Industrial Electronics Society'09. 35th Annual Conference of Institute of Electrical and Electronics Engineers, 3422 – 3427.
- Marques, O., 2011. Practical Image and Video Processing Using MATLAB. Wiley-Institute of Electrical and Electronics Engineers Press, pp. 696, Singapore.
- Mercimek, M., Gülez, K., Mumcu, T. V., 2005. Real Object Recognition Using Moment Invariants. Sadhana, 30, 765-775.
- Minsky, M., Papert, S., 1969. Perceptrons. MIT Press, Cambridge, MA.
- Misiti, M., Misiti, Y., Oppenheim, G., Poggi, J.M., 1997. Wavelet Toolbox Users Guide, The Mathworks Inc.
- Mohan, S., Venkatachalapathy, K., 2012. Wood Knot Classification Using Bagging. International Journal of Computer Applications, 51(18), 50-53.
- Mu, H., Qi, D., 2008. Recognition of Wood Defects Based on Artificial Neural Network. IEEE/ASME International Conference on Advanced Intelligent Mechatronics, 1232 – 1237, China.
- Murguia, M. I. C., Ramirez, G., 2006. Fuzzy Clustering Algorithms in Subjective Classification Tasks. IEEE International Conference on Fuzzy Systems, 2309 – 2316, Canada.
- Niskanen, M. 2003. A Visual Training Based Approach to Surface Inspection. University of Oulu, Department of Electrical and Information Engineering, Oulu, Finland.
- Obuchowski NA, Lieber ML, Wians FH. 2004. ROC Curves in Clinical Chemistry:

- Uses, Misuses, and Possible Solutions. Clin Chem. 50,1118-1125.
- Obuchowski NA, McClish D.1997. Sample size determination for Diagnostic Accuracy Studies Involving Binormal ROC Curve Indices. Stat Med. 16, 1529-1542.
- Obuchowski NA. 2005. ROC Analysis. AJR Am J Roentgenol. 184, 364-372.
- Ölmez, T., Dokur, Z., 2009. Uzman Sistemlerde Örüntü Tanıma. İTÜ, Elektronik ve Haberleşme Mühendisliği Bölümü, 325s, İstanbul.
- Percival, D.B., Walden, A.T., 2002. Wavelet Methods for Time Series Analysis, Cambridge University Press, Second Edition, 594p.
- Rao, R. M., Bopardikar, A. S., 1998. Wavelet Transforms: Introduction to Theory and Applications, Prentice Hall, 336p, Massachusetts.
- Roumi, M. 2009. Implementing Texture Feature Extraction Algorithms on FPGA. Master Thesis, Delft University of Technology, Faculty of Electrical Engineering, Mathematics and Computer Science, 53p, Delfth, Netherlands.
- Ruz, G. A., Estevez, P.A., Ramirez, P.A., 2009. Automated Vsual Inspection System for Wood Defect cCassification Using Computational Intelligence Techniques. International Journal of Systems Science, 0(2), 163-172, Taylor&Francis.
- Saatçioğlu, F., 1976. Silvikültürün Biyolojik Esasları ve Prensipleri (Silvikültür I). İstanbul Üniversitesi, Orman Fakültesi Yayın No: 2187/222, 423 s. İstanbul.
- Saraç, T., 2004. Yapay Sinir Ağları. Gazi Üniversitesi, Endüstri Mühendisliği Bölümü, Basılmamış Seminer Projesi, 75s, Ankara.
- Shahnorbanun, S., Siti, S.A., Huda, N., Haslina, A., Nazlia, O., Rosilah, H., 2010. A Computational Biological Network for Wood Defect Classification. World Congress on Engineering and Computer Science, I, 978-988, USA.
- Shannon, C. E., 1948. A mathematical theory of communication. Bell System Technical Journal, 27(3), 379-423 ve 623-656.
- Silven , O., 2009. Oulu Üniversitesi Ahşap Veritabanı (Aktif). Laboratory of Wood Technology Helsinki University of Technology, Valtion Teknillinen Tutkimuskeskus Building Technology: Wood Technology, Erişim Tarihi: 09.07.2013. <http://www.ee.oulu.fi/research/imag/WOOD/>
- Silven , O., 2009. Oulu Üniversitesi Budak Veritabanı (Aktif). Laboratory of Wood Technology Helsinki University of Technology, Finland Valtion Teknillinen Tutkimuskeskus Building Technology: Wood Technology, Erişim Tarihi: 09.07.2013.

<http://www.ee.oulu.fi/research/imag/knots/KNOTS/>

- Silven, O., Kauppinen, H., 1994. Color Vision Based Methodology for Grading Lumber, Proceedings of the 12th IAPR International Conference, 1, 787 – 790, Oulu, Finland.
- Silven, O., Niskanen, M., Kauppinen, H., 2003. Wood Inspection with non-Supervised Clustering. Machine Vision and Applications, 13, 275–285, Springer-Verlag.
- Singh, R., Yadav, C. S., Verma, P., Yadav, V., 2010. Optical Character Recognition for Printed Devnagari Script Using, Artificial Neural Network, Int. J. of Comp. Sc. & Com., 1(1), pp. 91-95.
- Sonka, M., Hlavac, V., Boyle, R., 2008. Image processing. Anal. and Mach. Vision. Int. Student Edition, pp. 332-333, USA.
- Srikanteswara, S. 1997. Feature Identification in Wooden Boards Using Color Image Segmentation. Master's Thesis, Virginia Polytechnic Institute and State University, Electrical and Computer Engineering, Blacksburg, Virginia.
- Strang, G., Nguyen, T., 1997. Wavelets and Filter Banks, 400p, USA.
- Şen, Z., 2004. Yapay Sinir Ağları İlkeleri, Su Vakfı Yayınları, 7s, İstanbul.
- Tape, T. G., 2013. Interpreting Diagnostic Tests, University of Nebraska Medical Center. Erişim Tarihi: 21.11.2013. <http://gim.unmc.edu/dxtests/ROC1.htm>.
- Teahan, W. J., 2000. Text Classification and Segmentation Using Minimum Cross-Entropy. Recherche d'Information Assistee par Ordinateur, 943-961.
- Teknomo, K., 2006. K Nearest Neighbors Tutorial. Erişim tarihi: 04.08.2013. <http://people.revoledu.com/kardi/tutorial/KNN>
- TS 11970, 1996. Ahşap Döşeme Tahtaları. Türk Standartları Enstitüsü, I. Baskı, Ankara.
- TS EN 13990, 2006. Ahşap Yer Döşemesi- Masif Yumuşak Ağaç Yer Döşeme Levhaları. Ankara.
- Ünsalan, C., Erçil, A., 1997. Automated Quality Inspection of Wood Surfaces Using Texture Analysis Techniques. Proceedings of Institute of Electrical and Electronics Engineers, Signal Processing and Communications Applications, pp. 264-271, Kusadasi, Turkey.
- Ünver, S., Acar, H. H., 2005. Odun Hammaddesi Üretim Çalışmalarının Odun Kalite Sınıfları Üzerine Olan Etkileri. Kafkas Üniversitesi, Artvin Orman Fakültesi Dergisi, 6 (1-2), 128-134.

- VTT Group, 2013. Finlandiya Teknik Araştırma Merkezi. Erişim Tarihi: 12.07.2013. <http://www.cse oulu.fi/CMV>.
- Wilks, S. S., 1962. Mathematical Statistic, Princeton University Press, 98p, New York.
- Xiansheng, Q., Feng, H., Qiong, L., Xin, S.,. 2009. Online Defect Inspection Algorithm of Bamboo Strip Based on Computer Vision. Institute of Electrical and Electronics Engineers, International Conference on Industrial Technology,1-5.
- Yaltırık, F., Boydak, M., 1993. Türkiye Kızılçamlarında Genetik Çeşitlilik. Uluslararası Kızılçam Sempozyumu, Bildiriler Kitabı,1-10, Marmaris.
- Yang, J., Yu, H., Kunz, W., 2000. An Efficient LDA Algorithm for Face Recognition. 6th ICARCV, 1-6, Singapore.
- Ylakoski, I., Visa, A., 1993. A Two-Stage Classifier for Wooden Boards. Proc. 8th Scandinavian Conference on Image Analysis, pp. 637-641, Norway.
- Yu, G., Kamarthi, S.V., 2010. A Cluster-Based Wavelet Feature Extraction Method and Its Application. Engineering Applications of Artificial Intelligence, 196–202, Elsevier.
- Yu-Hua Gu, I., Andersson, H., Vicen, R., 2009. Wood Defect Classification Based On Image Analysis And Support Vector Machines. Wood Sci Technol, 44, 693–704, Springer-Verlag.
- Zekai, Ş., 2004. Yapay Sinir Ağları Ve İlkeleri, Su Vakfı Yayınları, 7s, İstanbul.
- Zhang, Z., Ye, N., 2009. A Novel Nonlinear Dimensionality Reduction Method for Robust Wood Image Recognition. Institute of Electrical and Electronics Engineers International Journal of Chemical and Biochemical Science, 533 – 536.
- Zheng, Y., Zhang, Q., 2010. Damped Newton Based Iterative Non-Negative Matrix Factorization for Intelligent Wood Defects Detection, Academy Publisher, 899-906, China.

EKLER

EK A. Deney Sonuçları

EK A. Deney Sonuçları

Görüntü		Uzman1	Uzman2	Uzman3	Uzman4	kNN	YSA
		0	0	0	0/1	0	0
		0	0	0	0/1	0	0
		0	0	0	0	0	0
		1	1	0	0	0	1
		0	0	0	0	0	0
		0	0	0	0/1	0	0

						
	0	0	0	0/1	0	1
						
	0	0	1	0	0	0
						
	0	0	1	1	0	0
						
	0	0	1	0	0	0
						
	0	0	1	0/1	0	0
						
	0	1	1	0/1	0	0
						
	0/1	1	1	1	0	0

		0	1	1	0/1	0	1
		0/1	1	1	1	0	0
		0/1	0/1	1	0/1	0	0
		0	0	1	0/1	0	0
		0	0	1	0/1	0	0
		0	1	1	0/1	0	0
		1	1	1	1	0	0

							
		0/1	1	1	0/1	0	0
							
		0	1	1	1	0	0
							
		0	0	0	1	0	1
							
		0	0	1	1	0	0
							
		0	0	0	1	0	0
							
		0	0	1	0	0	1/0
							
		0	0	1	0	0	0


							
		0	0	0	0	0	0
							
		0	0	0	0	0	0
							
		0	0	0	0	0	1
							
		0	0	0	0	0	0
							
		0	0	0	0	0	0
							
		0	0	0	0	0	0
							
		0	0	0	0	0	0

		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	1
		0	0	0	0	0	0

		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0


		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0

		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	1
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0

		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	1
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	1
		0	0	0	0	0	0

		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	1
		0	0	0	0	0	0
		0	0	0	0	0	0

						
	0	0	0	0	0	0
						
	0	0	0	0	0	0
						
	0	0	0	0	0	0
						
	0	0	0	0	0	0
						
	0	0	0	0	0	0
						
	0	0	0	0	0	0
						
	0	0	0	0	0	0

							
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0

		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	1
		0	0	0	0	0	0

		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0	0	0

		0	0	0	0	0	0
		0	0	0	0	0	0
		0	0	0	0/1	1	1
		0	0	0	0/1	1	1
		0	0	0	1	1	1
		0/1	0	1	0/1	1	0
		0	1	1	0/1	1	1

		1	1	0	1	1	0
		1	1	0	1	1	0
		1	1	1	1	1	1
		1	1	1	1	1	0
		1	1	1	1	1	0
		1	1	1	1	1	1
		1	1	1	1	1	1

		1	1	1	1	1	1
		1	1	1	1	1	1
		1	1	1	1	1	1
		1	1	1	1	1	1
		1	1	1	1	1	1
		1	1	1	1	1	1
		1	1	1	1	1	0

		1	1	1	1	0	1
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0/1
		1	1	1	1	1	0
		1	1	1	1	0	0

		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	1
		1	1	1	1	0	0/1
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	1

		1	1	1	1	1	1
		1	1	1	1	1	0/1
		1	1	1	1	0	0
		1	1	1	1	0	1
		1	1	1	1	1	1
		1	1	1	1	0	0
		1	1	1	1	0	0

		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	1	0
		1	1	1	1	0	0
		1	1	1	1	1	1
		1	1	1	1	1	0
		1	1	1	1	0	1

		1	1	1	1	1	0
		1	1	1	1	0	1
		1	1	1	1	0	0
		1	1	1	1	0	1
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0

		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	1
		1	1	1	1	0	0
		1	1	1	1	0	1
		1	1	1	1	0	0

						
	1	1	1	1	0	0
						
	1	1	1	1	0	0
						
	1	1	1	1	1	0
						
	1	1	1	1	1	0
						
	1	1	1	1	0	0
						
	1	1	1	1	0	0
						
	1	1	1	1	0	0

		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0/1
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	1	0

		1	1	1	1	1	1
		1	1	1	1	0	1
		1	1	1	1	1	1/0
		1	1	1	1	0	0/1
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0

		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	1
		1	1	1	1	0	0
		1	1	1	1	0	1

		1	1	1	1	0	1
		1	1	1	1	0	1
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	1	0
		1	1	1	1	0	0
		1	1	1	1	0	0

		1	1	1	1	1	0
		1	1	1	1	1	0
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	1	0
		1	1	1	1	0	1
		1	1	1	1	0	0


		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	1
		1	1	1	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	1
		1	1	1	1	0	0

		1	1	1	1	1/0	0
		1	1	1	1	0	1
		0	0	0	0	0	0
		0	0	0	0	0	1
		0	0	1	0	0	0
		1	1	1	1	0	0
		1	1	1	1	0	0

		0	0	0	0	1	0
		1	1	0	1	1	1
		0	0	0	0/1	0	0
		0	0	0	0/1	0	0
		1	1	0	1	0	1
		0	0	0	0	0	0
		0	0	0	0	0	0

		1	0	0	1	0	0
		1	1	1	1	0	0
		1	1	1	1	0	1
		1	1	1	1	0	0
		0	0	1	0	0	0
		1	0	0	1	0	1
		0	0	0	1	1	0

		1	1	1	0/1	1	1
		0	1	1	0/1	0	0
		0	1	1	1	0	0
		0	0	1	0	0	0
		1	1	1	0/1	0	0
		1	0	1	1	0	0
		0	0	1	1	0	0

							
		0	0	1	0/1	0	0
							
		1	0	1	1	0	0

ÖZGEÇMİŞ

Adı Soyadı : İbrahim ÇETİNER



Doğum Yeri ve Yılı : Burdur, 1976

Medeni Hali : Evli

Yabancı Dili : İngilizce

E-posta : ibrahimcetiner@sdu.edu.tr

Eğitim Durumu

Lise : Isparta Teknik Lisesi, Bilgisayar Bölümü, 1995

Lisans : SAÜ, Teknik Eğitim Fakültesi, Elektronik ve Bilgisayar Eğitim Bölümü, Elektronik Öğretmenliği, 1999

Yüksek Lisans : SAÜ, Fen Bilimleri Enstitüsü, Elektronik ve Bilgisayar Eğitimi, 2003

Mesleki Deneyim

Kocaeli/Körfez EML - Teknik Öğretmen 1999-2000

SDÜ Teknik Eğitim Fakültesi - Araştırma Görevlisi 2000-2001

SDÜ Keçiborlu MYO - Öğretim Görevlisi 2001-(halen)

Yayınları

Çetiner, H., Cetişli, B., Çetiner, İ., 2012. Gerçek Zamanlı Kimlik Numarası Tanıma. Sakarya Üniversitesi Fen Bilimleri Enstitü Dergisi, 16(2),123-129, Sakarya.

Çetiner, İ., Şimşek, M., Çalış, H., 2005. Asenkron Motorların Sensörsüz Hız Tespiti. 3.Ulusal Meslek Yüksekokulları Sempozyumu, Burdur Meslek Yüksek Okulu, Burdur.

Çalış, H., Özcerit, A.T., Çetiner, İ., 2003. Asenkron Motorların Sensörsüz Hız Tespitinin 8051 Yardımıyla Gerçekleştirilmesi. Sakarya Üniversitesi Fen Bilimleri Enstitü Dergisi, 7(3), 14-20.

Çetiner, İ., 2003. Asenkron Motorların 8051 Yardımıyla Sensörsüz Hız Tespiti. Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik-Bilgisayar Eğitimi Ana Bilim Dalı, Yüksek Lisans Tezi.

Çalış, H., Özcerit, A.T., Çetiner, İ., Gürdal, O., Çakır, A., 2003. Sensorless Speed Prediction of Induction Machines by Using Fluctuation of Zero Crossing of Motor Current. Proceedings of Third International Conference on Electrical and Electronics Engineering, Bursa.(Poster)