

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**EL ÇİZİMİ DİYAGRAMLARIN MODİFİYE DESTEK VEKTÖR
MAKİNELERİ VE GRİD TABANLI SU HAVZASI İLE TANINMASI**

Orhan NOORULDEEN

DOKTORA TEZİ
Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı

Danışman
Dr. Öğr. Üyesi Oğuz ALTUN

Ağustos, 2020

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

EL ÇİZİMİ DİYAGRAMLARIN MODİFİYE DESTEK VEKTÖR MAKİNELERİ
VE GRİD TABANLI SU HAVZASI İLE TANINMASI

Orhan NOORULDEEN tarafından hazırlanan tez çalışması 14.08.2020 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Dr. Öğr. Üyesi Oğuz ALTUN
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Dr. Öğr. Üyesi Oğuz ALTUN, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Songül VARLI, Üye
Yıldız Teknik Üniversitesi

Doç. Dr. Gökhan BİLGİN, Üye
Yıldız Teknik Üniversitesi

Dr. Öğr. Üyesi Pelin GÖRGEL, Üye
İstanbul Üniversitesi Cerrahpaşa

Dr. Öğr. Üyesi Mustafa DAĞTEKİN, Üye
İstanbul Üniversitesi Cerrahpaşa

Danışmanım Dr. Öğr. Üyesi Oğuz ALTUN sorumluluğunda, tarafımca hazırlanan “EL ÇİZİMİ DİYAGRAMLARIN MODİFİYE DESTEK VEKTÖR MAKİNELERİ VE GRİD TABANLI SU HAVZASI İLE TANINMASI” başlıklı çalışmada, veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Orhan NOORULDEEN

İmza

Çok Değerli Aileme

TEŞEKKÜR

Tezimi hazırladığım sürede gerekli önerilerde ve bana tavsiyede bulunan, rehberlik eden, yönlendiren ve katkıda bulunan değerli danışman hocam Dr. Öğr. Üyesi Oğuz ALTUN'a minnetle ve sevgiyle teşekkürlerimi sunarım. Destekleri, katkıları ve tez izleme komitesinde katılımları nedeniyle Doç. Dr. Gökhan Bilgin'e, Dr. Öğr. Üyesi TOLGA ENSARİ'ye ve Dr. Öğr. Üyesi PELİN GÖRGEL'e teşekkürlerimi sunarım.

İÇİNDEKİLER

SİMGE LİSTESİ	VIII
KISALTMA LİSTESİ	IX
ŞEKİL LİSTESİ	X
TABLO LİSTESİ	XI
ÖZET	XII
ABSTRACT	XIV
1 GİRİŞ	1
1.1 Literatür Özeti	1
1.1.1 El çizimi / Görüntü Nesne Tanıma Teknikleri	1
1.1.2 Yumuşak Hesaplama Teknikleri Kullanan Tanıma	3
1.1.3 El Çizimi Tanıma	5
1.1.4 Çıkarımlar	11
1.1.5 Araştırma Problemi	11
1.1.6 Önerilen Çözüm	11
1.2 Tezin Amacı	12
1.3 Orjinal Katkı	12
1.4 Görüntü Analizi	12
1.4.1 Görüntü Tanıma	13
1.4.2 Görüntü Sınıflandırıcı Anatomisi	13
1.4.3 Nesne Tanıma Sorunları	15
1.4.4 Nesne Tanıma Uygulamaları	16
1.5 El Çizimi Diyagram Tanıma Sistemi	17
1.6 El Çizimi Tanımaya Genel Bakış	18
1.7 El çizimi Tanıma Çeşitleri	18
1.7.1 Görünüme Dayalı Tanıma	18
1.7.2 Geometri Tabanlı Tanıma	19
1.8 Çevrimdışı ve Çevrimiçi El Çizimi Tanıma	19
1.9 El Yazısı Karakter ve Diyagram Tanıma	19
1.9.1 Kullanıcı Giriş Modelleri	20

1.9.2 Giriş El çizimlerin Eldesi.....	20
1.9.3 Ön İşleme Teknikleri.....	20
1.9.4 Bölütleme	21
1.9.5 Özellik Çıkarımı.....	21
1.9.6 Sınıflandırma.....	21
1.10 El Çizimi Tanıma Zorlukları.....	21
1.11 Araştırma Problemi	21
1.12 Kullanılan Veri Kümeleri	22
1.12.1 Akış Şeması (FC) Veri Kümesi.....	22
1.12.2 Sonlu Otomata (FA) Veri Kümesi.....	22
1.12.3 Dijital Mantık Devreleri Veri Kümesi	22
1.13 Tezin İçeriği	23
2 EL ÇİZİMİ OKLAR İLE BAĞLI DİYAGRAMLARDA KAPALI ŞEKİLLERİN	
TANINMASI	24
2.1 Kapalı Şekiller.....	24
2.2 Havza İle Sembol Tanıma.....	25
2.3 Önerilen Gridshed Sembol Tanıma Algoritması.....	26
2.4 Önışleme	27
2.5 El Çizimi Görselleştirmenin İyileştirilmesi.....	28
2.6 Gridshed Kapalı Bölgeler Çıkarma Algoritması	29
2.7 Özet.....	31
3 SKETRACK: ÇEVİRİMİÇİ EL ÇİZİMLERİNİN DARBE-TABANLI	
TANIMLANMASI	32
3.1 Ön İşleme.....	33
3.2 Özellik Çıkarma	35
3.3 Spektral Kümeleme Kullanarak Sembol Segmentasyonu.....	36
3.4 Sembol Tanıma.....	37
3.4.1 MDVM Kullanarak Sembol Sınıflandırması	37
3.4.2 Oklar/Çizgi Bağlantı Algılama	39
3.5 Yapı Analizi Ve El Çizimi Tanıma	40
3.6 Özet.....	42
4 SONUÇLAR VE TARTIŞMA	43
4.1 Giriş.....	43
4.2 Kapalı Şekil Nesne Tanıma Sonuçları	43

4.3 Darbe Tabanlı Tanıma Sonuçları.....	46
4.4 Özet.....	53
5 SONUÇ VE ÖNERİLER	54
KAYNAKÇA	55
TEZDEN ÜRETİLMİŞ YAYINLAR	62

SİMGE LİSTESİ

Th_{I_a, I_b}	a ve b düğümleri arasındaki eşik benzerlik
E_{ab}	a ve b arasındaki bağlantı
w	Ağırlık vektörü
P_i	Aradaki noktalar
X_{id}	Aslanların konumu
M_{id}	Aslanların hızı
E	Bağlantı
P_1	Başlangıç uç nokta
$d_{connector}$	Connector mesafesi
K_P	Çokterimli çekirdeği
T	Dörtlü ağaç
d_{thresh}	Genel eşik mesafesi
Z	Genişlik
X_{map}, Y_{map}	Haritalama konumu
K_{RP}	Hibrit çekirdek
S	İkinci sembolün sınırlayıcı kutusu
R	İlk sembolün sınırlayıcı kutusu
Q	İnce ayar parametre hareketi
λ	İnce ayar parametresi

KISALTMA LİSTESİ

AÖS	Artırıcı Özellik Seçimi
BTF	Bulanık Temel Fonksiyonu
BMD	Birleşik Modelleme Dili
CB	Cep Bilgisayarı
ÇÇÖ	Çoklu Çekirdek Öğrenimi
DDA	Dijital Diferansiyel Analizörü
DE	Darbe Etiketleme
DLD	Dijital Lojik Devresi
DÖÖSA	Derin Öğrenme Özyinelemeli Sinir Ağı
DVM	Destek Vektör Makinesi
ESA	Evrşimsel Sinir Ağları
EYT	El Yazısı Tanıma
FA	Sonlu Otomata
FC	Akış Şeması
GKA	Grafik Kullanıcı Arayüzü
GMM	Gizli Markov Model
HSÖ	Hızlandırılmış Sağlam Özelliği
İUKB	İki Yönlü Uzun-Kısa Vadeli Bellek
KA	Kullanıcı arayüzü
KDH	Kendinden Düzenlenen Harita
KHA	Kazanan-Hepsini-Alır
MDVM	Modifiye Destek Vektör Makinesi
ÖDÖD	Ölçek Değişmeyen Özellik Dönüşümü
ÖSA	Özyinelemeli Sinir Ağları
PET	Piksel Eşleştirme Tekniği
RGB	Kırmızı Yeşil Mavi
TÖY	Tümler Ölçme Yöntemi
UKVB	Uzun-Kısa Vadeli Bellek
YGH	Yönelimli Gradyanların Histogramı
YSA	Yapay Sinir Ağları

ŞEKİL LİSTESİ

Şekil 1.1	Görüntü sınıflandırma adımları	14
Şekil 1.2	El çizimi tabanlı grafik giriş aracının çerçevesi (Zhengxing ve diğerleri, 2005)	21
Şekil 2.1	(a)(b) Kapalı şekil örnekleri (c)(d) Açık şekil örnekleri	25
Şekil 2.2	Havza algoritmasının diyagramı, Kaynak: Rashwan ve diğerleri (2009)	26
Şekil 2.3	Önerilen sistemin akış şeması	27
Şekil 2.4	Darbe noktalarının basit gösterimi.....	28
Şekil 2.5	El çizimlerin iyileştirilmiş görseli.....	29
Şekil 2.6	Hücreleri birleştirerek önerilen sembol çıkarma işlemi için elde edilen sonuçlar (a) Basit el çizimi akış diyagram örneği (b) (c) Diyagram hücrelere bölünüp kenarlardan boş hücreler silinir (d)(e)(f) Rastgele boş hücre seçilip benzer komşu hücreler	30
Şekil 3.1	SKETRACK Tanıma işleme akışı.....	33
Şekil 3.2	FC veri tabanından bir girdi imgesinden ayrılan metinler	34
Şekil 3.3	FC veri tabanından bir girdi imgesinden kalan darbe örnekleri	41
Şekil 4.1	FC el çizimi tanıma sonuçlarına örnek	43
Şekil 4.2	(a) (b) Havza tarafından algılanmayan ancak Gridshed tarafından algılanan kapalı şekillerin örnekleri (c) (d) El çizimi iyileştirme sırasında oluşabilecek hata örnekleri.....	45
Şekil 4.3	FC veri kümesinde tanıma sonuçlarına örnekler (a) giriş el çizimi (b) tanıma sonucu (yeşil: doğru sembol tanıma, kırmızı: metin, mavi: yanlış semboller)	51
Şekil 4.4	FA veri kümesinde tanıma sonuçlarına örnekler (a) giriş el çizimi (b) tanıma sonucu (yeşil: doğru tanıma, kırmızı: metin, mavi: yanlış)	51
Şekil 4.5	DLD veri kümesinde tanıma sonuçlarına örnekler (a) giriş çizimi (b) tanıma sonucu (kahverengi: OR, menekşe: AND, yeşil: NOR, sarı: NAND, mavi: XOR, pembe: baloncuk, siyah: çizgi)	52

TABLO LİSTESİ

Tablo 4.1 DDA el çizimi iyileştirme olmadan sembol çıkarma oranı.....	44
Tablo 4.2 DDA el çizimi iyileştirmesi ile sembol çıkarma oranı	45
Tablo 4.3 İşleme süresi	46
Tablo 4.4 FC veri kümesi için tanıma performansı sonuçları	47
Tablo 4.5 FA veri tabanı için tanıma performansı sonuçları	47
Tablo 4.6 DLD veri kümesi için tanıma performansı sonuçları	47
Tablo 4.7 FC veri kümesi için tanıma sonuçları	48
Tablo 4.8 FA veri kümesi için tanıma sonuçları.....	49
Tablo 4.9 DLD veri tabanı için tanıma sonuçları	49
Tablo 4.10 Optimizasyon süresi	50
Tablo 4.11 Toplam çalışma süresi.....	50
Tablo 4.12 Farklı SKETRACK işlemi için yanlış tanınma oranları	52

El Çizimi Diyagramların Modifiye Destek Vektör Makineleri ve Grid Tabanlı Su Havzası ile Tanınması

Orhan NOORULDEEN

Bilgisayar Mühendisliği Anabilim Dalı

Doktora Tezi

Danışman: Dr. Öğr. Üyesi Oğuz ALTUN

Diyagram ve görüntülerdeki kapalı nesnelerin ve yapıların algılanması ve tanınması, son yıllarda ilginç bir araştırma kavramı olarak kabul edilmektedir. Çünkü; elle yazılmış belgelerin dijitalleştirilmesi, literatür ve tanıma yönetiminin tüm seviyelerinde giderek daha fazla gerçekleştirilmektedir. Havza (Watershed); çizgi bağlı el çizimlerinde, kapalı şekil tespiti için kullanılabilecek klasik bir görüntü bölütleme algoritmasıdır. Bununla birlikte, havza algoritması, gürültü eşit olmadığından fazla bölütlemeye neden olabilmektedir. Ayrıca, nesneler birbirine çok yakın olduğunda algoritma verimli değildir. Çünkü; yerel minimumlara karşı algoritma oldukça duyarlıdır. Bu sınırlamalar yüzünden, kapalı şekil nesnelerini tespit etmek için, yeni ileri tekniklere ihtiyaç duyulmaktadır.

Bu tez kapsamında ilk araştırma, elle çizilmiş ok bağlantılı diyagramlarda kapalı şekil nesnelerini tespit etmek için, ızgara havzası (Gridshed) adlı basit, yeni ve verimli bir sistem geliştirmeyi amaçlamaktadır. Izgara havzası algoritmasında, başlangıçta elle çizilmiş diyagram ön-işlemden geçmektedir. Daha sonra, dijital diferansiyel analizörü kullanılarak, kenarlar ve kapalı döngüler oluşturmak için en yakın darbelerin uç noktalarını bağlayarak, görüntü iyileştirilmektedir. Sembol

çıkarma, boş görüntü piksellerin kenarlık kutularını bağlayarak gerçekleştirilmektedir. Boş hücrelerin sürekli bağlanmasıyla, diyagramın şeklinin darbeleri kapalı bölgelerden tanınabilmektedir.

Tezin ikinci araştırma çalışması, elle çizilmiş ok şemaları ve dijital mantık devre şemaları için SKETRACK adlı yeni, verimli darbe tabanlı çevrimiçi el çizimi tanıma yönteminin, tasarımı ve geliştirilmesine odaklanmaktadır. Bu yöntemin temel aşamaları; metin ayrımı, sembol bölütlemesi, özellik çıkarma, sınıflandırma ve yapısal analizdir. Önerilen yöntem, metni şekillerden ayırmak için normalleştirme ve bölütleme araçlarını kullanmaktadır. Daha sonra etkili işlem için, şekil darbelerinin farklı yapısal varyasyonlarının özellikleri çıkarılmaktadır. Darbeler, özellikler arasındaki benzerliği hesaplamak ve benzer özellikleri gruplayarak özellik boyut sayısını aza indirmek için p-uzaklığı ve Öklid mesafesine dayalı spektral kümeleme algoritması kullanılarak kümelenebilmektedir. Daha sonra sembol tanıma, hibrit çekirdek fonksiyonun kullanıldığı Modifiye Destek Vektör Makinesi (Modified Support Vector Machine, MDVM) sınıflandırıcısı kullanılarak gerçekleştirilmektedir. Hibrit çekirdek fonksiyon parametreleri Aslan Optimizasyon Algoritması ile optimize edilmektedir. Yapısal analiz, son diyagram gösterimlerini oluşturmak ve sembol adaylarını tanımak için gerçekleştirilmektedir. Önerilen bu tanıma modeli, akış şemaları, sonlu otomat ve mantık devre şemaları gibi daha basit yapılar için uygun olmaktadır.

Deneyler yoluyla, önerilen Gridshed ve SKETRACK yöntemlerinin performansı, veri tabanlarında değerlendirilmekte, sonuçlar üstün verimliliklerini doğrulamak için en son yöntemlerle karşılaştırılmaktadır.

Anahtar kelimeler: El çizimi, kapalı şekiller, darbeler, MDVM, Gridshed

Recognition of Hand Drawn Diagrams Using Modified Support Vector Machines and Grid Based Watershed

Orhan NOORULDEEN

Department of Computer Engineering

Doctor of Philosophy Thesis

Advisor: Assist. Prof. Dr. Oğuz ALTUN

Detection and recognition of the closed shape objects and structures in diagrams and images is considered to be an interesting research concept in the recent years as the digitalization of handwritten documents have been increasingly performed at all levels of literature and administration. Watershed is a classical image segmentation algorithm that can be utilized for closed shape detection in line connected sketches. However, the watershed algorithm results in excessive over-segmentation when the noise is non-uniform. Also, the algorithm is not efficient when objects are very close to each other as it is highly sensitive to local minima. These limitations created the need for novel advanced techniques for detecting the closed shape objects.

First research work of this thesis aims at developing a simple, novel, and efficient system named Gridshed for detecting the closed shape objects in hand-drawn arrow-connected diagrams. In Gridshed, initially the hand drawn diagram is pre-processed. Then the image visualization is enhanced by connecting the closest stroke's endpoints to form edges and closed loops using the digital differential analyzer. The symbol extraction is performed by connecting the border boxes of the

empty image pixels. By continual connection of empty grids, the shape strokes of the diagram can be recognized through the closed regions.

Second research work of the thesis focuses on the design and development of a new, efficient Stroke based online hand-drawing recognition scheme named SKETRACK for hand-drawn arrow diagrams and digital logic circuit diagrams. The fundamental parts of this model are text separation, symbol segmentation, feature extraction, classification and structural analysis. The proposed scheme utilizes the concepts of normalization and segmentation to isolate the text from the sketches. Then the features are extracted to form the feature extraction model of different structural variations of the strokes that are categorized into the arrows/lines and the symbols for effective processing. The strokes are clustered using the spectral clustering algorithm based on p-distance and Euclidean distance to compute the similarity between the features and minimize the feature dimensionality by grouping similar features. Then the symbol recognition is performed using Modified Support Vector Machine (MSVM) classifier in which a hybrid kernel function with a tuning parameter optimized by Lion Optimization Algorithm is utilized. Structural analysis is performed to form the final diagram representations and recognize symbol candidates. This proposed recognition model is suitable for the simpler structures like flow charts, finite automata and the logic circuit diagrams.

Through the experiments, the performance of the proposed Gridshed and SKETRACK schemes are evaluated on databases and the results are compared with the state-of-the-art methods to validate their superior efficiency.

Keywords: Sketch, closed shapes, strokes, MSVM, Gridshed

Son yıllarda görüntü ve benzer dijital verilerin kullanımı popüler hale gelmiştir. Dijital kameraların ve akıllı cihazların gelişmesi, dijital görüntü miktarının büyümesini sonuç vermektedir. Dijital görüntülerin içeriğini tahmin ve analiz etmek, araştırmacılar için çekici bir konu haline gelmiştir.

1.1 Literatür Özeti

El çizimi tanıma, otomatik bilgisayar teknolojilerinde bulunan bir sorundur. El çizimi tanımasını gerektiren çok sayıda uygulama vardır. Kullanılan uygulamalardan bazıları, el çizimlere dayalı görüntü alma (image retrieval) ve el çizimi görüntülere dayalı video almadır. Bu bölümde, çok sayıda el çizimi tanıma tekniği hakkında bilgi verilmektedir.

1.1.1 El çizimi / Görüntü Nesne Tanıma Teknikleri

Zhang ve diğerleri (2019) çevrimiçi el çizimi görüntülerini, elle çizilmiş görüntüleri ve benzerlerini kullanarak, çeşitli el çizimi tanıma tekniklerinin performansını tartışmaya çalışmaktadır. Çalışmada ayrıca, 3B şekillere dayanan çeşitli görüntü geri alma teknikleri hakkında tartışma sağlanmaktadır. Analiz çalışması esas olarak, el çizimi tabanlı görüntü geri alma tekniklerine odaklanmaktadır.

Peng ve diğerleri (2018), farklı stilist el çizimi görüntülerinden yüzleri tanımaya çalışan bir analiz çerçevesi sunmaktadırlar. Bu araştırma çalışması “elle çizilmiş yüzler ve kompozit yüzler” olmak üzere iki çeşit yüz şekli üzerinde analiz gerçekleştirmektedir.

Liu ve diğerleri (2018), SIFT ve HOG özelliklerini dikkate alınarak yeni kompozit tabanlı el çizimi tanıma tekniği sunmaktadır. Önerilen bu araştırma tekniklerinde, lineer fonksiyonla bütünleştirilmiş puan düzeyini kullanarak, farklı türdeki özellikler birleştirilmektedir.

Chen ve diğerleri (2018), yüz el çizimleri için bir sentez ve tanıma tekniği sunmaktadır.

Bu işlem iki aşamada yapılmaktadır. Birinci aşamada, Markov ağının kullanılmasıyla, farklı ölçeklerde el çizimi yüz sentez edilmektedir. İkinci aşamada, yüz tanıma doğruluğunu artırmak için, hem yapısal hem de bilgi tabanlı (yerel yüz bileşenleri) özellikler kullanılmaktadır.

Yoon & Yoon (2017), 3B görüntü el çizimi tabanlı nesne tanıma tekniğini sunmaktadır. Bu araştırma çalışmasının temel amacı, özellikleri öğrenmek üzere, nesneleri otomatik olarak öğrenmek ve tahmin etmektir. Burada özellik öğrenme, siyah beyaz tabanlı el çizimi görüntülerinden elde edilen, güçlü özellikleri öğrenmeye çalışan denetimsiz bir algoritma kullanılarak gerçekleştirilmektedir. Bu özellik veri kümesi, farklı el çizimi görüntüleri öğrenilerek oluşturulan, 3B nesnelerin özelliklerine yansıtılarak ön işlenmektedir. Çalışmada, görüntü veri tabanında bulunan benzer nesnelerle karşılaştırılarak, 3B nesnelerin tanınması sağlanmaktadır.

Mittal ve diğerleri (2017), dijital fotoğrafların kompozit el çizimlerini tahmin etmek için yeni bir yöntem sunmaktadırlar. Bu yöntemde görüntü veri tabanından çıkarılan el çizimi görüntüleri görsel belirginlik ve doku (texture) özelliklerinin çıkarılması ile eşleştirilmektedir. Doğru çizim tanıma için dikkate alınan özelliklerden bazıları; cinsiyet, etnik köken ve ten rengidir. Bu özellik bilgileri, çizim görüntülerini sıralayarak tanımak için kullanılmaktadır. Ayrıca, çizim nesnesi tanıma işleminin doğruluk düzeyini artırmak için, kompozit araçlar kullanılmaktadır.

Li ve diğerleri (2015), doğru ve otomatik çizim tanıma için, Çoklu Çekirdek Öğrenimi (Multiple Kernel Learning, ÇÇÖ) yöntemini sunmaktadır. Bu yöntemde, giriş çizim görüntülerinden özellikler çıkarılarak ve birleştirilerek tanıma yapılmaktadır

Arandjelović & Sezgin (2011), görüntü tabanlı tanıma ve zaman tabanlı tanıma olmak üzere, iki yöntemi sunarak nesne tanıma gerçekleştirmeye çalışmaktadırlar. Bu araştırma çalışmasının temel amacı, İnternet Ağından alınan farklı el çizimi görüntülerinden elde edilen özellikleri birleştirmektir. Bu yöntem, nesnelerin doğru tanınması için hem mekânsal hem de zamansal özellik bilgisini kullanmaktadır. Önerilen bu araştırma yöntemi, izole el çizimi tanımayı ve tam diyagram tanımayı başarabilmektedir.

Brieler & Minas (2010), geometri tabanlı özellikleri kullanan bir nesne tanıma sistemi gerçekleştirmektedirler. Bu yöntem, nesnelerin doğru tanınmasını sağlamak için hem kümeleme, hem de segmentasyon görevlerini kullanmaktadır. Bu yöntem, giriş görüntüsünden darbe bilgilerini çıkarıp, ön işleme modülüne bağımsız olarak

işlemektedir. Önerilen araştırma tekniği, darbelerin doğru ve net bir şekilde tanınmasını sağlayabilmektedir. Bu kümeleme ve bölümlleme sonuçları, model veri tabanında saklanacaktır. Bu model, çizgileri ve yayları (arc) tanımak için kullanılmaktadır.

Zhu ve diğerleri (2020), giriş çizim görüntüleri için, doğru tanıma amacı ile 2D serbest çizim etiketleme yöntemini sunmaktadırlar. Bu yöntem, görüntüleri daha doğru bir şekilde tahmin edebilen ESA ve CRF prosedürlerini uyarlayarak (adapting) yapılmaktadır.

Zhao ve diğerleri (2019), doğru tahmin sonucunu sağlamak için, çok parçalı el çizimlerinden faydalanan derin öğrenme tabanlı bir el çizimi tanıma yöntemi sunmaktadırlar. Çalışmada, “sketch transfer net” adlı bir model geliştirilmektedir.

Moetesum ve diğerleri (2020), derin konvolüsyon sinir ağını kullanarak, nöropsikolojik el çizimlerini analiz etmeye çalışmaktadırlar. Bu yöntem, aynı zamanda deforme olabilen modelleme (deformable modelling) prosedürünü kullanabilmektedir.

Liu ve diğerleri (2017), Deep Sketch Hashing adlı çerçeveyi sunmaktadırlar. Bu yöntemin temel amacı el çizimi görüntülerini web sayfalarından almaktır. Bu yöntem, iyi sonuç elde etmek için, uçtan uca bir ikili çerçeve uygulamaktadır.

Seddati ve diğerleri (2017), derin sinir ağına dayalı bir el çizimi tanıma tekniği sunmaktadırlar. Bu yöntem esas olarak doğru tanıma oranını sağlamak için, el çizimi özelliklerine odaklanmaktadır.

Zheng ve diğerleri (2019), el çizimi tanıma görevinde, derin sinir ağının performansını analiz etmektedirler. Bu yöntem, doğru ve verimli tahmin sonucunu garanti etmek için, anlamsal boşluk (semantic gap) özelliğine odaklanır. Bu yöntemde aynı zamanda aşamalı öğrenme stratejisi, yumuşak-ağırlıklı (soft-weighted) öğrenme çıktısını sağlayacak şekilde tasarlanmaktadır.

1.1.2 Yumuşak Hesaplama Teknikleri Kullanan Tanıma

Das ve diğerleri (2015), elle yazılmış Bangla karakterlerini tanımaya çalışmaktadırlar. Bu işlem, doğruluk seviyesini arttırmak için, karakter tanıma çerçevesiyle entegre edilen, yumuşak hesaplama teknikleri kullanılarak yapılmaktadır. Bu, iki geçişli bir yöntemin uyarlanmasıyla yapılmaktadır. Bangla alfabesinde 400 karakter vardır. Bu karakterler çoğunlukla Hindistan ve Bangladeş'te kullanılmaktadır. Önerilen iki geçiş yaklaşımı, bu

elle yazılmış karakterler dikkate alınarak uygulanmaktadır. Bu yöntem, bilinmeyen örnek desenlerini öğrenerek karakter sembollerini daha doğru bir şekilde tanıyabilmektedir. Bilinmeyen örüntü tanıma ilk geçişte yapılmakta ve daha iyi sınıflandırma sonucu ikinci geçişte elde edilmektedir.

Li ve diğerleri (2018), el hareketi lokalizasyonunu ve tahminini gerçekleştirmeye çalışan bir ESA çerçevesi sunmaktadırlar. Bu yöntem, renkli görüntülere uygulanmaktadır. Bu çalışmada, girdi görüntüleri ESA çerçevesi kullanılarak eğitilmektedir. Bu ESA çerçevesi, ilgi alanlarını otomatik bir şekilde öğrenerek ve yerleştirerek el hareketlerini doğru bir şekilde öğrenmekte ve tahmin etmektedir.

Zhang ve diğerleri (2020), çizim objelerinin doğru tanınması için, yüksek dereceli bir istatistik modeli sunmaktadırlar. Bu yöntem, normalize edilmiş Kovaryans Ortaklama (Covariance Pooling) yönteminin kullanılmasıyla, nesnelerin yerini belirleyerek yapılmaktadır. Bu araştırma çalışmasının temel amacı, nesneleri doğru ve artan güç ile bulmaktır.

Shao & Chiu (2016), Aşırı Öğrenme (Extreme Learning) sınıflandırıcısı ve Rastgele Orman (Random Forest) sınıflandırıcısı olmak üzere, popüler iki yumuşak hesaplama tekniği sunmaktadır.

Wazarkar ve diğerleri (2018), sosyal ağlardan toplanan nesneleri, yumuşak sınıflandırma tekniği sunarak bölümlere ayırmaya çalışmaktadırlar. Bu sunulan teknik, KNN ve yumuşak sınıflandırma tekniğinin çalışma prosedürünü, doğruluk seviyesini artırmak için uygulamaktadır. Yumuşak sınıflandırma tekniğinin temel amacı, nesneleri eşleştiği birden fazla sınıf etiketine atamaktır.

Wang & Deng (2020), kümeleme yaklaşımına dayalı yeni yöntem önermektedir. Bu yöntem, giriş resmini eşleme özelliği olmayan, hedef alan resimleriyle eşleştirmeye çalışmaktadır.

Shen ve diğerleri (2018), pas yoğunluğu düzeyini tahmin etmek için bir sinir ağı tabanlı tanıma çerçevesi tanıtmaktadırlar. Bu işlem, sıkıştırma seviyesinin doğru tanınması için, Kök Ortalama Kare Standart Sapması (Root Mean Square Standard Deviation) prosedürünün sinir ağı ile birleştirilmesiyle yapılmaktadır. Bu araştırma çalışmasının temel amacı, pas yoğunluğunu ve paslanma şiddetini ölçmektir. Önerilen yöntem, pas görüntüsünün farklı pas renklerinin varyasyonlarını ölçmektedir.

Wan & Lee (2019), yüz el çizimi görüntülerini doğru bir şekilde tanımak için bir yöntem geliştirmektedirler. Bu yöntemde VGG derin özellikleri kullanılmaktadır.

Zhang ve diğerleri (2018), doğru el çizimi görüntüsü almak için, serbest el çizimi oluşturma modeli olan yeni bir yöntem sunmaktadırlar. Bu yöntem derin konvolüsyon sinir ağını kullanmaktadır.

Wang ve diğerleri (2018), el çizimi görüntülerini sağlam bir şekilde tahmin etmeye çalışan SKETCHPOINTNET çerçevesini sunmaktadırlar. Bu yöntem, tanıma tahmin sonucunu artırmak için, aşağıdan yukarıya doğru yapılmaktadır. Girdi görüntülerinin doğru tahmini için hiyerarşik bir şekilde özellikler çıkarılmaktadır.

1.1.3 El Çizimi Tanıma

Bu bölümde, çeşitli elle çizilmiş el çizimi tanıma teknikleri ele alınmaktadır.

1.1.3.1 Basılı Diyagramların Tanınması

Gupta ve diğerleri (2019), yerel bölgeleri düşük maliyetli bir şekilde tespit etmek için, çok amaçlı bir çerçeve sunmaktadırlar. Araştırma çalışmasının genel analizi, dört farklı veri kümesi üzerinden değerlendirilmektedir. Bu veri kümeleri; izole el yazısı Bangla temel karakterleri, izole el yazısı Bangla rakamları, İngilizce rakamları ve izole el yazısı Devanagari karakterleridir.

Amin (2000), C4.5 makine öğrenme yöntemi kullanılarak gerçekleştirilen bir Arapça metin tanıma yöntemini sunmaktadır. Çalışmada kullanılan yöntem iki adımdan oluşmaktadır. İlk adımda, farklı varyasyonlara sahip, farklı yazı tipi stillerinin tahmini yapılmaktadır. İkinci adımda, daha fazla sayıda örnek öğrenilerek farklı yazma stilleri tahmin edilmektedir.

Namane ve diğerleri (2014), bir nesne tanıma gerçekleştirme yöntemi önermektedirler. Bu yöntem, iki alt ağ sinir ağı kullanılarak gerçekleştirilmektedir. Birincisi; benzerlik hesaplaması için, Tümler Ölçme Yöntemi (Complementary Measure Method, TÖY) kullanılmaktadır. İkincisi; alt ağ sınıflandırmasında, Kazanan-hepsini-alır algoritması (Winner-takes-all Algorithm, KHA) ile Evrişimsel Sinir Ağları (Convolutional Neural Network, ESA) kullanılarak yapılmaktadır.

Sohal (2016), doğru tanıma görevi için bir karakter tanıma yöntemi önermektedir. Metin baskıların doğru tanınması, görüntülerden özellikler çıkarılarak ve Kohonen Kendinden-Düzenlenen Harita (Self-Organizing Maps, KSH) kullanılarak yapılmaktadır. Bu yöntem ile tanımda, öğrenmeyi gerçekleştirmek için, denetimsiz (unsupervised) bir yöntem kullanılmaktadır.

Chen ve diğerleri (2018), Fourier Spektrumu (Fourier Spectrum) tabanlı bir nesne tanıma yöntemi sunmaktadırlar. Araştırma çalışmasının temel amacı, çeşitli türdeki nesnelerin ışıık yoğunluğu değerlerini öğrenerek, doğru nesne tanıma oranını sağlamaktır.

Bresler ve diğerleri (2015), çevrimiçi toplanan veri tabanlarındaki okları algılamaya çalışmaktadır. Önerilen ok bulucu yöntem, şekillerin bağlantılarını bulmak ve tanımak için kullanılmaktadır. Burada ok algılama, ok kuyruğu ve başı dikkate alınarak yapılmaktadır.

Xu ve diğerleri (2018), el çizimi tabanlı görüntü almayı gerçekleştirmeye çalışmaktadırlar. Bu yöntem, giriş el çizimleri ile fotoğraflar arasındaki Benzerlik Boşluğu (Similarity Gap) ölçülerek yapılmaktadır. Bu eşleşmelere dayanarak, doğru görüntü alımı verimli bir şekilde yapılabilmektedir.

Rahman ve Beg (2015), görüntülerdeki metin içeriğini öğrenerek yüz el çizimlerini tanımaya çalışmaktadırlar. Bu, açıklayıcı kelimeler yardımıyla gerçek el çizimi görüntülerini, doğru bir şekilde tahmin edebilecek kelimelerle çizim yöntemi kullanılarak yapılmaktadır.

Li ve diğerleri (2017), deforme olabilen darbe modelini uyarlayarak, otomatik tanıma işlemi yapmaya çalışmaktadırlar. Bu araştırma tekniği, el çizimi modellerinin farklı yapılarını ve özelliklerini, farklı şekiller ve içerikler açısından öğrenmeye çalışmaktadır.

Sun ve diğerleri (2012), çeşitli uygulamaları desteklemek için, el çizimi görüntü bölütlemesine odaklanmaktadırlar. Bu yöntem, giriş çizim görüntülerini yakınlık ölçümü açısından birden fazla parçaya ayıracak grafik tabanlı bölütleme yöntemi ile yapılmaktadır.

Abdel-Majeed ve diğerleri (2020), bir dijital mantık devresi tanıma çerçevesi sunmaktadırlar. Bu yöntem, çeşitli devre diyagramlarının, etkileşimli bir şekilde öğrenilmesi hedefiyle yapılmaktadır. Böylece doğru tahmin sonucu sağlanabilmektedir.

Sarvadevabhatla ve Babu (2015), bir serbest çizim tanıma çerçevesi sunmaktadırlar. Önerilen çerçeve, derin özellikler ile çalışmaktadır.

1.1.3.2 Çevrimdışı Diyagramların Tanınması

Xiao ve diğerleri (2010), çizimlerden el çizimleri tamamlayarak, el çizimi ve fotoğraf arasındaki çelişkileri azaltmayı planlamışlardır. Daha sonra el çizimi/fotoğraf tanınması, Alt Uzay Öğrenimi (Subspace Learning) tabanlı tekniklerle yapılmaktadır. Eğitim aşamasında aynı şahsın el çizimi görüntüsünün ve fotoğraf görüntüsünün bağlanması, Gömülü Gizli Markov Modeli (Embedded Hidden Markov Model) ile gerçekleştirilmektedir.

Bhunja ve diğerleri (2020), yeni bir kelime seviyesi Hintçe içerik tahmini metodu sunmaktadırlar. Bu yöntemde, eğitim aşamasında sadece harf seviyesi verileri kullanılır. Bu strateji, verilerin hem çevrimdışı hem de çevrimiçi veriler ile birlikte kullanan derin sinir ağ sistemini kullanmaktadır.

Jayech ve diğerleri (2016), Tunus şehir isimleri için Arapça yazılmış çevrimdışı tanıma çerçevesi sunmaktadırlar. Yapılan araştırma incelemesinde, Kayan Pencere (Sliding Window) yaklaşımını esas alan Gizli Markov Modeli (Hidden Markov Model, GMM) kullanılmaktadır.

Eskander ve diğerleri (2014), çevrimdışı imza görüntülerine bağlı Bulanık Kasa (Fuzzy Vault, BK) çerçevesini sunmaktadırlar. Aza indirgenmiş ve ayırt edici bir özellik gösterimi seçmek için, iki aşamalı Artırıcı Özellik Seçimi (Boosting Feature Selection, AÖS) prosedürü sunulmaktadır.

Bhattacharya ve diğerleri (2013), piksel eşleştirme yöntemini kullanarak, çevrimdışı imza kimlik doğrulaması ve tanıma çerçevesi sunmaktadırlar. Piksel Eşleştirme Tekniği (PET), müşterinin imzasını, veri tabanında bırakılan örnek imzayla doğrulamak için kullanılır. Önerilen stratejinin sunumu, mevcut Yapay Sinir Ağları (Artificial Neural Network, YSA) yöntemi ve Destek Vektör Makinesi (Support Vector Machine, DVM) yöntemleri ile karşılaştırılmaktadır.

Mahmoud ve diğerleri (2014), çeşitli uluslardan oluşan 1000 akademisyenin oluşturduğu, 1000 adet elle yazılmış yapıdan oluşan, kapsamlı Arapça çevrimdışı El Yazısı Metin veri tabanını (KHATT) sunmaktadırlar. Yapılar 200, 300 ve 600 dpi hedeflerinde kontrol

edilmektedir. Veri tabanı 46 kaynaktan rastgele seçilmiş 2000 paragraf, Arapça karakterlerin tüm şekillerini kapsayan 2000 rastgele içerik bölümü ve alternatif olarak açık konulardaki bölümleri içermektedir. 2000 rastgele içerik bölümü 9327 satırdan oluşmaktadır.

Li ve diğerleri (2018), el çizimlerin doğru tanınması için, Özenli Ağ (Attentive Network) sunmaktadırlar. El çizimi görüntü tanıma, vektörlere dönüştürülen giriş el çizimlerini vektör formatında gerçekleştirmektedir. Önerilen araştırma çalışması, girişleri tanıma çerçevesindeki sorunları öğrenerek ve çözerek gidermektedir.

Choi ve diğerleri (2019), çevrimiçi veri tabanlarından serbest el çizimi görüntülerini almaya çalışmaktadırlar. Bu yöntem, Sketch Helper adlı çerçeve tanıtılarak yapılmaktadır. Bu çerçeve Derin İkili Karma (Deep Binary Hashing) tekniğini kullanmaktadır.

1.1.3.3 Çevrimiçi Diyagramların Tanınması

Sepahvand ve diğerleri (2016), atalet sensörlü kalemler için, Farsça / Arapça el yazısı karakter tanıma çerçevesi sunmaktadırlar. Başlangıç olarak, atalet kaleminin hareket yönü, atalet yolu çerçevelerinin hipotezini kullanarak, konum sinyallerini değerlendirmek için yeniden üretilmektedir. Konum hareketleri, daha sonra özellikler elde etmek için kullanılmaktadır.

Keysers ve diğerleri (2016), Google'ın şu anda 22 içeriği ve 97 dili destekleyen web tabanlı el yazısı tanıma çerçevesini tanıtmaktadırlar.

Ghosh ve diğerleri (2019), çevrimiçi el ile yazılmış kelime tanıma için yeni bir yöntem sunmaktadırlar. Yöntemde, Özyinelemeli Sinir Ağları (Recurrent Neural Network, ÖSA)'nın Uzun-Kısa Vadeli Bellek (Long Short Term Memory, UKVB) ve iki yönlü uzun-kısa vadeli bellek (Bidirectional Long Short Term Memory, İUKB) versiyonları kullanılarak, darbelerin eğitimi tamamlamadan önce her kelime eşit olarak, üst, orta ve alt olmak üzere üç bölgeye ayrılmaktadır. Bu bölge bölütlemesi, bir kelimenin içindeki darbelerin düzenindeki değişiklikleri azaltmak için yapılmaktadır.

Galbally ve diğerleri (2015), çevrimiçi verilerden üretilen iyileşmiş statik örnekler yöntemi sunmaktadırlar. Bu tür üretilen çevrim dışı imzalar, iki tür verinin karışımına bağlı olarak başka bir çevrim içi imza tanıma tasarımı kullanılmaktadırlar. Bunlar;

gerçek verilerle birleştirilen, çevrim içi ve çevrim dışı imzalardan toplanan gerçek zamanlı örneklerdir.

Delaye ve Anquetil (2013), görüntü tanıma çerçevelerinin değerlendirilmesi için, elle çizilmiş görüntülerin temsilinde değişik bir özellik düzenlemesi sunmaktadır. Farklı deneysel bağlamlarda çok sayıda sembolle başa çıkmaya hazır olan, bu 49 yapısal özelliği planlamak için, gözlemsel bir yöntem kullanılmaktadır.

Wang ve diğerleri (2012), Çin el yazısının cümle tabanlı tanınması için, gerçek zamanlı bir tanıma yöntemi sunmaktadırlar.

Bresler ve diğerleri (2016), ok bağlantılı diyagramları tahmin etmeye çalışan, çevrimiçi bir tanıma çerçevesi sunmaktadırlar. Bu yöntem, etki alanına özgü bilgilere dayanarak, çizim görüntülerinin darbe özelliklerini öğrenerek yapılmaktadır. Bu analiz, akış şemaları ve sonlu otomata diyagramları üzerinde yapılmaktadır.

Fahmy ve diğerleri (2018), geometrik şekillere dayanan bir el çizimi tanıma çerçevesini sunmaktadırlar. Bu araştırma yöntemi, akış şemaları, Markov zincirleri, durum diyagramları ve benzeri gibi yapılandırılmış diyagramları doğru bir şekilde tanıyabilmektedir. Bu araştırma çalışması, doğru el çizimi tanıma sonucunu sağlamak için etkileşimli bir şekilde gerçekleştirilmektedir.

Liu ve diğerleri (2019), elle çizilmiş el çizimi görüntülerinin doğru tanınmasını sağlamaya çalışan SKETCHGAN çerçevesini sunmaktadırlar. Bu yapısal bilgi ile yapılmaktadır. Önerilen yöntem, Kaskad kodlayıcı (encoder) ve kod çözücü (decoder) ağ networkü uyarlamaktadır.

Wang ve diğerleri (2020), Çoklu Sütun Tabanlı Nokta ESA (Multi Column Based Point Convolution Neural Network) yöntemi ile, el çizimi bölütlemesi gerçekleştirmeye çalışmaktadırlar. Bu araştırma tekniğinin temel amacı, görüntüleri daha düşük hesaplama maliyetiyle bölümlere ayırmaktır.

Wadhwa ve diğerleri (2019), piksel bilgilerine dayanan bir yüz tanıma çerçevesini sunmaktadırlar. Bu yöntem, Tek Adımda Öğrenme (One Shot Learning) yöntemini, elle çizilmiş el çizimi görüntülerinin doğru tahmini için uyarlamaktadır.

Chandan ve diğerleri (2018), çevrimiçi alınan veri tabanından, el çizimi görüntülerini tahmin etmeye çalışmaktadırlar. Bu yöntem, Derin Öğrenme (Deep Learning) tekniğini kullanmaktadır.

1.1.3.4 Çevrim Dışı ve Çevrim İçi Diyagramların Tanınması

Phangtrastu ve diğerleri (2017), çıkarılan bazı özellikler üzerinden tanıma yapmak için, Zoning Algoritması, Projeksiyon Profili, Yönelimli Gradyanların Histogramı (Histogram of Oriented Gradients, YGH) ve bu yöntemlerin karışımlarını kullanmaktadırlar. Önerilen çerçevede sınıflandırıcı olarak, Destek Vektör Makinesi ve Yapay Sinir Ağları sınıflandırıcıları kullanılmaktadır.

Radhika ve Gopika (2015), bir otomatik imza/kimlik doğrulama çerçevesi sunmaktadırlar. Bu çalışma, elle yazılmış imzaların hem çevrimiçi, hem de çevrimdışı özellikleri etrafında odaklanmaktadır. İmzalar hem çevrimiçi, hem de çevrimdışı olarak toplanmaktadır. Toplanan çevrim içi veriler, bir web kamerası kullanılarak yakalanan imza prosedürüdür. Toplanan çevrimdışı veriler ise, taranan imzalardır.

Awal ve diğerleri (2014), sayısal sembol tanımayı, sayısal bir gramer sınırlaması altında sembol bölütlemesi, görüntü tanıma, 2B yapı tanıma ve iyileştirme olarak işleyen, çevrim içi yazılı bir matematiksel sembol tanıma çerçevesi olarak sunmaktadırlar.

Qi ve diğerleri (2018), İnternet Ağında 3B şekilli el çizimleri bulmaya çalışmaktadırlar. Bu yöntem, daha sonra Derin Alanlar Arası Semantik Gömme (Deep Cross Domain Semantic Embedding) modeli kullanılarak öğrenilen, 3B şekillerden özellikler çıkarılarak yapılmaktadır.

Jia ve diğerleri (2017), çevrim içi serbest el çizimi görüntülerinden, şekil ve doku (texture) özelliklerini tanımak için, Ardışık Çift Derin Öğrenme (Sequential Dual Deep Learning) çerçevesini sunmaktadırlar. Bu, çevrim içi el çizimi görüntü veri tabanından çıkarılan özellikler ile yapılmaktadır. Önerilen yöntem, darbe çizim sırası açısından, doğru tanıma oranını sağlamaktadır.

Sert ve Boyacı (2019), Transfer Learning tabanlı el çizimi tanıma çerçevesini sunmaktadırlar. Bu yöntem, tanıma doğruluğunu arttırmak için, ESA (Conventional Neural Network) kullanılmaktadır. Önerilen yöntem, özellik seviyesi füzyon prosedürü uyarlanması ile, tanıma sonucunun elde edilmesini sağlamaktadır.

Hou ve diğerleri (2018), gerçek zamanlı bir şekil tanıma prosedürü sunmaktadırlar. Bu yöntem hem çevrim dışı hem de çevrim içi çizim görüntülerini kullanmaktadır.

1.1.4 Çıkarımlar

El çizimi görüntülerinin çevrimiçi tanınması için, daha önce birçok araştırma çalışması yapılmıştır. Bu araştırma çalışmaları, el çizimi görüntülerini farklı faktörleri göz önünde bulundurarak, doğru şekilde tahmin etmeye çalışmaktadır. Bununla birlikte, el çizimlerinin doğru tanınmasını etkileyebilecek aşağıdaki faktörler bulunmaktadır.

Mevcut araştırma teknikleri, değişen gürültü varlığı ile, sayısallaştırılan el çizimi görüntülerini tanımaktadır. El çizimi görüntülerinin doğru bir şekilde tanınması için, gelecekte daha fazla araştırma yapılması gerekmektedir.

1.1.5 Araştırma Problemi

Diyagram ve görüntülerdeki kapalı şekil nesnelerin ve yapıların algılanması ve tanınması, ilginç bir araştırma problemidir. Çünkü; elle yazılmış belgelerin yeni dokunmatik cihazlar ile daha hızlı oluşturulması, insan tarafından daha esnek ve kolay şekilde yapılmaktadır. İnsanın klavye ve fare yerine kendi parmağı ile veya dijital kalemle ile serbestçe yazıp çizmesi popülerleşmiştir. Buda bahsedilen belgelerin miktarını artırmaktadır. Havza; çizgi bağlı el çizimlerde kapalı şekil tespiti için kullanılabilecek, klasik bir görüntü segmentasyon algoritmasıdır. Bununla birlikte havza algoritması, gürültü düzensiz olduğunda, aşırı segmentasyona neden olmaktadır. Mevcut teknikler, tek bir darbe kullanılarak çizilen nesneleri, düzgün bir şekilde işleyemezler. Yöntemler aynı zamanda, tutarlı çizim stili hakkında yapılan varsayımlara da dayanmaktadır.

1.1.6 Önerilen Çözüm

Önerilen model, giriş diyagramlarının ve darbelerin ön işleminden geçirilmesi, metin ayrımı, sembol tanıma, analiz ve temsil işlemlerinden oluşmaktadır. Değerlendirme için, Sonlu otomat, akış şeması ve dijital mantık devresi, çevrim içi elle çizilmiş diyagramları kullanılabilir. Sembol tanıma aşaması, tanıma performansını artırmak için, yeni fikirlerin entegre edildiği araştırma kısmıdır. İlk öneri, kapalı şekil sembollerini tanımak için, Gridshed algoritmasının sunulmasıdır. İkinci öneri ise, segmentasyon işlemi için Spektral Kümeleme (Spectral Clustering) kullanılması, hibrit çekirdek fonksiyonu ve SVM parametrelerini optimize etmek için, Aslan Optimizasyonu (Lion Optimization) (Yazdani

ve Jolai, 2016) kullanılarak, sınıflandırma için Modifiye Destek Vektör Makineleri (Modified Support Vector Machine , MDVM) kullanılmasıdır.

1.2 Tezin Amacı

Bu araştırma çalışmasının temel hedeflerin birincisi; minimum düzeyde gürültü ve hata ile yüksek başarıya sahip çevrimiçi bir kapalı şekil algılama algoritması sunmaktır. İkinci hedef ise, çevrimiçi ok bağlantılı diyagramları doğru bir şekilde tanıyan ve tahmin eden etkili bir yöntem sunmaktır.

1.3 Orjinal Katkı

Bu tez çalışmasının ana katkılarının birincisi; doğru ve verimli çevrimiçi el çizimi tanıma için, havza algoritmasının hızlandırılmasını sağlayan Gridshed isimli bir algoritma sunmasıdır. İkinci katkı ise; SKETRACK isimli, modifiye edilmiş DVM tabanlı çevrimiçi bir el çizimi diyagram tanıma sisteminin geliştirilmesidir.

1.4 Görüntü Analizi

Görüntü analizindeki hedef görüntülerin içerdiği bilgileri taramak ve istenilen bileşenlere ulaşmaktır. Bilgisayarla görmeye dayalı bazı algoritmalar, internette görüntü dosyalarının aranması, sıkıştırılması, görüntü dosyalarında nesnelerin takip edilmesi, fotoğrafların organizasyonu, vb. uygulamalarda kullanılmaktadır.

Bilgisayarla görme açısından görüntü, nesneler ve nesneleri çevreleyen arka plandan oluşmaktadır. Nesneler arasındaki karşılıklı ilişkiyi öğrenerek ve bularak, görüntülerin gerçek senaryosu tahmin edilebilmektedir. Bu işlem de iki şekilde yapılabilmektedir: Nesne Algılama ve Nesne Tanıma.

Nesne Algılama; nesnenin verilen giriş görüntüsünde ve konumunda olup olmadığını bulma işlemi olarak tanımlanabilir.

Nesne Tanıma; bir nesnenin özelliklerini öğrenip, test kümesinden benzerini bulma işlemidir.

İnsan iletişimi çeşitli dönemlerde değişmektedir. İnsanların kullandığı yaygın iletişim biçimlerinden biri el çizimleridir. El çizilimi görüntülerinin doğru ve verimli bir şekilde tanınması için, daha önce tanıtılan farklı araştırma teknikleri vardır. El çizimi görüntülerinin otomatik olarak tanınması, dijitalleştirme ve işleme gibi çeşitli problemleri gündeme getirmektedir. Bu nedenle el çizimi tanıma araştırmalarının devam etmesini beklemekteyiz.


1.4.1 Görüntü Tanıma

Görüntü Tanıma girdi olarak verilen görüntülerde mevcut nesneleri bulma görevidir.

Görüntü tanıma görüntüdeki nesnelerin sınıf etiketini çıktı olarak verir. Bu işlem verilen giriş görüntülerinden yapılarak yapay zeka sistemlerinin eğitilmesiyle gerçekleştirilebilmektedir.

1.4.2 Görüntü Sınıflandırıcı Anatomisi

Geleneksel sınıflandırma prosedürünün işleme adımları aşağıdaki Şekil 1.1'de gösterilmektedir.



Şekil 1.1 Görüntü sınıflandırma adımları¹

1.4.2.1 Ön İşleme

Ön işleme, girdi görüntülerini hazırlamak ve çalıştırılabilir formata dönüştürmek için kullanılan adımlardır. Çokça kullanılan bazı ön işleme teknikleri, renklerde histogram

¹ <https://www.learnopencv.com/image-recognition-and-object-detection-part1/>

incelemesi ve azaltması, verilerin tek boyuta dönüşmesi ve bir sonraki asama için verilerde renkler gereksiz ise görüntülerin siyah beyaza dönüşmesidir.

1.4.2.2 Özellik Çıkarma

Her üzerinde tanıma gerçekleştirilecek girdi görüntüleri çoğunlukla görüntüde tanınacak nesne ile ilgisiz bilgiler içerir. İlgisiz bilgileri sınıflandırma görevinde işlemek gereksizdir. Sınıflandırma aşamasına girmeden önce, görüntü bilgilerinin azaltılmasıyla işlem hızını artırılabilen ve başarıyı etkileyen negatif faktörler önlenmektedir. Önleme, giriş görüntülerinden gerekli özelliklerin çıkarılıp, geri kalanların yok sayılmasıyla yapılabilmektedir.

Örneğin; verilen giriş görüntülerinde, insan gözleri bulma senaryosunu düşünelim. Burada, görüntüdeki renk pikselleri değerleri önemli olmayabilmekte, kenarlar daha önemli olabilmektedir (Yang ve diğerleri 2011).

Geleneksel algoritmaların çoğunda özellik çıkarma aşaması, algoritmanın performansını etkileyen çok önemli bir görevdir. Yeni bulunan özellik çıkarma algoritmaları, daha yüksek hassasiyetli olmalıdır. Örneğin; iyi özellik çıkarma algoritması, sadece düğmelerin dairesel şeklini değil, aynı zamanda lastikler, bilezikler ve benzeri diğer dairesel şekillerdeki nesnelerin ayırt edilebilmesinde yardımcı olabilmektedir. Bilgisayar görmede kullanılan bazı özellik çıkarma algoritmaları Haar-benzeri (Haar-like) (Lienhart ve Maydt, 2002) özellikler, Yönelimli Gradyanların Histogramı (Histogram of Oriented Gradients, YGH) (Dalal ve Triggs, 2005), Ölçekle Değişmeyen Özellik Dönüşümü (Scale-Invariant Feature Transform, ÖDÖD) (Lowe,2004), Hızlandırılmış Sağlam Özelliği (Speeded up Robust Features, HSÖ) (Bay ve diğerleri, 2006) vb. algoritmalarıdır. Son yıllarda derin sinir ağları ile öğrenmeyle ilgili özellik çıkarmaya odaklanan birçok çalışma yapılmıştır. Çalışmalarda evrimsel sinir ağları ile özellikler çıkarılıp nesne sınıfının tahmini yapılmaktadır.

1.4.2.3 Sınıflandırma ve Öğrenme Algoritmaları

Özellik çıkarma görevlerinde, girdi görüntülerinden istenen bilgiler, özellik vektörleri olarak gösterilmektedir. Sınıflandırma prosedüründe, bu özellik vektörleri girdi olarak alınmakta ve uygun sınıf etiketleri çıktı olarak atanmaktadır. Tahmin gerçekleştirilmeden

önce, eğitim yapılarak sınıflandırma performansı iyileştirilebilmektedir. Bu eğitim, gerekli nesneleri içeren binlerce görüntüye ve nesne içermeyen görüntülere ihtiyaç duymaktadır. Çevrimiçi olarak, çok popüler öğrenme algoritmaları bulunmaktadır.

1.4.3 Nesne Tanıma Sorunları

Nesne tanıma işlemi sırasında ortaya çıkabilecek olası sorunlar aşağıda listelenmektedir.

1.4.3.1 Aydınlatma

Her görüntünün farklı aydınlatma koşulları bulunmaktadır. Örneğin; gece ve gündüz çekilen görüntülerin farklı aydınlatma koşulları bulunur. Ayrıca, değişen hava durumu da giriş görüntülerinin aydınlatılmasını etkilemektedir. Evin içinde ve evin dışında çekilen görüntüler farklı aydınlatma efektlerine sahiptir. Giriş görüntüsündeki gölgeler de görüntü aydınlatma koşulunu etkilemektedir. Bu değişen aydınlatma etkisinden bağımsız olarak, tanıma prosedürü, giriş görüntülerinde bulunan her türlü nesneyi tahmin edebilmelidir.

1.4.3.2 Konumlama

Farklı görüntülerdeki aynı nesneler aynı konumda bulunmamaktadır. Giriş görüntülerin, tek düzeyde olmayan konumlarını işleyebilecek nesne tanıma yeteneği olmalıdır.

1.4.3.3 Dönüş

Çekilen görüntüler farklı açılarda olmaktadır. Görüntülerin bu döndürülmüş doğası, bilgisayar görme tabanlı tanıma tekniklerde göz önünde bulundurulmalıdır.

1.4.3.4 Yansıtma

Bazı senaryolarda, nesne tanıma sistemi görüntülerde yansıtma efektlerini yakalamalıdır.

1.4.3.5 Kapanma

Kapanma, çekilen görüntülerdeki nesnelerin başka nesneleri örtmesi olarak tanımlanmaktadır. Nesne tanıma teknikleri, bu koşulların üstesinden gelebilmeli ve nesneleri doğru tanımalıdır.

1.4.3.6 Ölçeklendirme

Nesnelerin boyutu doğruluk açısından nesne tanıma tekniklerinde performans düşüşüne neden olmamalıdır.

1.4.4 Nesne Tanıma Uygulamaları

Nesne tanımanın birçok uygulama alanı bulunmaktadır.

1. **Biyometrik Tanıma:** İnsanların fiziksel veya davranışsal özelliklerini kullanarak, güvenlik seviyesini sağlamak için kimlik doğrulama işlemidir. Bireyi tanımak için kullanılan biyometri örnekleri; parmak izleri, el geometrisi, göz, iris ve benzer karakteristiklerdir.
2. **Gözetim:** Çoğu video gözetim sistemi, güvenlik amacıyla videolarda çekilen nesnelerin algılanmasını gerektirmektedir. Nesne tanıma, videoda yakalanan insanları tahmin etme sürecidir.
3. **Endüstriyel Muayene:** Nesne tanıma teknikleri, makine parçalarının doğru şekilde çalışma yeteneğinin gözetlenmesi için, çeşitli uygulamalarda kullanılmaktadır. Böylece makine parçalarında bulunan hatalar ve hatalar hakkında doğru kararlar alınabilmektedir.
4. **İçeriğe Dayalı Görüntü Geri Getirme:** İçeriğe Dayalı Görüntü Geri Getirme veya Geri Erişim; giriş içeriğiyle eşleşen sonuçlardan gelen görüntüleri, analiz ve tahmin etme işlemi olarak tanımlanmaktadır. Örneğin; Plantsnap², benzer görüntüleri Internet Ağ'ından eşleştirmek ve almak için görüntü ek açıklamasını kullanan güdümlü (supervised) bir öğrenme sistemidir.

² <https://www.plantsnap.com/>

5. Robotik: Bilgisayarla görme, robot konumunu, ortam haritasını, giriş ve çıkış yollarını, uzak durma sınırını, vb. unsurları tamamlamak için, robotun verileri toplamasına yardımcı olmaktadır.
6. Tıbbi analiz: Nesne tanıma, taranmış görüntülerde kanser, tümör vb. tespiti için kullanılabilmektedir.
7. Optik Karakter Tanıma: Taranmış PDF belgelerindeki karakterleri tahmin etmek için nesne tanıma teknikleri kullanılabilmektedir.
8. İnsan-Bilgisayar Etkileşimi: İnsan hareketlerinin tanınması, insan-makine iş birliği için kullanılabilmektedir. Cep telefonu uygulamaları, akıllı oyunlar, vb. uygulamalar nesne tanımayı kullanabilmektedir.
9. Akıllı Araç Sistemleri: Nesne tanıma, çekilen görüntülerdeki trafik işaretlerini ve ayrıca araçları tespit etmek için kullanılabilir.

1.5 El Çizimi Diyagram Tanıma Sistemi

Görüntülerin dengeli şekilde sayısallaştırılma işlemi filtreleme veya yakalama ile yapılabilir. Dezavantajı ise karmaşık olması, gerçekçi olmaması ve profesyonelce olmamasıdır. Sayısallaştırma işlemi için oluşturulan bilgisayar programları, bir giriş görüntüsünden doğal ve otomatik olarak sayısallaştırılmış grafikler üretmeye çalışmaktadır.

Cep telefonları, normalde sık kullanılan görüntüleri yakalamak için çok kullanılan cihazlardır. Diyagramları çizmek ve bunları dijital cihazlardan yakalamak, ilk bakışta daha basit görünse de bazı sık görülen sorunlar bulunmaktadır. Bu görüntüler çoğunlukla dikkatsizce çekilmektedir. Bu nedenle, sadece doğru bir şekilde çerçevelenmiş bir şekil aramak doğru değildir.

Sıklıkla karşılaşılan diğer bir sorun ise görüntülerin arka planının farklı renklerde olabilmesidir.

Kötü aydınlatmalı odalarda çekilen görüntüler çok fazla gürültü içermekte ve düzensiz parlaklık içermektedir.

Görüntünün boyutu ve ayrıca içerisinde bulunan şeklin boyutu bilinmemekte ve önemli ölçüde değişmektedir.

Son olarak, diyagramlarda bulunan farklı türde nesnelerin ve metinlerin tahmini, tanınmayı daha karmaşık bir görev haline getirmektedir.

Bu faktörlerin tanıma sırasında dikkate alınması gerekmektedir.

1.6 El Çizimi Tanımaya Genel Bakış

El çizimleri insanlar tarafından makineler ve dokunmatik ekran cihazları aracılığıyla başkalarıyla iletişim kurmak için kullanılmaktadır. El çizimi tanıma, el çizimi tabanlı arama motorları, oyun tasarım planı, çocuk eğitimi vb. çeşitli uygulamalarda kullanılabilmektedir.

1.7 El çizimi Tanıma Çeşitleri

El çizimi, akış şemaları ve diyagramları oluşturarak insanlar tarafından kullanılan bir iletişim yoludur. Bu günlerde, dokunmatik ekranlı cihazların genişleyen dönemi olarak, el çizimi görüntüleri algılamak ve akış şeması / grafiklerini sayısal şekillerine dönüştürmek çok fazla istenmektedir. El çizimi tanıma yirmi yılı aşkın bir süredir araştırılmaktadır. Analistler çeşitli elle çizilmiş şekilleri, örneğin görüntüleri, akış şemalarını, el çizimi veya genel öğeleri algılamaya çalıştılar. El çizimi tanıma çok yönlü doğası açısından iki sınıfa ayrılabilir; basit elle çizilmiş el çizimi tanıma ve karmaşık elle çizilmiş el çizimi tanıma. Birincisi sınıfta taslakta sadece bir nesne olmakta, diğeri ise bu varsayıma bağlı olmamaktadır. Tanıma algoritması çeşitleri arasında hareket (gesture) tabanlı, görünüş (appearance) tabanlı, geometri tabanlı veya bunların karışımları sayılabilir.

1.7.1 Görünüme Dayalı Tanıma

Görünüme dayalı metotlar, şeklin görsel görünümüne bağlıdır ve çizim çeşitlerine karşı yüksek dayanıklılığa sahiptir.

Nesne tanıma yaklaşımları iki gruba ayrılabilir: Nesne karakterizasyonu ve belirgin nesne tanınması. Nesne gruplama, nesneleri ağaç, insan, araç, bisiklet, vb. genel sınıflandırmalara ayırır. Nesne özelliği tanıma veya ince taneli tanıma, nesneleri kitap kapakları, albüm kapakları, tüylü yaratık türleri, araç çeşitleri vb. tanımaktadır.

1.7.2 Geometri Tabanlı Tanıma

Geometrik tabanlı metotlar, nesneleri geometrik özellik vektörleri olarak betimlemeye çalışmaktadır. Geometri, nesnelerin boyutunu ve şeklini doğru olarak tahmin etmek için kullanılmaktadır. Bu nedenle, nesnelerin doğru tanınması çeşitli araştırmacıların ilgisini çekmektedir. 16. yüzyılın ortalarında, örneğin; René Descartes ve Pierre De Fermat gibi matematikçilerin geometri alanında önemli katkıları bulunmuştur.

1.8 Çevrimdışı ve Çevrimiçi El Çizimi Tanıma

İnsan iletişimi farklı dönemlerde, çeşitli şekillerde yapılmıştır. İnsanların kullandığı iletişim biçimlerinden biri el çizimidir. Eski zamanlarda, çeşitli mağaralarda ve piktogramlarda iletişim çizimi görülebilmektedir. Son zamanlarda el çizimler dijital forma dönüştürülerek gerçekleştirilmektedir. Bu elle yazılmış nesnelerin sayısallaştırılması, daha fazla ilgiyle yapılması gereken çok karmaşık bir görevdir.

Dokunmatik ekranlı aygıtların sayısının artması ile elle çizilmiş el çizimi üretimi de artmıştır. Elle çizilmiş el çizimlerin tanınması için farklı teknikler geliştirilmiştir. Bu teknikler, elle çizilmiş el çizimi tanıma için hem çevrimiçi hem de çevrimdışı prosedürler kullanılmaktadır. Daha önce tanıtılan çeşitli teknikler ve yöntemler hem çevrimiçi hem de çevrimdışı elle çizilmiş el çizimlerin doğru bir şekilde tanınmasına yardımcı olmaktadır.

1.9 El Yazısı Karakter ve Diyagram Tanıma


El Yazısı Tanımada (EYT) amaç, el yazısı karakterleri veya kelimeleri bilgisayarın anlamasını sağlamaktır. Giriş aygıtları genellikle bir kalem ve hassas bir ekrandan oluşmaktadır. Tek karakterlerin tanınmasından başlayarak, tüm kelimelerin ve el yazısı cümlelerin tanınmasına kadar çok sayıda EYT derecesi vardır. Apple Newton³ EYT özelliği bulunan öncü aygıtlardandır. Tanıma hassasiyeti genellikle mükemmel değildi. Newton, çalışma çerçevesinin basılı içeriğin giderek daha iyi tanınmasını sağladı. İlk Apple Newton cihazının satıldığı Xerox PARC'den Goldberg ve diğerleri (1993), tamamen farklı bir metot hakkında bir makale "Unistrokes" yayınladılar. Çeşitli açılardan, Unistrokes Newton'un doğrudan tersidir. Newton elle mesaj için tamamen düzenli bir strateji

³ <https://www.apple.com/tr/>

vermeye çalışsa da Unistrokes sistemi kendisini benzer kullanımdan tamamen ayırdı. Unistrokes, tanıma doğruluğunu ve içerik geçiş hızını iyileştirmeye çalıştı.

1.9.1 Kullanıcı Giriş Modelleri

Grafik girişi için el çizimi tabanlı bir platform, Şekil 1.2 ile gösterilmektedir.



Şekil 1.2 El çizimi tabanlı grafik giriş aracının çerçevesi (Zhengxing ve diğerleri, 2005)

1.9.2 Giriş El çizimlerin Eldesi

Görüntü elde etme, dünyadan bir kamera kullanarak veya etkin erişilebilir bir cihaz ekranında direk çizerek elde edilen görüntü ile dijital yapıya geçmektir. Bilgisayar ortamına alınmış görüntünün, ön işleme aşamasına alınmasında fayda vardır.

1.9.3 Ön İşleme Teknikleri

Ön işleme, nesne tanımanın temel bir aşamasıdır. Ön işleme, dijital görüntü çizimi, gürültü filtreleme (açıklıkların doldurulması, sınırların temizlenmesi) vb. görevleri uygulamaktır. Bunun yanında, çeşitli el çizimi görüntü boyutlarını tek bir boyuta dönüştürmek için kullanılmaktadır. Gürültü filtreleme, görüntüde önemsiz bilgileri atmak için kullanılmaktadır. Bu, sonraki aşamaların doğruluğunu artırmaktadır.

1.9.4 Bölütleme

Bu aşamada, giriş görüntüsü nesnelere bölünmektedir. Görüntü bölütlemesi; girdi görüntüsünü farklı faktörlere göre birden fazla parçaya bölme işlemidir. Bölütleme, ilgilenilen bölge parçası özelliklerinin kalan görüntü özelliklerinden ayrılmasına yol açmaktadır.

1.9.5 Özellik Çıkarımı

Bu düzeyde, görüntüyü az ve etkili şekilde temsil eden faktörler çıkarılmaktadır.

1.9.6 Sınıflandırma

Sınıflandırma aşamasında, yukarıdaki aşamadan çıkarılan özelliklerle, bir sınıf nesnesi diğerinden ayrılmaktadır.

1.10 El Çizimi Tanıma Zorlukları

Çizim tanıma, el çizimi girişi çizim görüntüleri ile eşleştirme işlemidir ve benzer görüntü veri tabanlarını bulmaktadır. Tanınan öğeler ve tasarımlar, el çizimi anlama prosedürlerinin önemli bir parçası olacaktır. El çizimi tanıma verilerin değişkenliği ve belirsizliği ele alma zorlukları yaşanmaktadır. El çizimleri algılamak için sağlam bilgisayar programları oluşturmak zordur. Grafikler ve görüntüler, hatta görünüşte yapısal olanlar bile bunlara dâhil edilmektedir. Birinci engel, bu değişken veri kaynaklarının birkaç açıdan istisnai bir faktör olduğu ve bu tutarsızlığa uyum için genel yöntemlerin halen oluşturulmamasıdır. Bu genel zorluğu gidermek için, çeşitli verileri tanımak ve her bir veri çeşidi için uçtan uca modeller oluşturmak önemlidir. El çizimi görüntülerin birden fazla nesne çeşidi ve sayısı içermesi zorlukları artırmaktadır

1.11 Araştırma Problemi

El çizimdeki ve görüntülerdeki kapalı şekil nesnelerin ve yapıların teşhisi ve tanınması, önümüzdeki yıllarda el ile yazılan belgelerin dijitalleştirilmesi nedeni ile çekici bir analiz fikri olarak görülmektedir. Havza çizgi bağlı nesnelerde kapalı şekil tanıma için

kullanılabilen bir görüntü bölütleme algoritmasıdır. Havza algoritması, gürültü tekdüze olmadığına aşırı bölütlemeye neden olmaktadır.

1.12 Kullanılan Veri Kümeleri

Bu araştırma çalışmasında, çevrimiçi tanıma için üç veri kümesi kullanılmaktadır. Bunlar, Akış Şeması (FC) veri tabanı (Bresler ve diğerleri, 2016), Sonlu Otomata (FA) veri tabanı (Bresler ve diğerleri, 2014) ve Dijital Lojik Devresi (DLD) veri tabanıdır (Indermühle ve diğerleri, 2010).

1.12.1 Akış Şeması (FC) Veri Kümesi

Akış şemaları, farklı oklar kullanılarak bağlanan, çeşitli şekiller ve nesneler içeren çizimlerdir. FC veri kümesi⁴ 672 akış şeması çizimi içermektedir. Burada 24 kullanıcı tarafından, 28 çizim kalıbı çizilmiştir. Bu veri tabanında bulunan toplam el çizimi sayısı, eğitim ve test olmak üzere iki türe ayrılmıştır. Bu veri tabanı, çeşitli metin ve sembollerin anlamlarını, gerekli açıklamalarla birlikte içermektedir.

1.12.2 Sonlu Otomata (FA) Veri Kümesi

Sonlu otomata da ok tabanlı çizimlerdir. FA veri kümesinde⁵ iki şekil vardır. Bunlar; daire ve oklardır. Bu veri tabanında, 12 el çizimi deseninde 300 el çizimi bulunmaktadır. Bu çizim desenleri 25 kullanıcı tarafından çizilmiştir.

1.12.3 Dijital Mantık Devreleri Veri Kümesi

Dijital mantık devreleri, kabarcık veya daire, normal kapılar ve konsantre eğri kapılar (X-OR gibi) olmak üzere, üç tip sembol sınıfı içeren çizgi tabanlı çizimlerdir. Değerlendirme için dikkate alınan semboller, daire (bubble), OR, AND, NOT, NOR, NAND ve X-OR'dur. Bu veri tabanındaki metin blokları A, B ve C girişlerini ve Y çıkışlarını adlandıran tek bir metindir. Bu çalışmada, SKETRACK yönteminin tanımını birleştirdiği için, X-NOR ve diğer

⁴ <http://cmp.felk.cvut.cz/~breslmar/flowcharts/index.html>

⁵ http://cmp.felk.cvut.cz/~breslmar/finite_automata/index.html

karmaşık yapılandırılmış el çizimlerden kaçınılmaktadır. Bu araştırmanın DLD çizimleri, IAMonDo⁶ veri tabanından çıkarılmaktadır. Eğitim ve test için ayrı ayrı kategorize edilen, 15 kullanıcı tarafından 10 farklı çizim desenine dayanarak toplam 150 örnek el çizimi toplanmaktadır.

1.13 Tezin İçeriği

Tezin genel organizasyonu aşağıda verilmektedir:

Bölüm 1'de, çevrimiçi el çizimi tanıma hakkında genel tartışma ve tanıtım verilmektedir. Ayrıca, el çizimi diyagramlarının, farklı tip ve çeşitleri tanıma prosedürleri ayrıntılı olarak tartışılmaktadır. Çeşitli yazarlar tarafından sunulan farklı mevcut araştırma teknikleri hakkında tartışılmaktadır. Farklı çevrimiçi el çizimi tanıma teknikleri ve çalışma prosedürleri ayrıntılı olarak tartışılmaktadır. Farklı mevcut araştırma tekniklerinden çıkarımlar da verilmektedir.

Bölüm 2'te, Gridshed algoritması kullanılarak, kapalı şekil nesne tanıma hakkında tartışma sunulmaktadır. Bu bölüm, önerilen araştırma tekniğinin çalışma prosedürü ve işleme akışı hakkında ayrıntılı tartışma sunmaktadır.

3. bölümde darbeye dayalı olarak yapılan çevrimiçi elle çizilmiş el çizimi tanıma hakkında tartışma verilmektedir. Bu bölümde, SKETRACK'ın çalışma modelleriyle birlikte ayrıntılı bir genel bakış sunulmaktadır.

Bölüm 4'te önerilen araştırma teknikleri farklı performans ölçütleri açısından karşılaştırılarak araştırma çalışmasının performans analizi verilmiştir.

5. bölümde, araştırma çalışmasının sonucu ve gelecekte yapılabilecekler tartışılmaktadır.

⁶ <http://www.fki.inf.unibe.ch/databases/iam-online-document-database>


EL ÇİZİMİ OKLAR İLE BAĞLI DİYAGRAMLARDA KAPALI ŞEKİLLERİN TANINMASI

Gerçek dünyada, elle yazılmış figürleri ve belgeleri, dijital formata dönüştürmeye odaklı çeşitli araştırmalar yapılmıştır. Elle yazılmış belgelerin sayısallaştırılması, çeşitli nedenlerle yapılmaktadır. Daha yeni tekniklerin, daha yeni cihazların yardımıyla ve belgelerin dijitalleştirilmesiyle çözülebilmektedir. Elle yazılmış belgelerin zarar görmesi ve bozulması, içerik kaybına yol açan diğer bir nedendir. Belgelerin dijitalleştirilmesi, bu sorunu çözebilir ve ayrıca önemli bilgiler kayıpsız olarak yeni nesile aktarılabilir. Dijitalleştirmenin üçüncü nedeni ise, elle yazılmış belgelerin her kullanıcı tarafından erişilebilirliğinin zor bir iş olmasıdır. Sayısallaştırmanın bir diğer önemli nedeni ise, akıllı telefonların ve dijital kalemliğin artan şekilde kullanılmasıdır. Dijital olarak çizilmiş içerikler ile kağıt üzerinde çizilen içerikler arasında çok fazla fark vardır. Belgelerin dijitalleştirilmesi, bu sorunların üstesinden gelinmesine ve dijital belge okumasında performansın artmasına yardımcı olmaktadır.

Bu kısım, el çizimlerde kapalı şekilleri tanımlamak ve çıkarmak için, Havza algoritmasını hızlandıran Gridshed algoritmasını tanıtmaktadır. Çalışmada popüler FC veri tabanı (Bresler ve ark. 2016) kullanılmıştır. Metod, daha yakın darbelerin kenarlarını bağlama ve sembol çıkarma aşamasını gerçekleştirmek için, görüntünün boş hücre bloklarını birleştirme fikrini kullanmaktadır.

2.1 Kapalı Şekiller

Kapalı bir şekil, çizimin kendisini ve sınırlı bir iç alanı karakterize etmektedir. Kapalı şekil çiziminde bir noktadan başlanır, şekil çizilir ve başlanan noktaya varılır. Ayrıca çizim sırasında hiç kesişme yaşanmaması şarttır (Şekil 2.1 (a, b)). Bu nedenle kapalı şekiller, açık şekillerde bulunmayan çeşitli varsayımları içermektedir (Şekil 2.1 (c, d)). Kapalı bölgenin şekli, çeşitli yollarla parametrelendirilebilir. Ancak, tanıma işlemi sırasında hangi şekil özelliklerinin önemli olabileceği net değildir. Bilinen açık şekil keşif yöntemlerinin, kapalı şekillerde işe yarayıp yaramayacağı veya tüm yapıları kapsayan yeni yöntemlerin sunulup sunulmayacağı belirsizdir.



Şekil 2.1 (a)(b) Kapalı şekil örnekleri (c)(d) Açık şekil örnekleri

Şekil kapanması, şekil bileşenleri arasındaki birleştirilmiş komşuluk ilişkilerinin ötesinde bir algılama avantajı sağlayabilir. Örneğin; bir şeklin perspektif oranı hakkındaki kararlar, şekil kapalı olduğunda, açık olduğundan daha kesindir. Kapalı şekiller açık olanlardan daha verimlidir. Bu da onları hatırlama ve tanımda elverişli bir konuma sahiptir.

Aktif kontur modeli (Kass ve diğerleri, 1988), bazen Yılan Algoritması olarak bilinir ve doğal görüntülerdeki kapalı şekilleri keşfetmek için etkili bir şekilde kullanılmaktadır. Örneğin; Kenarsız Dinamik Kontur (Edgeless Dynamic Contour) algoritması (Ye ve Zhan, 2009), farklı türdeki görüntülerde, hatta aşırı gürültülü görüntülerde şekilleri keşfedebilmektedir. Ayrıca bu algoritma, sınırı keskin olmayan nesneler arasındaki sınırları keşfetmek için kullanılabilir.

2.2 Havza İle Sembol Tanıma


Havza segmentasyon algoritması, bir görüntünün topografik bir kabartma olarak gösterilmesine bağlıdır. Burada, görüntünün bileşen sayısı tahmini rengine bağlıdır. Bu algoritma hem iki boyutlu hem üç boyutlu görüntüleri işleyebilir. Böylece bileşen, piksel ve voksel (bir pikselin 3 boyutlu karşılığıdır) terimleri kullanılmaktadır. Kabartma, alçakta bulunan vadiler, yüksek tepeler ve yamaçlardan oluşmaktadır. Segmentasyonun temel amacı; havza toplama alanları arasındaki sınıra karar vermektir (Şekil 2.2).

Algoritma, en az yükseklik tabanından başlayarak, çeşitli renkli sular ile, yavaş yavaş tüm tutma havzalarını doldurur. Havza Algoritması, çeşitli havzalardan gelen suyun bir araya geldiği noktalarda havza çizgisi denen bölücü sınır koymaktadır. Su coşması en uç noktasına ulaştığında, prosedür durmakta ve böylece her tutma havzası hatları ile sabitlenmektedir. Su coşması en uç noktasına ulaştığında, prosedür durmakta ve böylece

her tutma havzası hatları ile sabitlenmektedir. Bu prosedürü taklit etmek için, Meyer (1994) tarafından önerilen algoritma aşağıdaki adımlardan oluşmaktadır:

Görüntüdeki tüm renkler bulunur ve renkler yerel minimumları temsil etmektedir.

1. Renk değerlerine göre, yerel minimumlar seviyeli bir şekilde yerleştirilmektedir. Örneğin; gri bir görüntüde renkler 0-255 değer arası oynamaktadır. Her renk bir seviye miktarı olarak görülmektedir. Koyu renk düşük seviyede olup, açık renk yüksek seviyede olmaktadır.
2. Yerel minimum, değeri düşük olan renklere doğru seçilmektedir. Aynı renk değerinde olan yerel minimum olasılığı da mevcuttur.
3. Yerel minimum, aynı değere sahip komşu pikselleri toplamaktadır. Bu işlem su taşması simülasyonuna benzemektedir.
4. Toplama, başka renkler ile karşılaştığında bu yöndeki işlem durdurularak başka yöne devam etmektedir. Durduğu noktaya havza sınır işareti koyulmaktadır.
5. Tüm vadi dolduğunda, tepeye yetişmiş ve toplama alanı oluşmuş sayılır. İşlem sonlanır ve bir başka yerel minimuma geçilir.



Şekil 2.2 Havza algoritmasının diyagramı, Kaynak: Rashwan ve diğerleri (2009)

2.3 Önerilen Gridshed Sembol Tanıma Algoritması

Bu bölümde, el çizimi tanıma için bir çerçeve oluşturulmaktadır. Elle yazılmış grafik tanıma, çevrim dışı ve çevrim içi olmak üzere iki türdür. Çevrimdışı grafik tanıma; kâğıda veya baskıya çizilen çevrim dışı grafikleri tanıyan grafik tanıma yöntemidir. Çevrimiçi el çizimi tanıma; elle veya bilgisayarlı kalem benzeri bir şeyle çizilen el çizimleri algılamak içindir. Böyle bir el çizimin tanınması, müşteri ilişkisini yükseltebilir. Çevrim içi el yazma

verileri üç aşamada yaratılabilir. İstemci parmağını ekrana koyar, bir şey çizmek için parmağını sürükler ve parmağını ekrandan çeker. Çerçeve, zamana ek olarak parmağın hareket ettiği noktaları saklar, belirli cihazlar için basınç ve aç değeri de kaydeder. Bizim önerdiğimiz bu çerçeve, çevrim içi çizimlerdeki kapalı şekilleri tanımlamak içindir. Akış şemaları, özellikle 'İşlem-Process', 'Veri-Data', 'Karar-Decision', 'Sonlandırıcı-Terminator', ve 'Ok-Arrow' görüntülerini içeren, çevrim içi çizim örnekleri olarak seçilmektedir. Çalışmada akış şemalarında metin yazı örnekleri işleme alınmamaktadır.

Şekil 2.3 önerilen yaklaşım için akış şemasını göstermektedir. Çerçeve, çevrim dışı çizim grafikleri için de uygundur. Çevrim dışı çizim verileri, çerçeve işlemine girilebilmesi için bilgisayarlı türe dönüştürülmesi gereken kâğıda çizilebilir veya basılabilir. Çevrim dışı verilerdeki ana sorun, gürültüyü filtrelemek için ekstra prosedürler gerektirebilmesidir. Önerilen çerçeve önişleme, segmentasyon ve gruplama işlemleri gerçekleştirmektedir. Bu prosedürler için, önce darbelerin uçları kümelenmeli ve boş hücreler birleştirilmelidir.



Şekil 2.3 Önerilen sistemin akış şeması


2.4 Önişleme

Önişleme adımı, giriş veri tabanından gelen girdi akış şeması, çerçeve tarafından işlenecek şekle getirilmektedir. El çizimi verisi, aç oranını değiştirmeden pencereye

sığacak şekilde yeniden boyutlandırılmalıdır. Yeniden boyutlandırma prosedürü, diyagramdaki darbelerde iki ardışık piksel arasındaki mesafe çok büyük olduğundan, algoritma işleme hızını arttırmak için uygulanmaktadır. Başlangıç olarak, FC veri tabanı grafiklerinin normal boyutu incelenmektedir. Grafiklerin boy bileşeni yaklaşık 30000×15000 pikseldir. El çizimi 2000×1000 piksele yeniden boyutlandırılmaktadır. Bu normalleştirme prosedürü, tüm FC veri tabanının genel hesaplama süresini 2.5 saatten 5-7 dakikaya indirmektedir.

2.5 El Çizimi Görselleştirmenin İyileştirilmesi


Kapalı nesne tanıma çerçevesinin bir sonraki adımı, el çizimin iyileştirilmesidir. El çizimlerde dikkat çeken bir durum, çeşitli sembollerin ardışık darbelerinin her zaman bağlı olmamasıdır. Kapalı şekil tespiti için, ilk önce bu bağlı olmayan darbeler, tanıma modeline yükseltilmiş el çizimi görüntüleri verecek şekilde bağlanmalıdır. Bu darbeleri bağlamak için, uç noktalar ilk adımda sabitlenir (bkz. Şekil 2.4).



Şekil 2.4 Darbe noktalarının basit gösterimi

Bağlantı prosedürü, 2 uç nokta arasını birleştiren herhangi bir el çizimi algoritması kullanılarak gerçekleştirilmektedir. Bu nedenle, değişkenlerin başlangıç ve bitiş noktaları arasındaki bir aralıkta, enterpolasyonunu sağlayan Dijital Diferansiyel Analizörü (Digital

Differential Analyzer, DDA) (Matsushiro, 1998) çizgi üretim algoritması kullanılmaktadır. DDA algoritması iki nokta arası piksellerden çizgi üretmektedir. İki piksel çizginin uçları olarak gösterilmektedir. Uçlar arası eğim değeri hesaplanır, sonra bir uçtan diğer uca kadar ara pikseller eklenmektedir. Üretilen her piksel bir önceki piksel değeri adapte edilerek hesaplanmaktadır. Bu bağlantı prosedürü, kapalı şekillerin tanınmasında önemli bir rol oynamaktadır. Şekil 2.5, ardışık darbeleri bağlayarak çizim geliştirme prosedürünü göstermektedir. Şekil 2.5a'da, mavi noktalar ilk diyagram nesnelerini, kırmızı noktalar ise iki yakın darbe uç noktalarını bağlamak için sistemimiz tarafından eklenen verileri ifade etmektedir. Şekil 2.5b'de yeşil noktalar ardışık iki noktayı entegre etmek için üretilmiş çizgiler de dahil olmak üzere, iyileştirilmiş el çizimin son halini göstermektedir.




Şekil 2.5 El çizimlerin iyileştirilmiş görseli

2.6 Gridshed Kapalı Bölgeler Çıkarma Algoritması

Tanıma çerçevesindeki son prosedür, hücre birleştirme yoluyla sembol çıkarımıdır. Akış şemaları tamamen kapalı şekillerden oluştuğundan, kapalı şekillerin algılanması çoğu kez daha kolaydır. Önerilen model, akış şeması grafiğini içeriklere ayırmak için bir teknik kullanmaktadır. Bir darbenin temel bir özelliği boyutudur. Sınırlayıcı Kutu (Bounding Box) Genişlik, Yükseklik, Alan ve Ark uzunluğu olarak adlandırılan dört özellik ile tarif edilebilmektedir. Bu dört özellik, minimum koordinat hizalamalı sınırlayıcı kutuların

özellikleridir. Önerdiğimiz yöntem, bir darbenin kapalı şeklin darbe kümesine ait olup olmadığını çıkarmaktadır. Bu metotları kullanarak tanıma stratejisi, boş hücreleri birleştirip kapalı şekli tanımlamayı planlamaktadır. Çıkarılan kapalı şekiller aday sembollerini ifade etmektedir.



Şekil 2.6 Hücreleri birleştirerek önerilen sembol çıkarma işlemi için elde edilen sonuçlar (a) Basit el çizimi akış diyagram örneği (b) (c) Diyagram hücrelere bölünüp

kenarlardan boş hücreler silinir (d)(e)(f) Rastgele boş hücre seçilip benzer komşu hücreler

Şekil 2.6, örnek bir el çizimi üzerinde önerilen yaklaşımı kullanarak, sembollerin çıkarılması işlemini adım adım göstermektedir.

Kapalı şekillerin çıkarılması stratejisi aşağıdaki gibi verilmektedir:

- 1) Görüntü matrisi ($n \times n$) boyutundaki hücrelere bölünür (Şekil 2.6 (b)).
- 2) Çalışma alanı sınırlayıcı kutuya indirgenerek görüntü kenarlarındaki boş hücreler silinir (Şekil 2.6 (c)).
- 3) Rastgele bir boş hücre seçilir (Şekil 2.6 (d)).
- 4) Seçilen boş hücrenin komşu hücreleri analiz edilir.
 - a. Eğer komşu hücre de boş ise, iki hücre bir bölgede birleştirilir (Şekil 2.6 (e)).
 - b. Aksi takdirde akım yönündeki birleştirme durur.
- 5) Komşu boş hücreleri birleştirme işlemi, hiçbir yönde boş hücre kalmayana kadar sürdürülür. Piksel verileri içeren hücreler, kapalı şekil nesnelerini temsil etmektedir (Şekil 2.6 (f)).
- 6) Kalan boş hücreler varsa 3. adıma geçilir. Aksi takdirde işlem bitirilir.
- 7) Sonuç kapalı şekiller alınır (Şekil 2.6 (g)).

2.7 Özet

Önerilen Gridshed, el çizimi darbelerini iyileştirmek için DDA bağlantı prosedürünü kullanır ve daha sonra boş hücrelerin birleştirilmesiyle nesnelerin darbelerini çıkarır. Akış şeması veri tabanında yürütülen testler, önerilen Gridshed'in mevcut havza tanıma algoritmasından daha yüksek tanıma oranı ve daha az hesaplama süresi ile daha iyi sonuçlar verdiğini göstermektedir.

SKETRACK: ÇEVİRİMİÇİ EL ÇİZİMLERİNİN DARBE-TABANLI TANIMLANMASI

Tezin bu bölümünde, el çizimi görüntülerinin doğru ve verimli bir şekilde tanınması için, bir darbe tabanlı çevrim içi serbest el çizimi tanıma yöntemi (SKETRACK) sunulmaktadır. Önerilen bu yöntem, doğru tanıma oranını sağlamak için üç adımı gerçekleştirmektedir. Bunlar segmentasyon, özellik çıkarma ve sembol tanımadır.


Önerilen araştırma çalışmaları, FC, FA ve DLD veri tabanları olmak üzere üç veri tabanı üzerinde test edilmiştir.

Önerilen araştırma çalışmasında, başlangıçta girdi veri tabanları, gürültüleri filtrelemek ve kenarları ayarlamak için normalleştirilmektedir.

Normalleştirdikten sonra, metin içeriğini, şekil içeriği görüntülerinden ayırmaya çalışan segmentasyon işlemi başlatılır. İçerik segmentasyonu sürecinin temel amacı, girdi verilerinden, girdi verileri hakkında hiçbir anlamı ve açıklaması olmayan metinleri çıkarmaktır. Segmentasyonun ile, metin ve semboller birbirinden ayrılır ve dolayısı ile semboller metinden bağımsız olarak işlenebilir. Böylece, toplam işlem karmaşıklığı önemli ölçüde azaltılabilmektedir.

Segmentasyondan sonra, farklı darbe yapısal özelliklerinin çıkarıldığı ve veri tabanında saklandığı özellik çıkarma işlemi gerçekleştirilmektedir.

Özellikler çıkarıldıktan sonra, benzer darbe özellik bilgisini spektral kümeleme algoritması kullanarak gruplamak için, sembol özellik kümeleme gerçekleştirilmektedir. Bu spektral kümeleme algoritması, benzer yapı özelliği bulunan bilgilerin birlikte gruplandırılmasını sağlamaktadır. Özelliklerin boyutu yüksek olduğunda, işleme karmaşıklığı artacaktır. Boyutsal azaltma gerçekleştirilerek, önerilen araştırma tekniğinde bundan kaçınılır. Burada P-uzaklığı ölçüsü ve Öklid mesafe ölçüsü, boyut sayısı azalmasının gerçekleşmesine bağlı olarak, çıkarılan her özellik için hesaplanır. Son olarak, giriş sembollerinin tanınması MDVM sınıflandırıcısı kullanılarak gerçekleştirilmektedir. Önerilen araştırma çalışmasının toplam işleme akışı, Şekil 3.1'de gösterilmektedir.




Şekil 3.1 SKETRACK Tanıma işleme akışı

3.1 Ön İşleme

Girdi veri tabanları semboller, ek açıklamalar ve çeşitli semboller arasındaki ara bağlantılardan oluşur. Önerilen araştırma yönteminin ilk adımı normalleştirme

yapmaktır. Normalleştirme, gürültüleri çıkararak ve kenarları ayarlayarak, giriş sembollerini sisteme uygun bir formata dönüştürmek için kullanılmaktadır. Normalleştirme, giriş görüntülerinde bulunan gürültü sorununu çözmek için kullanılmaktadır.

İçeriğin giriş sembollerinden ayrılması için, Derin Öğrenme Özyinelemeli Sinir Ağı (Deep Learning Recurrent Neural Network, DÖÖSA) kullanılmaktadır. Bu çalışmanın temel amacı, içerik gruplaması yaparak metin içeriklerini giriş sembollerinden ayırmaktır. Önerilen DÖÖSA, dâhili bellekteki giriş sembolünün darbelerini işlemektedir. Bu normalleştirme işlemi, el yazısı, konuşma ve nesnelerin tanınması gibi birçok yararlı uygulamada kullanılabilir. DÖÖSA, bilgi döngüsü ve giriş sembolü görüntüleri hakkında kısa süreli bellek oluşturmaktadır. Bu yöntem, sembol tanımının doğruluğunu artırır. DÖÖSA, FC, FA ve DLD olmak üzere her üç giriş veri tabanına da uygulanmaktadır. DÖÖSA uygulanarak, üç veri tabanı için elde edilen doğruluk değeri gösterilmiştir. FC veri tabanı için şekil doğruluğu %99,56 ve metin doğruluğu %97,7 oranı elde edilirken, FA veri tabanı için %98,8 ve %99,76, DLA veri tabanı için %99,12 ve %94,88 olarak elde edilmiştir. FC veri tabanı için elde edilen bir metin ayırma sonucu, aşağıdaki Şekil 3.2'de gösterilmektedir. Bu şekilde, girdi figürünün semboller, metinler ve oklar içerdiği öğrenilebilir. Görüntü kalitesinde azalma hataya yol açar ve sembol sınıflandırıcısı kullanılarak azaltılabilir.



Şekil 3.2 FC veri tabanından bir girdi imgesinden ayrılan metinler

El çizimi yapısal analiz aşamasında, girdi sembollerinden ayırt edilmiş metinler de işlenir.

3.2 Özellik Çıkarma

Ön işlemten sonra, özellik çıkarma işlemi gerçekleştirilir. Özellik çıkarma modelinde, benzer türde sembol darbe yapısı bilgisi bulunacaktır. Her giriş veri tabanı için, başlangıçta anlamsal darbeler tanımlanacaktır. Özellik çıkarma işlemi, girdi veri tabanlarında bulunan her bir sembol için yapılmaktadır. Özellik çıkarma işlemi eğitim veri kümelerinde de gerçekleştirilir. Anlamsal darbe atamasından sonra, benzer karakteristikleri paylaşan semboller, benzer sembol kümesi oluşturmak için birlikte gruplandırılacaktır. Bununla birlikte, OR, NOR gibi bazı semboller, aynı olmasalar bile benzer özellikleri paylaşırlar. Böylece, bazı yanlış tanıma sonuçları olacaktır. Bu sorun, giriş sembolü görüntülerindeki daha düşük kalite nedeniyle oluşmaktadır.

Giriş çizim görüntüleri tüm gerekli sembollerden oluşmaktadır. Aynı giriş sembolünden benzer darbeler birlikte gruplandırılacaktır. Etkili grupta sonuçları, kümeleme algoritması yardımıyla ve özellik boyutunun azaltılması ile gerçekleştirilmektedir. Önerilen araştırma çalışmasında, toplam 29960 örnek eğitim sembolü alınmıştır. Bu el çizimi görüntülerinden optimum özellikler seçilmektedir. Artan özellik sayısı, zaman tüketimi de önemli ölçüde artacaktır. Bu nedenle, artan zaman tüketimine odaklanmak gerekmektedir. Bu, p-uzaklığı ve Öklid mesafesi ölçüsü uyarlanarak yapılmaktadır. Burada p-uzaklığı hesaplama prosedürü aşağıdaki denklem 3.1'de verilmiştir.

$$p_{uzaklığı} = 1 - \frac{\text{similar features}}{\text{total features}} \quad (3.1)$$

P-uzaklığı ölçümü gibi, özellikler arasındaki Öklid mesafesi farklı özellikler arasındaki uzunluk ölçülerek hesaplanır. İki p ve q özelliği arasındaki Öklid mesafesi hesaplama prosedürü aşağıda verilmektedir:

$$Ed(p, q) = Ed(q, p) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2}, (i = 1, 2, \dots, n) \quad (3.2)$$

Bu mesafe ölçümleri kullanılarak, özellik boyutunun azaltılması gerçekleştirilmektedir. Özellik azaltma işleminde, spektral kümeleme tekniği kullanılarak sembol darbelerini kümelenebilir.

3.3 Spektral Kümeleme Kullanarak Sembol Segmentasyonu

Özellik azaltma işlemi, görüntülerin bölümlere ayrılması ve spektral kümeleme kullanılarak yapılmaktadır. Bu kümeler özellik çıkarma modeline dayanarak oluşturulmaktadır. Bu çalışmada, giriş sembolü darbeleri yönlendirilmemiş grafik (undirected graph) G kullanılarak temsil edilecektir. Grafik yapımı dörtlü ağaç (quad tree) T 'nin yardımıyla yapılmaktadır. Yapılandırılmış grafik topolojisine dayanarak, giriş örnekleri için darbe yapısı temsil edilecektir. T 'nin yaprak nodları (leaf nodları) $V = \{v_1, v_2, \dots, v_n\}$ vektörü olarak tanımlanır ve farklı yaprak düğümleri arasındaki bağlantıları (Edges) $E = \{e_{ab} | a, b \leq n\}$ olarak temsil edilir. Bu yaprak (leaf) nodlarından ve bağlantılardan, olay matrisi (incident matrix) I inşası, giriş sembollerinde bulunan farklı darbe türleri arasındaki benzerlik temel alınarak yapılmaktadır. Grafiklerin doğru segmentasyonunu sağlamak için, giriş grafiği eşik değerine göre seyrek graf (sparse graph) tabanına dönüştürülecektir. Eşik değeri (3.3) ile verilir.

$$Th_{I_a, I_b} = 1.05 \frac{\max(x_{map}, y_{map}) * (2^I a + 2^I b)}{2^I a 2^I b} \quad (3.3)$$

(3.3)'te Th_{I_a, I_b} benzerlik matrisinde iki nokta arası (a, b) eşik değerini temsil ederken, x_{map}, y_{map} ise haritalama konumunu temsil etmektedir. 1.05 kayan nokta (floating point) hesaplama hatasını önlemek için eklenen kat sayıdır. Eşik değerinden daha uzun bağlantılar grafiğe eklenmez. Seyrek grafik yapısından sonra darbe segmentasyonu, ağırlıklı tek yönlü grafiğin modellenmesi ile yapılmaktadır. Laplace matris formasyonu kullanılarak doğru ve verimli segmentasyon sonucunu sağlamak için spektral kümeleme yapılır. Laplace matrisi $L_{a,b}^I$ hesaplama prosedürü (3.4)'te verilir.

$$L_{a,b}^I = \begin{cases} 1 & a = b, \deg(v_a) \neq 0 \\ -\frac{1}{\sqrt{\deg(v_a) \deg(v_b)}} & a \neq b \\ 0 & \text{aksi halde} \end{cases} \quad (3.4)$$

(3.4) denkleminde v_a ve v_b graf üzerinde iki yaprak düğüm vektörünü temsil etmektedir, $\deg$ ise v_a derecesini ifade etmektedir. Laplace matrisinin öz vektörleri, aşağıdaki gibi verilen P matrisi kullanılarak hesaplanır:

$$P = [ev_1, ev_2, \dots, ev_n] = \begin{bmatrix} ev_{11} & \cdots & ev_{k1} \\ \vdots & \ddots & \vdots \\ ev_{1n} & \cdots & ev_{kn} \end{bmatrix} \quad (3.5)$$

Yukarıdaki denklemde, her bir P matris satırı örnek sembol darbeleri olarak tanımlanır. Spektral kümeleme sonucu aşağıdaki gibi temsil edilmektedir:

$$Darbe_i = \{P_{ab} | 1 \leq a \leq k, b \in [1, n]\} \quad (3.6)$$

(3.6) denkleminde k alt harita sayısını ve n ise yaprak düğüm sayısını temsil etmektedir. Bu şekilde G grafiği yeterince parçalanabilir. Bu grafik doğrudan sembollerin darbe gruplarını vermektedir.

3.4 Sembol Tanıma

Sembol tanıma, segmentasyon görevinden sonra birlikte gruplanan darbeleri tahmin etme işlemidir. Bu çalışmada, sembol tanıma için MDVM tanıtılmaktadır.

3.4.1 MDVM Kullanarak Sembol Sınıflandırması

Sınıflandırıcının temel amacı, kümelere uygun sınıf etiketlerini atamaktır. Bu çalışmada, uygun sınıf etiketlerinin atanması için çoklu sınıf SVM sunulmaktadır. Genel SVM sınıflandırıcısı tanıma işlemi sırasında bazı sorunlar yaşama eğilimindedir. SVM iki farklı nesne kümesini ayıran en uzak iki düzlemi bulmaya çalışmaktadır. Bu şekilde aday nesnenin düzlemlerin hangi tarafında kalacağına bağlı olarak sınıf etiketlenmektedir. İki düzlemin denklemi (3.7) ve (3.8) ile verilmektedir.

$$w \cdot x + c = 1 \quad (3.7)$$

$$w \cdot x + c = -1 \quad (3.8)$$

(3.7) ve (3.8) denklemlerinde c skalar değeri, w ise hiper düzlemleri ayıran ağırlık vektörünü temsil etmektedir.

SVM Önemli sorunlardan biri, işlem süresinin artması ve çekirdek fonksiyonunun yanlış seçilmesidir. Bu sorunlar, bu yöntemde MDVM modeli adı verilen yöntemle çözülmektedir. MDVM modeli, nesnelerin doğru tanınmasını sağlamak için hibrit bir çekirdek fonksiyonu önermektedir. Hibrit çekirdekte Gauss çekirdeği ve çokterimli (polynomial) çekirdek birleştirilir. Ve sonra Aslan Optimizasyonu (Lion Optimization) algoritması kullanılarak optimum MDVM parametreleri seçilir.

MDVM yönteminin ana amacı, giriş darbelerini çoklu kümelerle ayırabilecek bir hiper düzlem tahmin etmektir. $x_1, x_2, \dots, x_n$ çoklu küme grubu için hiper düzlemleri bulmak amacıyla, x 'in bir kümeyi tanımlayan grafik noktası olarak tanımlandığı MDVM uygulanmaktadır.

Çekirdek fonksiyonunun uygun seçimi, nesne tanıma işleminde önemli bir görevdir. Genel olarak çok kullanılan çekirdekler; doğrusal (linear) çekirdek, radyal temel fonksiyon (radial basis function), çokterimli (polynomial) çekirdek ve sigmoid tanh çekirdek. Bahsedilen standart çekirdek fonksiyonları, SVM algoritması için uygun öğrenme sonucunu sağlamayabilir. MDVM sınıflandırıcısında, Gauss ve çokterimli (polynomial) çekirdek olmak üzere iki çekirdek fonksiyonunu birleştiren hibrit bir çekirdek kullanılmaktadır. Bu çalışmada, radial basis fonksiyonu Gauss çekirdeğin uygulanması için uyarlanmaktadır. K_{RP} hibrit çekirdeği (3.9)'da verilmektedir.

$$K_{RP} = \lambda K_P + (1 - \lambda) K_R \quad (3.9)$$

$$K_P(x_1, x_2) = (\sum_{i=1}^n x_{1i} * x_{2i} + r)^d \quad (3.10)$$

$$K_R(x_1, x_2) = \exp(-g \sum_{i=1}^n (x_{1i} - x_{2i})^2) \quad (3.11)$$

(3.9), (3.10) ve (3.11)'de x_1 ve x_2 verileri, d ise uzaklığı ifade etmektedir. K_P çokterimli (polynomial) çekirdek fonksiyonu (3.10)'de verilmiştir. K_R gauss çekirdek fonksiyonu (3.11)'de ifade edilmektedir.

Genel olarak radial basis fonksiyonu K_R , global çözümlerle sonuçlanamayan lokal bir çekirdektir. Global çözümlere ulaşmak için, bu çalışmada hiper düzlem (hyperplane) daha hızlı yakınsama (convergence) elde etmek için daha uygun bir şekilde seçilmektedir. Bu çalışmada, λ parametreye ince ayar yapmaya çalışan hibrit çekirdek kullanılmaktadır. Bu çalışmada, K_P ve K_R çekirdeklerini birleştirerek hibrit çekirdek K_{RP} tasarlanmaktadır. Ayrıca MDVM performansını güçlendirmek için, bu çalışmada λ parametre optimizasyonu, Aslan Optimizasyon Algoritması kullanılarak yapılmaktadır.

Önerilen çalışma, λ parametresinin optimum seçimi için aslanların avlanma doğasını uyarlamaktadır. MDVM'nin arama işlemi, Aslan Optimizasyon Algoritması uyarlanarak iyileştirilmektedir. Aslan Optimizasyonunda Q , her bir aslan hareketinin hızını av konumu açısından ince ayarlamak için kullanılır. Aslan konumunun güncellenmesi, av konumu değiştirilerek de gerçekleştirilmektedir. Q değeri, mevcut aslan sayısına göre

ayarlanmaktadır. Tek sayıda aslan mevcutsa, Q değeri -1 olarak, aksi takdirde 1 olarak belirlenmektedir. Q değeri -1 ise, aslanların zıt yönde hareket ettiği varsayılır. Yoksa aslanların aynı yönde hareket ettiği varsayılır. Aslanların konumu ve hızı, (3.12) ve (3.13) ile güncellenir.

$$M_{id}(t + 1) = Q\{\omega \times M_{id}(t) + c \times rand() \times X_{id}(t)\} \quad (3.12)$$

$$X_{id}(t + 1) = X_{id}(t) + S_{id}(t + 1) \quad (3.13)$$

d iki özellik arasındaki mesafeyi, $X_{id}(t)$ aslan av konumuna göre önceki pozisyonu, $M_{id}(t)$ aslanın önceki hızını, ω ağırlıklandırma vektörünü (weighting vector), $rand()$ 0 ile 1 arasında rastgele değeri, c ise pozitif sabit bir değeri temsil etmektedir.

3.4.2 Oklar/Çizgi Bağlantı Algılama

Ok ve çizgileri tespit etmek için mevcut çeşitli araştırma teknikleri bulunmaktadır. Ancak bu tekniklerin performans sonuçları memnun edici bir sonuç vermemektedir. Okların görünüşleri açısından tanınması zor bir iştir. Nihai tahmin sonucunu arttırmak için, okların değişen özelliklerinin doğru bir şekilde tahmin edilmesi gerekmektedir. Semboller MDVM sınıflandırıcı kullanılarak tanındıktan sonra bağlantı elemanlarının analiz edilmesi gerekmektedir. Ok algılama işlemi iki adımda gerçekleştirilir. İlk adımda, sürekli darbelerden oluşan semboller bir sembolden başka bir sembole bağlamaya çalışan kuyruk tespiti yapılmaktadır. Bu prosedür, DLD'deki çizgileri tanımayı tespit etmek için de kullanılabilir. Sembol çiftleri MDVM sınıflandırıcısı kullanılarak algılanmakta ve bunları bağlayan ok kuyrukları algılanmaktadır. Sınırlayıcı kutuların boyutu net bir şekilde ayarlanarak giriş sembollerinin darbeleri doğru şekilde tahmin edilebilmektedir. Bu işlem, arama alanının artmasına ve farklı sembol çiftlerinin tahminine yol açacaktır. Sembol darbelerinin arama alanında mevcut olup olmadığını ve kuyruk uzunluğuna uyduğunu tahmin etmek gerekmektedir. Önerilen araştırma metodunun temel amacı, iki sembol arasındaki d_{thresh} genel mesafe eşik değerine göre karşılaştırılan en küçük mesafeyi bulmaktır.

Kuyruk bağlantıları belirlendikten sonra, okların kurulması gerekmektedir. Genellikle kuyruğun herhangi bir yönü yoktur. Kuyruğun yönü sadece ok kafası kullanılarak tanımlanabilmektedir. İkinci adımda, ok kafası kullanılarak algılama yapılmaktadır.

Genellikle kafa ve kuyruk ok sembolü olarak tanımlanmaktadır. Bu çalışmada kuyruğu tespit etmek için tekrarlanan darbe dizisi kullanılmaktadır.

Önceki adımda tanımlanan ok kafalarına mekansal olarak daha yakın olan darbeler, daha sonra diğer darbeler ile girişimlerini bulmak için analiz edilmektedir. Algılanan ok kafa darbeleri, diğer sembol darbeleri ile girişimli olmalıdır. Ok kafalarını doğrulamak için, ok kafa aday listesi oluşturulmakta ve yüksek güven değeri (3.14) ile hesaplanmaktadır (Bresler ve diğerleri, 2014).

$$confidence = shapeConf. distanceConf \quad (3.14)$$

$$shapeConf = \exp(-(z - h). (z + h)) \quad (3.15)$$

$$distanceConf = \exp\left(\ln(0.5). \frac{d_{centroid}}{d_{thresh}}\right) \quad (3.16)$$

Ok kafası darbe adayları sınırlayıcı kutu olarak temsil edilir, z sınırlayıcı kutunun genişliği ve h ise sınırlayıcı kutunun yüksekliğini ifade etmektedir. $d_{centroid}$ sınırlayıcı kutunun merkezinden, kuyruğun bitiş noktası arasındaki mesafeyi ifade etmektedir ve d_{thresh} genel eşik değerini temsil etmektedir.

Ok kafa yönü, ok kafasının kuyruk uç noktasıyla olan ilişkisi ile belirlenebilmektedir. Okun güven değeri tahmini kuyruk güven değeri ve kafanın güven değerleri çarpımıdır. Kuyruk güven değeri, iki uç arasındaki mesafeyi temsil etmektedir. Denklemi (3.17) ile verilmiştir.

$$connectorConf = \exp\left(\ln(0.5). \frac{d_{connector}}{d_{thresh}}\right) \quad (3.17)$$

$d_{connector}$ kuyruğun mesafesidir. Bu güven değerlerine dayanarak ok uçlarının yönü belirlenmektedir.

3.5 Yapı Analizi Ve El Çizimi Tanıma


Yapısal analiz, nesneleri tahmin etmek için SKETRACK çerçevesinde kullanılan son adımdır. ÖYDÖSA yazı metinleri sınıflandırmaktadır. MDVM sembolleri sınıflandırmaktadır. Son aşamada, sonuçlar nihai çıktıyı oluşturmak için birleştirilmelidir. Yapısal analiz, sonuçları birleştirmek ve herhangi bir darbenin dışarıda kalıp kalmadığını kontrol etmek için bu görevi yerine getirmektedir (Şekil 3.3). Yapısal analiz görevi, FC, FA

veya DLD veritabanlarında geçerli bir el çizimini oluşturmaktır ve gruplandırılabilen sembol ve ok / çizgi adaylarını tanımak içindir. Bu sembol aday setlerini bağlamak için, semboller arasındaki ilişki puan değerleri belirlenmelidir. Puan üç temel ilişki tipiyle hesaplanır. İlk tür, iki sembol adayının aynı bağlantı noktasında bir veya daha fazla darbe veya ok paylaştığı ilişkidir. İkinci ilişki, iki sembolün kesişen sınırlara sahip olduğu ilişkidir. Üçüncü ilişkide ise, ok / çizginin bitiş noktalarında iki sembol vardır. Birinci ve ikinci ilişkiler etkili olmakta ve her iki sembol adayında seçilmektedir. Üçüncü ilişki, yapı çözümü için ok seçilirse etkilidir. Güven puanı fonksiyonu çatışma (conflict) ve çakışma (overlap), ilk iki ilişki için modellenmektedir.

Çatışma ilişkisi için, puanlar negatif sonsuzdur. Yani; $s_1 = -\infty$. Çakışma ilişkisi (3.18) ile verilmektedir:

$$s_2 = -S_{R \cap S} / \min(S_R, S_S) \quad (3.18)$$

Diyagramlar, semboller arasındaki ilişkiyi bulduktan sonra tanımlanmaktadır. Tüm diyagramın puanı, seçilen tüm sembol adaylarının puanları ile aralarındaki ilişkilerin toplamı olarak hesaplanmaktadır.



Şekil 3.3 FC veri tabanından bir girdi imgesinden kalan darbe örnekleri

3.6 Özet


Önerilen SKETRACK yöntemi, metin segmentasyonu, özellik çıkarma modeli, sembol segmentasyonu için spektral kümeleme, MDVM sınıflandırıcısı kullanılarak sembol tanıma ve yapısal analizden oluşmaktadır. Bu süreçler, yüksek doğruluk ve minimum yanlış tanıma ile el çizimlerin tanınmasını sağlamaktadır.

4.1 Giriş


Bu bölümde önerilen tekniklerin performans değerlendirmeleri yapılmaktadır. Aşağıdaki alt bölümde, önerilen araştırma tekniklerinin karşılaştırma analizi ve tartışması verilmektedir.

4.2 Kapalı Şekil Nesne Tanıma Sonuçları

Bu bölümde, FC veri tabanına uygulanan kapalı şekil nesne algılama tekniğinin tasarımı gösterilmektedir. Burada önerilen sistemin performans değerlendirmesi, doğruluk ve işlem süresi ölçümleri açısından gerçekleştirilmektedir. Önerilen yöntem, mevcut havza algoritması ile karşılaştırılmaktadır. Bu doğrulukta, sembol tanıma oranı olarak tanımlanmaktadır. FC veri tabanını uyguladıktan sonra, elde edilen sonuçlar aşağıdaki Şekil 4.1'de gösterilmektedir.



(a) Girdi el çizimi



(b) Bölümlenmiş sonuç

Şekil 4.1 FC el çizimi tanıma sonuçlarına örnek

Tablo 4.1, önerilen GridShed tabanlı kapalı şekil nesne algılama sisteminin, tanıma oranını ve mevcut havza yöntemiyle tabanlı nesne algılama ile karşılaştırılmasını göstermektedir.

Karşılaştırmalar, algoritmaların temel performansını değerlendirmek için, DDA el çizimi görselleştirme ve iyileştirmesi eklenmeden yapılmaktadır. Önerilen GridShed yöntemindeki sembollerin tanınmasının, havza algoritmasından daha doğru olduğu görülebilmektedir. İşlem, Veri, Karar, Sonlandırıcı, ve Ok boşlukları sembollerinin çıkarma oranı, GridShed yönteminde havza algoritmasından daha yüksektir. Bu arada Havza (watershed), yalnızca Bağlantı sembolü için daha yüksek tanıma oranı sağlamaktadır.

Tablo 4.1 DDA el çizimi iyileştirme olmadan sembol çıkarma oranı

Semboller	Toplam Sembol Sayısı	Havza Çıkarma Oranı (%)	Sembol GridShed Çıkarma Oranı (%)
İşlem	380	72,36	90,8
Veri	356	67,97	89,9
Karar	224	84,82	97,77
Sonlandırıcı	263	85,17	93,5
Bağlantı	112	95,53	89,29
Ok Boşlukları	195	52,82	76,92


Tablo 4.2, önerilen GridShed ve mevcut havza yöntemi ile, her iki algoritmanın DDA çizim görsel iyileştirmesini kullanmaları arasındaki, sembol tanıma oranı karşılaştırmasını göstermektedir. Bu karşılaştırma sonuçları da önerilen GridShed yönteminin, Havza algoritmasından daha doğru olduğunu ve el çizimi iyileştirmenin dahil edilmesinin, kapalı şekil tanımayı daha da geliştirdiğini göstermektedir. İşlem sembolü hariç, DDA tabanlı el çizimi iyileştirmeli GridShed, DDA tabanlı çizim geliştirmeli Havza Algoritmasından daha yüksek tanıma oranı sonuç vermiştir.

Ayrıca, bulunması gereken önemsiz küçük kapalı şekiller vardır. Bu küçük nesneler, eşik (threshold) nesneleri olarak adlandırılmaktadır. Önerilen sistemdeki küçük nesnelerin sayısı, havza yönteminden çok daha azdır. Çünkü; sembollerin çoğu Gridshed tarafından doğru bir şekilde tespit edilmektedir.

Tablo 4.2 DDA el çizimi iyileştirmesi ile sembol çıkarma oranı

Semboller	Toplam Sembol Sayısı	Havza Çıkarma Oranı (%)	Sembol Oranı	GridShed Çıkarma Oranı (%)	Sembol Oranı
İşlem	380	86,3		80	
Veri	356	88		92,7	
Karar	224	100		100	
Sonlandırıcı	263	92		92	
Bağlantı	112	81,3		87,5	
Ok Boşlukları	195	72		86,7	

El çizimlerinin çoğunda, diğer darbelerle bağlantılı olmayan darbeler vardır (bkz Şekil 4.2 (a)(b)). DDA el çizimlerini iyileştirdikçe, önerilen Gridshed algoritması, havza algoritmasından daha yüksek bir fark ile sembollerin çoğunu algılamaktadır.



Şekil 4.2 (a) (b) Havza tarafından algılanmayan ancak Gridshed tarafından algılanan kapalı şekillerin örnekleri (c) (d) El çizimi iyileştirme sırasında oluşabilecek hata örnekleri

Çizim iyileştirmesi, kapalı olmayan bazı nesneleri yanlış bağlayarak, tanıma aşamasında bazı hatalara neden olabilmektedir. Darbelerin uç noktaları, şekil bozulmasına neden olan, istenmeyen veya alakasız darbelerle bağlanabilmektedir. Bununla birlikte, bu hatalar önerilen sistemde minimal sayıdadır ve bu nedenle ihmal edilebilir. Diyagramdaki bazı sembollerin bozulma şekli (Şekil 4.2 (c)(d)) ile gösterilmektedir. Mavi renk orijinal darbe verilerini gösterir. Kırmızı renk, darbenin uç noktalarını bağlamak için önerilen sistem tarafından eklenen verileri temsil etmektedir.

Gridshed algoritmasının zaman karmaşıklığı (time complexity) $\mathcal{O}(\frac{n}{hw})$ şeklindedir. Burada n giriş boyutu, h hücrelerinin yüksekliği ve w hücrelerinin genişliği olup, hepsi piksel cinsindendir. Havza algoritmasının zaman karmaşıklığı (Time complexity) $\mathcal{O}(n)$ şeklindedir. Sonuç olarak Havza yerine Gridshed kullanıldığında, tüm FC veri tabanı için zaman tüketimi 5-7 dakikaya düşmektedir. Havza ve Gridshed kullanılarak gerçekleştirilen segmentasyonun minimal, maksimum, ortalama ve medyan işlem süresi Tablo 4.3'te gösterilmektedir.

Tablo 4.3 İşleme süresi

Sınıf	İşleme süresi (s)			
	Minimal	Maksimum	Ortalama	Medyan
FC (Gridshed+DDA)	0,4	17,73	4,24	3,6
FC (Gridshed)	0,34	17,43	4,04	3,42
FC (Havza+DDA)	83,6	1073,9	564,2	599,01
FC (Havza)	83,57	1073,73	564,003	598,8

Tablo 4.3'te, önerilen Gridshed algoritmasının, minimum, maksimum, ortalama ve medyan süre açısından Havza algoritmasından daha iyi olduğu doğrulanmaktadır.

4.3 Darbe Tabanlı Tanıma Sonuçları

Bu bölümde FC, FA ve DLD veri tabanları üzerinde önerilen yöntemin sayısal değerlendirmesi yapılmaktadır. Veri tabanındaki karşılaştırma sonuçları Tablo 4.4, 4.5, 4.6'da verilmektedir.

Tablo 4.4 FC veri kümesi için tanıma performansı sonuçları

Metodlar	Doğruluk (Accuracy) (%)	Kesinlik (Precision) (%)	Duyarlılık (Recall) (%)	F-ölçüsü (%)
SVM	84,76	83,45	81,6	86,5
ESA	90,66	89,71	88,72	89,018
ESA-SVM	94,76	94,43	92,8	90,21
Önerilen MDVM	95,87	94,96	91,66	90,17

Tablo 4.4'ten, önerilen MDVM sınıflandırıcısının, FC veri tabanı üzerinde daha iyi doğruluk ve kesinlik oranına ulaştığı görülebilmektedir. Ancak duyarlılık ve F-ölçüsü değerleri açısından, önerilen MDVM, ESA-DVM yönteminden daha düşük, ancak diğer yöntemlerden daha iyi değer göstermektedir.

Tablo 4.5 FA veri tabanı için tanıma performansı sonuçları

Metotlar	Doğruluk (Accuracy) (%)	Kesinlik (Precision) (%)	Duyarlılık (Recall) (%)	F-ölçüsü (%)
SVM	86	83,83	85,5	83,54
ESA	90,23	88,13	89,30	88,87
ESA-SVM	93,22	93,95	92,16	90,85
Önerilen MDVM	94,99	94,31	94,13	91,46

Tablo 4.5'ten, önerilen MDVM sınıflandırıcısının FA veri tabanı için doğruluk, kesinlik, duyarlılık ve f-ölçüsü bakımından daha iyi sonuçlar verebileceği görülebilmektedir.

Tablo 4.6 DLD veri kümesi için tanıma performansı sonuçları

Metotlar	Doğruluk (Accuracy) (%)	Kesinlik (Precision) (%)	Duyarlılık (Recall) (%)	F-ölçüsü (%)
SVM 1	75,5	74,6	70,83	72,72

Tablo 4.6 DLD veri kümesi için tanıma performansı sonuçları (devamı)

SVM 2	73,4	74,2	71,5	73,66
Önerilen MDVM	79,21	73,5	73,1	74,95

Tablo 4.6'dan, önerilen MDVM sınıflandırıcısının doğruluk, duyarlık ve f-ölçüsü açısından DLD için diğer yöntemlerden daha yüksek sonuçlar verdiği görülebilmektedir.

Önerilen SKETRACK yöntemi ile tanıma, darbe etiketleme sembol segmentasyonu *DE* ve sınıflandırma ölçüsü *SS1* olmak üzere iki ölçüye göre değerlendirilmektedir. Birinci ölçü *DE*, doğru darbe etiketleme oranıdır (4.1). Her darbeye, sınıflandırıldığı sembol sınıfının bir etiketi atanır ve bu atama, veri tabanındaki kesin doğru (ground truth) değeri ile karşılaştırılarak kontrol edilir. İkinci ölçü *SS1*, sembol tanıma oranıdır (4.2). Bu ölçüde her bir sembolün tam olarak aynı darbeleri içerip içermediğini ve aynı etikete sahip olup olmadığı kontrol edilir.

$$DE = \frac{\text{Doğru etiketlenmiş darbe sayısı}}{\text{Toplam etiketli darbe sayısı}} \quad (4.1)$$

$$SS1 = \frac{\text{Doğru tanınan sembol sayısı}}{\text{Toplam sembol sayısı}} \quad (4.2)$$

Üç veri tabanının sonuçları ayrı ayrı değerlendirilmektedir. Tablo 4.7, 4.8 ve 4.9, FC, FA ve DLD veri tabanları için tanıma sonuçlarını göstermektedir.

Tablo 4.7 FC veri kümesi için tanıma sonuçları

Sınıf	<i>DE</i> (%)	<i>SS1</i> (%)
Ok	85,3	77,54
Bağlantı	82,45	96,2
Veri	86,22	92,3
Karar	92,4	75,3
İşlem	92,1	88,5
Sonlandırıcı	71,06	90,35

Tablo 4.7 FC veri kümesi için tanıma sonuçları (devamı)

Metin	98,8	91,15
Ortalama	94,15	86,2

Tablo 4.8 FA veri kümesi için tanıma sonuçları

Sınıf	<i>DE</i> (%)	<i>SS1</i> (%)
Ok	92,4	89,2
Başlangıç Ok	89,7	93,65
Son Durum	95,0	92,8
Durum	85,1	92,5
Etiket	90,4	91,3
Ortalama	91,25	91,89

Tablo 4.9 DLD veri tabanı için tanıma sonuçları

Sınıf	<i>DE</i> (%)	<i>SS1</i> (%)
Çizgi	92,0	89,24
OR	85,96	84,1
AND	78,45	81,5
NOT	79,6	79,2
NOR	82,1	77,66
NAND	81,23	72,24
X-OR	69,78	66,66

Tablo 4.9 DLD veri tabanı için tanıma sonuçları (devamı)

Baloncuk	75,77	74,58
Metin	92,08	90,9
Ortalama	82,22	79,8

Tablo 4.10 ile hibrit çekirdeğin lambda değerinin seçiminde, aslan optimizasyonunu kullanarak problemi çözmek için gereken minimum, maksimum, ortalama ve medyan zamanı listelerken, Tablo 4.11’de toplam sürenin minimum, maksimum, ortalama ve medyanı gösterilmektedir. Bu tablo, ek olarak optimizasyon görevini gerçekleştirmenin maliyetinin belirlenmesine yardımcı olmaktadır. Zamanın optimum olduğu ve dolayısıyla ek yükün az olduğu görülebilmektedir.

Tablo 4.10 Optimizasyon süresi


Sınıf	Optimizasyon süresi (s)			
Tablo 4.10 Optimizasyon süresi (devamı)				
	Minimal	Maksimum	Ortalama	Medyan
FC	0,14	0,55	0,14	0,11
FA	0,12	0,19	0,14	0,12
DLD	0,15	0,26	0,17	0,15

Tablo 4.11 Toplam çalışma süresi


Sınıf	Çalışma süresi (s)			
	Minimal	Maksimum	Ortalama	Medyan
FC	0,19	3,66	0,83	0,72
FA	0,28	2,54	0,87	0,84
DLD	0,38	1,43	0,77	0,67

Tablo 4.10 ve tablo 4.11'den, optimizasyon problemini çözmek için geçen sürenin, toplam sürenin sadece küçük bir kısmı olduğu ve bu nedenle işlemin hızlı gerçekleştirildiği görülebilmektedir. Optimizasyon işlemi, önerilen sistem için ek maliyet veya ek yük oluşturmamaktadır.


Şekil 4.3, 4.4 ve 4.5 yanlış tanıma sonuçlarına ilişkin örnekleri göstermektedir. FA ve FC veri tabanları sonuçlarında, yanlış tanınan semboller farklı renklendirilmektedir. Yeşil



Şekil 4.3 FC veri kümesinde tanıma sonuçlarına örnekler (a) giriş el çizimi (b) tanıma sonucu (yeşil: doğru sembol tanıma, kırmızı: metin, mavi: yanlış semboller)



Şekil 4.4 FA veri kümesinde tanıma sonuçlarına örnekler (a) giriş el çizimi (b) tanıma sonucu (yeşil: doğru tanıma, kırmızı: metin, mavi: yanlış)



Şekil 4.5 DLD veri kümesinde tanıma sonuçlarına örnekler (a) giriş çizimi (b) tanıma sonucu (kahverengi: OR, menekşe: AND, yeşil: NOR, sarı: NAND, mavi: XOR, pembe: baloncuk, siyah: çizgi)

renkler doğru sembol tanımayı, kırmızı renk metni ve mavi renk yanlış tanımayı göstermektedir. Şekil 4.3'te, üç tane sembol dışında tüm semboller doğru olarak tanınmaktadır. Başlamayı içeren oval şekil yanlış tanınmış, son metin kısmen tanınmış ve son oval şekil, tanımadaki çakışmalar nedeniyle metin olarak tanınmıştır.

Benzer şekilde, Şekil 4.5'teki DLD çizimi, OR için kahverengi, AND için mor, NOR için yeşil, NAND için sarı, XOR için mavi, Baloncuk için pembe ve bağlantı çizgiler için siyah ile renklendirilmiştir. Şekilde NAND, NOR sembolleri ve Baloncuklarda yanlış tanımaya sahiptir. Ayrıca NOT kapısı baloncuk olarak tanınmaktadır. Tablo 4.12 üç veri tabanının hepsi için yanlış tanıma sonuçlarını göstermektedir.

Tablo 4.12 Farklı SKETRACK işlemi için yanlış tanınma oranları

Veri tabanı	Yanlış tanınan sembol sayısı	Metin ayırma	Segmentasyon	Sınıflandırma	Yapısal Analiz
FC	359	%8,92	%43,5	%30,33	%8,9
FA	266	%3,95	%62,67	%51,5	%21,1
DLD	428	%5,5	%71,2	%59,2	%37,7

Tablo 4.12'den sembollerin tanınamamasının temel sebebi olarak, segmentasyon sürecinin düşük kaliteli el çizimlere uyum sağlamadaki etkisizliğinden kaynaklandığı

görülebilmektedir. Bir başka neden ise sınıflandırıcının performansıdır. Dolayısıyla, yanlış tanıma oranını önlemek için bölümlene işlemi iyileştirilmelidir. Bu nedenle, önerilen SKETRACK yönteminin DLD el çizimlerini tanımak için birçok ayarlamaya ihtiyaç duyulurken, FC ve FA el çizimi tanıma için etkili olduğu sonucuna varılabilmektedir.

4.4 Özet

Bu bölümde, DDA algoritması ile Gridshed ve MDVM tabanlı tanıma yöntemi olarak önerilen araştırma tekniklerinin karşılaştırma analizleri yapılmıştır. Burada analiz, kesinlik, duyarlılık, doğruluk ve f-ölçüsü metriklerine dayanarak yapılmaktadır. Ayrıca sembol tanıma için harcanan işlem süresi de tartışılmaktadır.

El çizimi tanıma, gürültü, darbeler vb. çeşitli faktörlerden etkilenebilen bir görevdir. El çizimi tanıma için, daha önce tanıtılan çeşitli araştırma teknikleri vardır. Bununla birlikte, bu tekniklerin kusurları yeni tekniklerin geliştirilmesine yol açmaktadır. Bu tezde tanıtılan ilk araştırma çalışmasında, elle çizilmiş kapalı şekillerin algılanması amacı ile DDA ile Gridshed algoritması sunulmaktadır. Önerilen Gridshed, el çizimi darbelerini iyileştirmek için DDA bağlantı işlemini kullanmaktadır. Daha sonra, boş hücrelerin birleştirilmesiyle sembol sınırları tespit edilip çıkarılmaktadır. FC veri tabanında yapılan deneylerde, önerilen Gridshed yöntemi tabanlı tanımanın mevcut Havza yöntemi tabanlı tanımadan daha yüksek tanıma oranı ve daha az işlem süresi ile önemli sonuçlar gösterdiği kanıtlanmıştır. Bu da okla bağlantılı diyagramlar için önerilen sistemin etkinliğini göstermektedir.

Bu tezde tanıtılan diğer bir yöntem SKETRACK tanıma çerçevesidir. Önerilen SKETRACK çerçevesi, metin segmentasyonu, özellik çıkarma modeli, sembol segmentasyonu için spektral kümeleme, MDVM sınıflandırıcısı kullanılarak sembol tanıma ve yapısal analizden oluşmaktadır. FC, FA ve DLD veri kümeleri üzerinde yapılan değerlendirmeler önerilen SKETRACK yönteminin başarı ile el çizimlerini tanıyabildiğini göstermektedir.

Tanıtılan sistemlerin iyileştirilmesi için sembol segmentasyon sürecinde yanlış tanıma oranının azaltılması için çalışmalar yapılabilir. İkinci olarak sistemler kullanılan üç veritabanı haricindeki diğer alanlardan gelen el çizimleri üzerinde değerlendirilebilir ve geliştirilebilir.

- Abdel-Majeed, M., Almousa, T., Alsalman, M., & Yosf, A. (2020). Sketic: Machine Learning Based Digital Circuit Recognition Platform. *Turkish Journal of Electrical Engineering & Computer Sciences*.
- AlKhateeb, J. H., Ren, J., Jiang, J., & Al-Muhtaseb, H. (2011). Offline Handwritten Arabic cursive text recognition using Hidden Markov Models and reranking. *Pattern Recognition Letters*, 32(8), 1081-1088.
- Amin, A. (2000). Recognition of printed Arabic text based on global features and decision tree learning techniques. *Pattern recognition*, 33(8), 1309-1323.
- Arandjelović, R., & Sezgin, T. M. (2011). Sketch recognition by fusion of temporal and image-based features. *Pattern Recognition*, 44(6), 1225-1234.
- Awal, A. M., Mouchère, H., & Viard-Gaudin, C. (2014). A global learning approach for an online handwritten mathematical expression recognition system. *Pattern Recognition Letters*, 35, 68-77.
- Bay, H., Tuytelaars, T., & Van Gool, L. (2006). SURF: speeded up robust features. In: *ECCV*.
- Bhattacharya, I., Ghosh, P., & Biswas, S. (2013). Offline signature verification using pixel matching technique. *Procedia Technology*, 10, 970-977.
- Bhunia, A. K., Mukherjee, S., Sain, A., Bhunia, A. K., Roy, P. P., & Pal, U. (2020). Indic handwritten script identification using offline-online multi-modal deep network. *Information Fusion*, 57, 1-14.
- Bresler, M., Prusa, D., & Hlaváč, V. (2015, January). Detection of arrows in online sketched diagrams using relative stroke positioning. *IEEE Winter Conference on Applications of Computer Vision* (pp. 610-617).
- Bresler, M., Průša, D., & Hlaváč, V. (2016). Online recognition of sketched arrow-connected diagrams. *International Journal on Document Analysis and Recognition (IJDAR)*, 19(3), 253-267.
- Bresler M., Van Phan T., Průša D., Nakagawa M. & Hlaváč V. (2014). Recognition system for on-line sketched diagrams. In *Proceedings of the 2014 14th International Conference on Frontiers in Handwriting Recognition*, pp. 563–568, IEEE, Heraklion, Greece.

- Brieler, F., & Minas, M. (2010). A model-based recognition engine for sketched diagrams. *Journal of Visual Languages & Computing*, 21(2), 81-97.
- Chandan, C. G., Deepika, M. M., Suraksha, S., & Mamatha, H. R. (2018, September). Identification and grading of freehand sketches using deep learning techniques. In *2018 International Conference on Advances in Computing, Communications and Informatics (ICACCI)* (pp. 1475-1480). IEEE.
- Chen, H., Shi, J., Liu, X., Niu, Z., & Zeng, G. (2018). Single-pixel non-imaging object recognition by means of Fourier spectrum acquisition. *Optics Communications*, 413, 269-275.
- Chen, Z., Yao, S., Jia, Y., & Liu, C. (2018). Face sketch-photo synthesis and recognition: Dual-scale Markov Network and multi-information fusion. *Journal of Visual Communication and Image Representation*, 51, 112-121.
- Choi, J., Cho, H., Song, J., & Yoon, S. M. (2019). Sketchhelper: Real-time stroke guidance for freehand sketch retrieval. *IEEE Transactions on Multimedia*, 21(8), 2083-2092.
- Das, N., Sarkar, R., Basu, S., Saha, P. K., Kundu, M., & Nasipuri, M. (2015). Handwritten Bangla character recognition using a soft computing paradigm embedded in two pass approach. *Pattern Recognition*, 48(6), 2054-2071.
- Lowe, D. G. (2004). Distinctive image features from scale-invariant keypoints. *International Journal of Computer Vision*, 60, 2 (2004), pp. 91-110
- Dalal, N. & B. Triggs. (2005, June). Histograms of Oriented Gradients for Human Detection. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, Vol. 1, pp. 886-893.
- Delaye, A., & Anquetil, E. (2013). HBF49 feature set: A first unified baseline for online symbol recognition. *Pattern Recognition*, 46(1), 117-130.
- Eskander, G. S., Sabourin, R., & Granger, E. (2014). A bio-cryptographic system based on offline signature images. *Information Sciences*, 259, 170-191.
- Fahmy, A., Abdelhamid, W., & Atiya, A. (2018, December). Interactive sketch recognition framework for geometric shapes. In *International Conference on Neural Information Processing* (pp. 323-334). Springer, Cham.
- Galbally, J., Diaz-Cabrera, M., Ferrer, M. A., Gomez-Barrero, M., Morales, A., & Fierrez, J. (2015). On-line signature recognition through the combination of real dynamic data and synthetically generated static data. *Pattern Recognition*, 48(9), 2921-2934.

- Ghosh, R., Vamshi, C., & Kumar, P. (2019). RNN based online handwritten word recognition in Devanagari and Bengali scripts using horizontal zoning. *Pattern Recognition*, 92, 203-218.
- Goldberg, D. & Richardson, C. (1993). Touch-typing with a stylus. In *Proceedings of the ACM Conference on Human Factors in Computing (INTERCHI '93, Amsterdam, The Netherlands, Apr. 24–29)*, S. Ashlund, A. Henderson, E. Hollnagel, K. Mullet, and T. White, Eds. ACM Press, New York, NY, 80–87.
- Gupta, A., Sarkhel, R., Das, N., & Kundu, M. (2019). Multiobjective optimization for recognition of isolated handwritten Indic scripts. *Pattern Recognition Letters*, 128, 318-325.
- Hou, Y. T., & Wang, S. L. (2018). Real-time shape recognition scheme on projected capacitive touchscreens. *Microsystem Technologies*, 24(10), 3985-3993.
- Indermühle E. Liwicki M., & Bunke H. (2010). IAMonDo-database: an online handwritten document database with non-uniform contents. In *Proceedings of the 9th IAPR International Workshop on Document Analysis Systems*, pp. 97–104, ACM, Boston, Massachusetts, USA.
- Jayech, K., Mahjoub, M. A., & Amara, N. E. B. (2016). Synchronous Multi-Stream Hidden Markov Model for offline Arabic handwriting recognition without explicit segmentation. *Neurocomputing*, 214, 958-971.
- Jia, Q., Yu, M., Fan, X., & Li, H. (2017). Sequential dual deep learning with shape and texture features for sketch recognition. *arXiv preprint arXiv:1708.02716*.
- Keysers, D., Deselaers, T., Rowley, H. A., Wang, L. L., & Carbune, V. (2016). Multi-language online handwriting recognition. *IEEE transactions on pattern analysis and machine intelligence*, 39(6), 1180-1194.
- Li, L., Zou, C., Zheng, Y., Su, Q., Fu, H., & Tai, C. L. (2018). Sketch-R2CNN: An Attentive Network for Vector Sketch Recognition. *arXiv preprint arXiv:1811.08170*.
- Li, Y., Hospedales, T. M., Song, Y. Z., & Gong, S. (2015). Free-hand sketch recognition by multi-kernel feature learning. *Computer Vision and Image Understanding*, 137, 1-11.
- Li, Y., Song, Y. Z., Hospedales, T. M., & Gong, S. (2017). Free-hand sketch synthesis with deformable stroke models. *International Journal of Computer Vision*, 122(1), 169-190.

- Li, Y., Wang, X., Liu, W., & Feng, B. (2018). Deep attention network for joint hand gesture localization and recognition using static RGB-D images. *Information Sciences*, 441, 66-78.
- Lienhart, R., & Maydt, J. (2002). An extended set of haar-like features for rapid object detection. In *Image Processing*. Proceedings. International Conference on, volume 1, pages I-900. IEEE.
- Liu, D., Li, J., Wang, N., Peng, C., & Gao, X. (2018). Composite components-based face sketch recognition. *Neurocomputing*, 302, 46-54.
- Liu, F., Deng, X., Lai, Y. K., Liu, Y. J., Ma, C., & Wang, H. (2019). Sketchgan: Joint sketch completion and recognition with generative adversarial network. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 5830-5839).
- Liu, L., Shen, F., Shen, Y., Liu, X., & Shao, L. (2017). Deep sketch hashing: Fast free-hand sketch-based image retrieval. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2862-2871).
- Mahmoud, S. A., Ahmad, I., Al-Khatib, W. G., Alshayeb, M., Parvez, M. T., Märgner, V., & Fink, G. A. (2014). KHATT: An open Arabic offline handwritten text database. *Pattern Recognition*, 47(3), 1096-1112.
- Matsushiro N. (1998). A new digital differential analyzer for circle generation, *IEICE TRANSACTIONS on Information and Systems*, vol. 81, no. 2, pp. 239-242.
- Meyer, F. (1994). Topographic distance and watershed lines. *Signal processing*, vol. 38, no. 1, pp. 113-125.
- Mittal, P., Jain, A., Goswami, G., Vatsa, M., & Singh, R. (2017). Composite sketch recognition using saliency and attribute feedback. *Information Fusion*, 33, 86-99.
- Moetesum, M., Siddiqi, I., Ehsan, S., & Vincent, N. (2020). Deformation modeling and classification using deep convolutional neural networks for computerized analysis of neuropsychological drawings. *Neural Computing and Applications*, 1-25.
- Namane, A., Guessoum, A., Soubari, E. H., & Meyrueis, P. (2014). CSM neural network for degraded printed character optical recognition. *Journal of Visual Communication and Image Representation*, 25(5), 1171-1186.
- Kass, M., Witkin, A., & Terzopoulos, D. (1988). Snakes: Active contour models, *Int. J. Comput. Vis.*, vol. 1, pp. 321-331
- Peng, C., Gao, X., Wang, N., & Li, J. (2018). Face recognition from multiple stylistic sketches: Scenarios, datasets, and evaluation. *Pattern Recognition*, 84, 262-272.

- Phangtriastu, M. R., Harefa, J., & Tanoto, D. F. (2017). Comparison between neural network and support vector machine in optical character recognition. *Procedia computer science*, 116, 351-357.
- Qi, A., Song, Y. Z., & Xiang, T. (2018, September). Semantic Embedding for Sketch-Based 3D Shape Retrieval. In *BMVC*, Vol. 2, No. 7, p. 8.
- Radhika, K. S., & Gopika, S. (2015). Online and offline signature verification: a combined approach. *Procedia Computer Science*, 46, 1593-1600.
- Rahman A, & Beg M. S. (2015). Face sketch recognition using sketching with words. *International Journal of Machine Learning and Cybernetics*, 6 (4), 597-605.
- Rashwan S, Faheem T, Sarhan A, Youssef BAB. (2009). A fuzzy-watershed based algorithm for protein spot detection in 2DGE images. In: *Proceedings of the 9th WSEAS international conference on signal processing, computational geometry and artificial vision (ISCGAV'09)*, Stevens Point, Wisconsin, USA: World Scientific and Engineering Academy and Society (WSEAS), p. 35-40.
- Sarvadevabhatla, R. K., & Babu, R. V. (2015). Freehand sketch recognition using deep features. *arXiv preprint arXiv:1502.00254*.
- Seddati, O., Dupont, S., & Mahmoudi, S. (2017). DeepSketch 3. *Multimedia Tools and Applications*, 76 (21), 22333-22359.
- Sepahvand, M., Abdali-Mohammadi, F., & Mardukhi, F. (2016). Evolutionary metric-learning-based recognition algorithm for online isolated Persian/Arabic characters, reconstructed using inertial pen signals. *IEEE transactions on cybernetics*, 47 (9), 2872-2884.
- Sert, M., & Boyacı, E. (2019). Sketch recognition using transfer learning. *Multimedia Tools and Applications*, 78 (12), 17095-17112.
- Shen, H. K., Chen, P. H., & Chang, L. M. (2018). Human-visual-perception-like intensity recognition for colour rust images based on artificial neural network. *Automation in Construction*, 90, 178-187.
- Sohal, J. S. (2016). Improvement of artificial neural network based character recognition system, using SciLab. *Optik*, 127 (22), 10510-10518.
- Sun, Z., Wang, C., Zhang, L., & Zhang, L. (2012). Free hand-drawn sketch segmentation. In *European Conference on Computer Vision* (pp. 626-639). Springer, Berlin, Heidelberg.

- Wadhwa, D., Maharana, U., Shah, D., Yadav, V., & Pandey, P. (2019, August). Human Sketch Recognition using Generative Adversarial Networks and One-Shot Learning. In *2019 Twelfth International Conference on Contemporary Computing (IC3)* (pp. 1-6). IEEE.
- Wan, W., & Lee, H. J. (2019). Deep feature representation and ball-tree for face sketch recognition. *International Journal of System Assurance Engineering and Management*, 1-6.
- Wang, D. H., Liu, C. L., & Zhou, X. D. (2012). An approach for real-time recognition of online Chinese handwritten sentences. *Pattern Recognition*, 45 (10), 3661-3675.
- Wang, F., Lin, S., Li, H., Wu, H., Cai, T., Luo, X., & Wang, R. (2020). Multi-column point-cnn for sketch segmentation. *Neurocomputing*.
- Wang, M., & Deng, W. (2020). Deep Face Recognition with Clustering based Domain Adaptation. *Neurocomputing*.
- Wang, X., Chen, X., & Zha, Z. (2018, October). Sketchpointnet: a compact network for robust sketch recognition. In *2018 25th IEEE International Conference on Image Processing (ICIP)* (pp. 2994-2998). IEEE.
- Wazarkar, S., Keshavamurthy, B. N., & Hussain, A. (2018). Region-based segmentation of social images using soft KNN algorithm. *Procedia Computer Science*, 125, 93-98.
- Xiao, B., Gao, X., Tao, D., Yuan, Y., & Li, J. (2010). Photo-sketch synthesis and recognition based on subspace learning. *Neurocomputing*, 73 (4-6), 840-852.
- Xu, P., Yin, Q., Huang, Y., Song, Y. Z., Ma, Z., Wang, L., & Guo, J. (2018). Cross-modal subspace learning for fine-grained sketch-based image retrieval. *Neurocomputing*, 278, 75-86.
- Yang, W., Sun, C., & Zhang, L. (2011). A multi-manifold discriminant analysis method for image feature extraction. *Pattern Recognition*, 44 (8), 1649-1657.
- Yazdani M., & Jolai F. (2016). Lion optimization algorithm (LOA): a nature-inspired metaheuristic algorithm, *Journal of Computational Design and Engineering*, vol. 3, no. 1, pp. 24–36.
- Ye, K., & Zhan, Y. (2009). Image segmentation algorithm based on mathematical morphology and active edgeless contour model without edges. *Journal of Computer Applications*, vol. 29, no. 9, pp. 2398-2401.
- Yoon, G. J., & Yoon, S. M. (2017). Sketch-based 3D object recognition from locally optimized sparse features. *Neurocomputing*, 267, 556-563.

- Zhang, W., Yan, Z., Wang, Q., Wu, X., & Zuo, W. (2020). Learning Second-order Statistics for Place Recognition based on Robust Covariance Estimation of CNN Features. *Neurocomputing*.
- Zhang, X., Li, X., Li, X., & Shen, M. (2018). Better freehand sketch synthesis for sketch-based image retrieval: Beyond image edges. *Neurocomputing*, 322, 38-46.
- Zhang, X., Li, X., Liu, Y., & Feng, F. (2019). A survey on freehand sketch recognition and retrieval. *Image and Vision Computing*, 89, 67-87.
- Zhao, P., Liu, Y., Lu, Y., & Xu, B. (2019). A sketch recognition method based on transfer deep learning with the fusion of multi-granular sketches. *Multimedia Tools and Applications*, 78 (24), 35179-35193.
- Zheng, Y., Yao, H., & Sun, X. (2019). Deep semantic parsing of freehand sketches with homogeneous transformation, soft-weighted loss, and staged learning. *arXiv preprint arXiv:1910.06023*.
- Zhu, X., Xiao, Y., & Zheng, Y. (2020). 2D freehand sketch labeling using CNN and CRF. *Multimedia Tools and Applications*, 79 (1-2), 1585-1602.
- Zhengxing S, and Jing, L. (2005). Informal user interfaces for graphical computing. Lecture Notes in Computer Science, Vol. 3784, 2005, page 675-682.

TEZDEN ÜRETİLMİŞ YAYINLAR

İletişim Bilgisi: orhan_karadigi@yahoo.com

Makaleler

Nooruldeen, O. and Altun, O. (2019). "SKETRACK: Stroke-Based Recognition of Online Hand-Drawn Sketches of Arrow-Connected Diagrams and Digital Logic Circuit Diagrams". *Sci. Program*, 2019, 6501264.