



Gizli Parmak İzlerinin Sentetik Üretimi

Program Kodu: COST-İKİLİ İŞBİRLİĞİ

Proje No: 217E092

Proje Yürütücüsü:

Dr. Öğr. Üyesi NESLİ ERDOĞMUŞ

Bursiyer(ler)

PELİN ŞENKULA

EMRE İRTEM

VAHDETTİN ONUR KILINÇ

TEMMUZ 2021

ANKARA

ÖNSÖZ

Gizli parmak izi tanıma alanında yeni tekniklerin geliştirilmesi adalet ve güvenlik alanında önemli katkılar sağlama potansiyeline sahiptir. Sentetik gizli parmak izi üretme teknikleri geliştirilmesinin ve bu verilerin derin öğrenme yapılarının eğitiminde kullanılmasının bu konulardaki eksiklikleri önemli ölçüde gidermesi ihtimal dışı değildir.

Tübitak tarafından desteklenen 217E092 no'lu bu projede, parmak izi tanıma probleminde karşılaşılan az veri problemini gidermek amacıyla sentetik gizli (kontROLSÜZ) parmak izleri üreten yöntemler geliştirilmesi hedeflenmiştir. Üretilen sentetik gizli parmak izleri derin öğrenme gibi çok eğitim verisi isteyen sistemlerin eğitilmesi için kullanılmış ve performanslarındaki değişiklikler gözlemlenmiştir.

Bu doğrultuda, birçok farklı parmak izi işleme ve tanıma alt görevi için geliştirilen derin öğrenme mimarileri farklı tekniklerle üretilen parmak izi imgeleri kullanılarak eğitilmiş ve bu sentetik verinin performanslara olan katkısı incelenmiştir.

İÇİNDEKİLER

1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	3
2.1 Sentetik Parmak İzi Üretme	3
2.1.1 Model tabanlı yaklaşımlar	4
2.1.2 Öğrenme tabanlı yaklaşımlar	6
2.2 Parmak İzi ve Derin Öğrenme	6
2.2.1 Parmak izi sınıflandırma	7
2.2.2 Özellik noktası tespiti	7
2.2.3 Papil yönelim çizgisi kestirimi	9
2.2.4 Parmak izi eşleştirme	9
3. GEREÇ ve YÖNTEM	10
3.1 Sentetik Parmak İzi Üretme	11
3.1.1 Model tabanlı parmak izi üretme	11
3.1.2 Öğrenme tabanlı parmak izi üretme	25
3.1.3 Simülasyon tabanlı parmak izi üretme	26
3.2 Derin Öğrenme ile Parmak İzi İşlem Adımları	28
3.2.1 Parmak izi sınıflandırması	28
3.2.2 Özellik noktası tespit etme	29
3.2.3 Papil çizgisi yönelimi kestirme	30
4. BULGULAR	31
4.1 Parmak izi sınıflandırması	31
4.1.1 Modellere göre	31
4.1.2 Transfer öğrenme yaklaşımına göre	32
4.1.3 Eğitim kümesi büyüklüğüne göre	33
4.1.4 Sentetik veriler ile eğitime	35
4.2 Özellik noktası tespit etme	37
4.3 Papil çizgisi yönelimi kestirme	40
5. TARTIŞMA, SONUÇ ve ÖNERİLER	41
5.1 Parmak izi sınıflandırması	41
5.1.1 Modellere göre	41
5.1.2 Transfer öğrenme yaklaşımına göre	42
5.1.3 Eğitim kümesi büyüklüğüne göre	42
5.1.4 Sentetik veriler ile eğitime	42
5.2 Özellik noktası tespit etme	46
5.3 Papil çizgisi yönelimi kestirme	48

Tablo Listesi

Tablo 4.1. Sınıflandırma performansları karşılaştırması	34
Tablo 4.2. Farklı deney kurguları ile elde edilen sonuçlar (1) özellik noktası için yamanın tamamına bakıldığını (2) ise merkezindeki 10x10'luk kareye bakıldığını göstermektedir	39
Tablo 5.1 En iyi sistemin performans metriklerinin parmak izi kalitesine göre alt kırılımı	48
Tablo 5.2 Veri arttırımının performanslara olan etkisi	48

Şekil Listesi

Şekil 3.1. Dört elips ile oluşturulan parmak izi alanı modeli ve örnek parmak izi alanları (Maltoni vd., 2009)	12
Şekil 3.2. Üretilen arka planlardan örnekler	12
Şekil 3.3. (a) Gerçek parmak izi görüntülerindeki papil çizgisi devamsızlıkları ve yoğunluk düzensizliği (b) Gerçek bir parmak izine medyan filtre uygulanarak elde edilen ve tekdüze olmadığı görülen yoğunluk düzensizliği	13
Şekil 3.4. [Pmax,Pmin] aralığında örnekleme ile ilklendirilerek oluşturulmuş pertürbasyon imgeleri (a) Pmax = 0.85, Pmin = 0.15, 0.35, 0.65, 0.85 (b) Pmin = 0.15, Pmax = 0.15, 0.35, 0.65, 0.85.	14
Şekil 3.5. Kırmızı ve yeşil parmak izleri FVC2002 DB1-A'dan alınmıştır ve aynı parmağa aittirler. Bu izler hizalandığında ve üstüste bindirildiğinde nasıl bir deformasyon farkı olduğu açıkça ortaya çıkmaktadır.	14
Şekil 3.6. Ana parmak izine oturtulan düzenli ızgara ve deformasyon sonucu aldığı şekil.	15
Şekil 3.7. Negatif T değerleri kuruluk ya da düşük baskı kuvvetini modellerken, pozitif T değerleri ıslaklık ya da yüksek baskı kuvvetini modeller.	15
Şekil 3.8. (a) Gerçek parmak izlerindeki örnek skarlar (b) Tek bir skar oluşturulması (c) Birden fazla skar eklenmiş ana parmak izi görüntüsü	16
Şekil 3.9. Oluşturulan sentetik veri kümelerinden her bir parmak izi sınıfı için örnekler	17
Şekil 3.10. Sherlock and Monro modeli kullanılarak, sağ kement sınıfına ait oluşturulmuş örnek bir yönelim haritası (Maltoni vd., 2009)	18
Şekil 3.11. Vizcaya ve Gerhardt, (1996)de önerilen Sherlock and Monro modelinin geliştirilmiş hali ve sonuç olarak iyileştirilen yönelim haritası (Maltoni vd., 2009)	18
Şekil 3.12. β parametresinin yay örüntüsüne olan etkisi	19
Şekil 3.13. (a) Düzeltme yapılmamış yay yönelim haritası (b) a'daki haritanın düzeltilmiş hali (c) Eklenen düzeltme yön ve büyüklükleri	19
Şekil 3.14. Örnek bir frekans haritası oluşumu.	20
Şekil 3.15. Farklı sayıda yineleme uygulanarak üretilen bir ana parmak izi	21
Şekil 3.16. Aynı frekans ve yönelim haritası kullanıldığı durumda, artan başlangıç imgesi beyaz nokta sayısının üretilen ana parmak izindeki özellik noktası miktarı ile olan ilişkisi	22
Şekil 3.17. (a) Tepki imgesi (b) Özellik noktası olasılık haritası (c)Eşik uygulanmış olasılık haritası (d) Medyan filtre uygulanmış olasılık haritası (e) İskelet haline getirilmiş olasılık haritası (f) tespit edilen özellik noktaları	23
Şekil 3.18. Yukarıdan aşağı sırasıyla sol kement, sağ kement, tak tipi, yay ve helezon sınıflarına ait sentetik parmak izi örnekleri	24
Şekil 3.19. Aynı parmak izinin farklı veri kümelerindeki görüntüsü	24

Şekil 3.20. Parmak izini oluşturan deri yapısının incelemesi ve profil grafikleri	27
Şekil 3.21. Örnek bir ana parmak izi ve bu izin aktarıldığı parmak ucu modeli	27
Şekil 3.22. 3B parmak ucunun düz bir yüzeye ve banknotun üzerine dokundurulması ile parmak izinin kısmi bırakılması sonuçları	28
Şekil 3.23. 3B parmak ucunun düz bir yüzeye sürtünmesi ile parmak izinin bulanık şekilde bırakılması sonuçları	28
Şekil 3.24. Yamaları ikili sınıflandırmak üzere tasarlanan EYSA	30
Şekil 4.1. 3 farklı model ile elde edilen en yüksek doğruluk değerleri	32
Şekil 4.2. 3 farklı transfer öğrenme yaklaşımı için elde edilen en yüksek doğruluk değerleri	32
Şekil 4.3. 5 farklı eğitim kümesi büyüklüğü için elde edilen en yüksek doğruluk değerleri	33
Şekil 4.4. 5-sınıf sınıflandırma için her eğitim döneminde elde edilen test doğruluk değerleri	34
Şekil 4.5. 5-sınıf sınıflandırma için farklı bozulmalara sahip sentetik eğitim kümeleri ile elde edilen doğruluk değerleri	35
Şekil 4.6. 5-sınıf sınıflandırma için farklı büyüklükteki eğitim kümeleri ile elde edilen doğruluk değerleri	35
Şekil 4.7. 5-sınıf sınıflandırma için gerçek ve gerçek+sentetik eğitim kümeleri ile ve transfer öğrenme kullanmadan elde edilen doğruluk değerleri	36
Şekil 4.8. 5-sınıf sınıflandırma için gerçek ve gerçek+sentetik eğitim kümeleri ile ve transfer öğrenme kullanarak elde edilen doğruluk değerleri	36
Şekil 4.9. 5-sınıf sınıflandırma için gerçek 1000 gerçek veriye farklı sayılarda sentetik veri eklenecek oluşturulan eğitim kümeleri ile ve transfer öğrenme kullanarak ve kullanmadan elde edilen doğruluk değerleri	37
Şekil 4.10. 30x30 ve 50x50 yama örnekleri	37
Şekil 4.11. 50x50 yama örnekleri. Üstte: Yamanın tamamında bulunmaması zorunlu Altta: Yamanın merkezindeki 10x10 büyüklüğündeki karede bulunmaması zorunlu	38
Şekil 4.12. Morfolojik operasyonların yapılmaması yanlış tespitleri arttırmaktadır.	39

ÖZ

Parmak izi tanıma sistemleri sınır geçişleri, kişisel bilgilerin korunumu ve güvenliği ve adli incelemeler gibi bir çok alanda önemli bir yer tutmaktadır. Parmak izi, pasaportlardan, cep telefonlarına kadar gündelik hayata nüfus etmiş olması bir yana, kriminal vaka çözümlerinde de halen en çok kullanılan araçların başında gelmektedir. Bu önem, dünya nüfusundaki ve nüfus hareketliliğindeki artış ile birleşince otomatik parmak izi eşleştirme ve tanıma araştırmaları hız kazanmıştır.

Ancak kişisel ve/veya adli veri olması, elde edilmesindeki güçlükler ve uzmanlık gereksinimi nedeni ile gizli parmak izlerinin araştırma amaçlı toplanmaları ve erişime açık hale getirilmeleri diğer araştırma alanlarına kıyasla güç olabilmektedir. Öte yandan çok sayıda parmak izi örneğine sahip olmak iki açıdan önem arz etmektedir:

1. Gerçek olay çözümlerinde ve kimlik tespitinde, parmak izi taraması büyük oranda milyonlarca kayıtlı parmak izi görüntüsü üstünde yapılmaktadır. Laboratuvar ortamında gerçekçi performans değerleri elde etmek için benzer büyüklükte veri kümeleri gerekmektedir.
2. Son yıllarda çok geniş bir uygulama alanı bulan ve bunların birçoğunda elde edilen başarımların çok daha ileri seviyelere taşıyan derin öğrenme yaklaşımlarının performansları ile eğitim veri kümesinin büyüklüğü arasında olumlu bir bağıntı mevcuttur. Yapay derin sinir ağlarının eğitimi için geniş veri kümelerine ihtiyaç vardır.

Gerçek parmak izi eşleştirme senaryolarında tarama yapılan veri kümelerinin büyüklüğü ve derin öğrenme yaklaşımları ile elde edilen başarımların veri büyüklüğüne olan bağımlılığı sebebi ile sentetik ve gerçeğine yakın veri üretme beraberinde büyük avantajlar getirmektedir. Bu projede, yukarıda bahsedilen etkenlerden ikincisine odaklanılmış ve sentetik gizli parmak izi görüntülerinin parmak izi işleme ve tanıma sistemlerinin eğitiminde kullanılmak üzere üretilmesi hedeflenmiştir.

Proje kapsamında üretilen parmak izlerinin ne kadar gerçeğe yakın oldukları, derin öğrenme sistemlerinin başarımlarını ne kadar arttırdıkları ölçüsüne göre değerlendirilmektedir. Bu doğrultuda, parmak izi tanıma ve eşleştirme alt adımlarından sınıflandırma, özellik noktası tespiti ve papil çizgisi yönelimi kestirimi görevleri için derin yapay sinir ağları geliştirilmiş ve eğitim için kullanılan sentetik parmak izi verilerinin bu ağların performanslarına olan etkileri ölçülmüştür. Örnek sayısının az olduğu sınıflandırma görevinde dikkate değer bir artış gözlemlenirken, yama-tabanlı geliştirilen ve bu sebeple az örnek sayısı probleminin bertaraf edildiği özellik noktası tespiti ve papil çizgisi yönelimi kestirimi görevlerinde benzer bir etki gözlemlenmemiştir.

Parmak izi üretimi için biri model, biri de istatistik tabanlı olmak üzere iki yaklaşım denenmiştir. Model tabanlı sistemde parmak izlerinin sınıfı, özellik noktaları, papil çizgisi yönelim ve frekansı gibi tüm faktörler kontrol/tespit edilebildiği için bu yöntemler üretilen parmak izleri için performans testleri yapılmıştır. Ancak, istatistik tabanlı sistemde çekişmeli üretici ağlar eğitilmiş, ancak imgelerin parmak izi sınıfı dışında bir meta veriye bağlı olarak üretilmeleri sağlanamamıştır.

Anahtar kelimeler: Parmak izi üretme, parmak izi işleme, parmak izi tanıma, derin öğrenme, çekişmeli üretici ağlar

ABSTRACT

Fingerprint recognition systems have an important place in many areas such as border crossing, protection and security of personal information and forensic investigations. Fingerprints are still one of the most used tools in criminal case analysis, aside from having penetrated into daily life from passports to mobile phones. This importance, combined with the increase in the world population and its mobility, has accelerated automatic fingerprint matching and recognition research.

However, collecting private data such as fingerprints and making them accessible for research purposes may be difficult compared to other research fields, due to several facts; such as fingerprints being private and/or forensic data, difficulties in obtaining them and the need for expertise. On the other hand, having a large number of fingerprint samples is important in two respects:

1. In real event analysis and identification, fingerprint scanning is largely done on millions of recorded fingerprint images. Datasets of similar size are required to obtain realistic performance values in a laboratory setting.
2. There is a positive correlation between the performance of deep learning approaches, which have found a wide range of applications in recent years and the size of the training dataset. Large datasets are needed for training artificial deep neural networks.

Due to the size of the datasets scanned in real fingerprint queries and the dependence of the performances obtained with deep learning approaches on the data size, producing synthetic and realistic data brings great advantages. This project focuses on the second of the factors mentioned above and aims to produce synthetic latent fingerprint images for use in training of fingerprint processing and recognition systems.

The fingerprints produced within the scope of the project are evaluated according to how close they are to reality and how much they increase the success rates of deep learning systems. In this direction, deep artificial neural networks were developed for classification, minutiae detection and ridge orientation estimation tasks, which are sub-steps of fingerprint recognition and matching, and the effects of synthetic fingerprint data used for training on the performance of these networks were measured. While a remarkable increase was observed in the classification task with a small number of samples, a similar effect was not observed in the minutiae detection and ridge orientation estimation tasks, which have adopted patch-based approaches and therefore eliminated the small sample size problem.

One model-based and one statistics-based approach are implemented for fingerprint generation. Since all factors such as class, feature points, ridge orientation and frequency can be controlled/detected in the model-based system, performance tests have been made for the fingerprints produced by these methods. However, in the statistics-based system, several generative adversarial networks are trained, but the synthetic images could not be produced depending on any metadata except the fingerprint class.

Keywords: Fingerprint generation, fingerprint processing, fingerprint recognition, deep learning, generative adversarial networks

İÇİNDEKİLER

1. GİRİŞ	1
2. LİTERATÜR ÖZETİ	3
2.1 Sentetik Parmak İzi Üretme	3
2.1.1 Model tabanlı yaklaşımlar	4
2.1.2 Öğrenme tabanlı yaklaşımlar	6
2.2 Parmak İzi ve Derin Öğrenme	6
2.2.1 Parmak izi sınıflandırma	7
2.2.2 Özellik noktası tespiti	7
2.2.3 Papil yönelim çizgisi kestirimi	9
2.2.4 Parmak izi eşleştirme	9
3. GEREÇ ve YÖNTEM	10
3.1 Sentetik Parmak İzi Üretme	11
3.1.1 Model tabanlı parmak izi üretme	11
3.1.2 Öğrenme tabanlı parmak izi üretme	25
3.1.3 Simülasyon tabanlı parmak izi üretme	26
3.2 Derin Öğrenme ile Parmak İzi İşlem Adımları	28
3.2.1 Parmak izi sınıflandırması	28
3.2.2 Özellik noktası tespit etme	29
3.2.3 Papil çizgisi yönelimi kestirme	30
4. BULGULAR	31
4.1 Parmak izi sınıflandırması	31
4.1.1 Modellere göre	31
4.1.2 Transfer öğrenme yaklaşımına göre	32
4.1.3 Eğitim kümesi büyüklüğüne göre	33
4.1.4 Sentetik veriler ile eğitime	35
4.2 Özellik noktası tespit etme	37
4.3 Papil çizgisi yönelimi kestirme	40
5. TARTIŞMA, SONUÇ ve ÖNERİLER	41
5.1 Parmak izi sınıflandırması	41
5.1.1 Modellere göre	41
5.1.2 Transfer öğrenme yaklaşımına göre	42
5.1.3 Eğitim kümesi büyüklüğüne göre	42
5.1.4 Sentetik veriler ile eğitime	42
5.2 Özellik noktası tespit etme	46
5.3 Papil çizgisi yönelimi kestirme	48



1. GİRİŞ

Dünyada artan nüfus, bu nüfusun artan seyahat kabiliyeti ve elektronik ortam etkileşimi biyometrik tanıma ihtiyacının hızlı bir şekilde büyümesine sebep olmuştur. Biyometrik tanıma, bireyleri yüz, ses, yürüyüş gibi ayırt edici olabilen anatomik ya da davranışsal özellikleri sayesinde tanımayı hedefler (Jain ve Ross, 2007). Bu özellikler arasında parmak izi, toplum içinde kabul edilirliliği, kişiye özel ve gizli kalabilme özelliği ve yaşlanmaya karşı direnç göstermesi ile öne çıkmaktadır. Parmak izleri, anne karnında 6.-24. haftalar arasında oluşur ve doğuştan itibaren aynı kalır. Parmak izini oluşturan kıvrımlar (papil çizgileri), dış deri altındaki papillaların şeklinin yüzeye yansımalarıyla ortaya çıkar. Bu nedenle parmaklardaki deri zarar görse bile parmak izi değişmez.

İnsanların bir kimliklendirme aracı olarak parmak izini yüzyıllar öncesinden kullanmaya başladıklarına dair kanıtlar mevcuttur ancak ilk modern parmak izi tanıma ve eşleştirme yöntemleri 16. Yüzyılın sonlarına doğru ortaya çıkmıştır (Lee vd., 2001). 1892’de Galton “Parmak İzleri” başlıklı kitabında parmak izi biliminin o günkü durumunu incelemiş; parmak izlerinin kalıcılığını, bireye özgü oluşunu ve belli başlı sınıflara ayrılacaklarını yazmıştır (Galton, 1965). Galton daha sonra 1888’de parmak izlerini karşılaştırabilmeyi kolaylaştıran ve günümüzde dahi kullanımı devam eden özellik noktaları fikrini ortaya atmıştır.

20. yüzyılın başında parmak izi tanıma geçerli bir kimliklendirme yöntemi olarak benimsenmiş, adli makamlarca dikkate alınan bir standart haline gelmiştir. Örneğin, 1924’te 810.000 parmak izi kartından oluşan bir veri tabanı ile FBI parmak izi tanıma birimi kurulmuştur (Maltoni vd., 2009). Ancak başlangıçta parmak izi uzmanlarının inceleyip hakkında hızlıca bir karara varabildikleri örneklerin sayısı hızla artmıştır. Bugün FBI’ın elinde bulunan ve dünyanın en büyük biyometrik veri tabanı olarak kabul edilen NGI (Next Generation Identification) veri tabanında 70 milyondan fazla sivil amaçlı toplanan ve 50 milyondan fazla ise suçlulardan alınan parmak izi kayıtları mevcuttur (Kofman, 2017). Her gün ortaya çıkan binlerce tarama isteği de düşünülecek olduğunda bu talebin parmak izi uzmanlarınca tek tek elle karşılanmasının imkânsız hale geldiği görülmektedir.

Bugün akıllı telefonları aktif hale getirmekten, işyerlerinde yoklamaya almaya kadar uzanan geniş bir sivil yelpazede kullanılabilen parmak izi, asıl yoğun olarak suçları çözmek, suçluları takip etmek, vatandaşları kimliklendirme ve sınır, havalimanı gibi yüksek güvenli alanlarda ve giriş-çıkışın kontrollü yapıldığı binalarda kimlik doğrulama yapmak gibi görevler için emniyet görevlileri ve adli birimlerce benimsenmiştir. Bu yaygın kullanımı olası kılan etmenlerin başında parmak izi incelemesinin otomatik hale getirilebilmesi gelmektedir. Bu da parmak izi inceleme alanında yapılan bilimsel araştırmalar sonucu gerçekleşmiştir.

Parmak izi uzmanlarının iz eşleştirme ve tanıma yöntemlerini rehber edinerek yapılan araştırmalar sonucu başlangıçta otomasyonunun sağlanması için aşılması gerek üç problem belirlenmiştir: parmak izi toplama, yerel özellik noktalarının tespit edilmesi ve özellik noktaları örüntülerinin eşleştirilmesi (Maltoni vd., 2009). Tanınacak parmak izi görüntülerinin ön işleme ile iyileştirilmesi adımında kullanılmak üzere papil çizgilerinin yönelimini kestirme de bunlara eklenebilir. Yerel özellik noktalarının tespit edilmesi ve elde edilen nokta kümelerinin eşleştirilmesi konusu ise bilgisayarla görü alt alanı olarak kabul edebileceğimiz parmak izi biyometrisinde aktif bir araştırma alanıdır. Ancak bu iki ayrı problem, son yıllarda derin yapay sinir ağlarının yaygın kullanımı ile daha girift hale gelmiş, aralarındaki sınır bulanıklaşmıştır. Parmak izlerinin eşleştirilmesi olarak tanımlayabileceğimiz bu bütünleşik problemde eşleştirmenin iki adımı (öznitelik çıkarma ve eşleştirme) bire indirilmiştir. (Peralta vd., 2017)

Yapay sinir ağları tabanlı yeni nesil bir makine öğrenmesi yaklaşımı olan derin öğrenme, bilgisayarla görü, doğal dil işleme ve veri analiz ve sentezi gibi birçok alanda önemli ilerlemeler kaydedilmesini sağlamıştır. Yapay ağ sistemlerinin mimari olarak geliştirilmesi (derinleştirilmesi) ve bu derin yapıların eğitilebilmesi için en az yapılan teorik çalışmalar kadar etkili iki unsur daha vardır: Büyük veri kümeleri ve yüksek hesaplama gücü.

Yoğun internet kullanımı ile birlikte dijital görüntü, ses, metin ve kullanıcı davranışı verileri büyük bir hızla toplanmaya başlanmıştır. Örneğin bu sayede bir araya getirilen ve doğal görüntü imgelerinden oluşan ImageNet veri tabanında internetten toplanan 10 milyonun üzerinde imge bulunmaktadır. Bu imgeler için, yine internetten faydalanılarak (kitle kaynak (crowdsourcing) kullanılarak), WordNet (Fellbaum, 1998) veri tabanındaki hiyerarşik yapıya paralel olarak imge sınıfları ve imgelerdeki obje konumları elle işaretlenmiştir. Yine benzer şekilde, Facebook'un geliştirdiği ve deney sonuçlarına göre insan performansına yaklaşmayı başardığı derin öğrenmeye dayalı yüz doğrulama sistemi şirketin elinde bulunan 4000'den fazla kişinin işaretlenmiş 4 milyon yüz imgesi ile eğitilmiştir. Görüldüğü üzere internet kullanımı sayesinde bazı veri türleri, özellikle de işaretlenmiş olarak dev boyutlara ulaşabilmektedir.

Kontrollü olarak toplanan referans parmak izlerini tanıma amacıyla derin öğrenme algoritmalarının kullanımı diğer bilgisayarla görü alt alanlarına kıyasla oldukça azdır. Veri eksikliğine bağlı olarak, bu yaklaşım özellikle gizli parmak izi tanıma alanında daha da sınırlı kalmıştır. Adli birimlerce olay yerlerinden toplanan gerçek gizli parmak izlerine ulaşmanın özel bilginin gizliliği ilkesine göre güç olduğu aşikardır. Böyle bir veri tabanının gönüllü kişilerce ya da kitle kaynak kullanılarak toplanması ve işaretlenmesi de çok meşakkatli ve masraflı olacaktır; üstelik aslında bu işlemin parmak izi uzmanlarınca yapılması gerekmektedir. Ayrıca, parmak izini veren katılımcılar açısından bir güvenlik riski oluşma

ihtimali vardır. Bu durumda böyle bir veri kümesinin sentetik olarak oluşturulması, bir diğer deyişle gizli parmak izi imgelerinin benzetim yolu ile üretilmesi en gerçekleştirilebilir seçenek olarak karşımıza çıkmaktadır.

Bu projede, öncelikle hazırda var olan sentezleme tekniklerin uygulanması ve incelenmesi hedeflenmiş, daha sonra alternatif sentetik gizli parmak izleri üretme yöntemleri önerilerek bu katkının geliştirilmiştir. Var olan tekniklere Literatür Özeti bölümünde, önerilen uyarlama ve yeni yaklaşımlara ise Gereç ve Yöntem bölümünde değinilecektir.

Projede, sentetik parmak izi imgesi üretiminin yanı sıra, varolan benzer çalışmalardan farklı olarak parmak izi sınıfları, özellik noktaları ve papil çizgisi yönelim verileri işaretlenmiş bir sentetik parmak izi veri kümesi oluşturulmuştur. Bu sayede, üretilen imgelerin gerçek verilere ne kadar yakın oldukları derin öğrenme algoritmalarını eğitebilme ve performansların arttırabilme kabiliyetleri ile ölçülmüştür. Bildiğimiz kadarı ile bu şekilde başka bir çalışma henüz mevcut değildir.

Yapılan çalışmalar doğrultusunda, iki yüksek lisans tezi tamamlanmış, bir uluslararası bildiri yayını yapılmıştır. Halen iki makale de gönderilmek üzere hazırlanma aşamasındadır.

2. LİTERATÜR ÖZETİ

Raporda literatür iki farklı başlıkta incelenecektir: Sentetik parmak izi üretme yöntemleri ve parmak izi tanımda derin öğrenme yaklaşımları. İlk grup çalışma ayrıca model tabanlı ve öğrenme (istatistik) tabanlı yaklaşımlar olarak iki ayrı kısımda değerlendirilecek ve bu iki kısmın birbirine göre avantaj ve dezavantajları tartışılacaktır. Parmak izi tanımda derin öğrenme yaklaşımlarından ise yalnızca proje kapsamı büyük oranda ile ilintili olanlar ele alınacaktır. Projenin ilk önerildiği 2016 yılından bu yana bu alanda yapılan çalışma sayıları üstel büyüme göstermiştir. Bu sebeple, özellikle son 1-2 yılda yayınlanan çalışmalar ele alınacaktır.

2.1 Sentetik Parmak İzi Üretme

2000'li yılların başından itibaren parmak izlerinin sentetik üretimi ile ilgili çalışmalar yayınlanmaya başlanmıştır. Bu çalışmalar genellikle dört farklı hedefe yönelik yapılmıştır:

1. Biyometrik sistemi aşmaya yönelik saldırı geliştirme: Bu gruptaki çalışmalar da kendi içlerinde rastgele saldırılar geliştirme ve hedefe yönelik saldırılar geliştirme olarak ikiye ayrılabilir.

2. Otomatik parmak izi tanıma sistemlerini kapsamlı şekilde test edilebilme: Bu kapsamda yapılan çalışmalar otomatik parmak izi tanıma sistemlerinin performans ölçümlerinin büyük veri setleri ile yapılmasına olanak sağlama amacı gütmüşlerdir.
3. Parmak izi önışleme: Parmak izi tanıma sistemlerinin performansının artırımı hedeflenmektedir; ancak bu hedef doğrultusunda sentetik bir parmak izi veri kümesi oluşturulması yerine eldeki gerçek izlerin iyileştirilmesi yolu seçilmiştir. Önerilen iyileştirme, aslında (yanıklık, bulanıklık vb. sebeplerle) imgede bulunmayan bir alanın gerçeğine uygun olarak üretilmesidir.

Bu projede ise amaç sentetik parmak izi verileri ile derin yapay sinir ağlarını eğitme olarak belirlenmiştir. Bilgimiz dahilinde bunu hedefleyerek parmak izi üreten ve üretilen sentetik verileri derin yapay sinir ağları eğitme performanslarını açısından değerlendiren bir çalışma bulunmamaktadır.

Bu literatür taramasında çalışmalar, yaklaşım farklılıkları (model / öğrenme tabanlı) ekseninde gruplanmış, ancak değinilen çalışmaların yukarıdaki hedeflerden hangisine sahip olduğu ayrıca belirtilmiştir.

Her iki yaklaşımın da kendine göre avantajları ve dezavantajları vardır. Model tabanlı tekniklerde çok fazla manuel çaba gerekir. Üretim adımlarını ayrı görevlere ayırmaya ihtiyaç duyarlar ve her görev önemli miktarda mühendislik getirir. Örneğin, model tabanlı bir parmak izi oluşturma sürecinde, (I) bir parmak izi sınıfı seçilir, (II) ilgili tekil nokta koordinatları ve papil çizgisi yönelimleri belirlenir. (III) papil çizgisi frekans haritaları oluşturulur ve (IV) filtreleme yardımı ile çıkıntı deseni oluşturulur ve (V) bir parmak izi imgesi üretilir. Ek olarak, bu tekniklerde birçok varsayım yapılır. Örneğin, çoğu papil çizgisi yönelimi ve özellik noktası konumlarının bağımsız olduğunu varsayar. Ancak gerçekte bu ikisi arasında bir ilişki olmalıdır. Bu nedenle, modele dayalı teknikler, gerçekçi olmayan özellik noktası konfigürasyonları (Johnson vd., 2013) üretebilir. Başlıca avantajları ise herhangi bir eğitim verisi gerektirmemeleridir. Öte yandan, öğrenme tabanlı yöntemler, parmak izi oluşturmaya öğrenmek için çok sayıda eğitim örneğine ihtiyaç duyar. Ayrıca, öğrenmeye dayalı teknikler kara-kutu şeklinde üreteçler ile sonuçlanır, bu da model tabanlı yaklaşımlarda olduğu gibi özünde hiçbir içgörü elde edilmediği ve parmak izi meta verilerini elde etmek için ek çaba gösterilmesi (elle işaretleme gibi) gerektiği anlamına gelir. Ancak, model tabanlı tekniklere kıyasla istatistiksel olarak daha gerçekçi veri kümeleri üretebilirler.

2.1.1 Model tabanlı yaklaşımlar

Sentetik parmak izi üretme alanında en eski çalışmalar bu grupta yer almaktadır ve büyük oranda otomatik parmak izi tanıma sistemlerini kapsamlı şekilde test edilebilme amacı

taşımaktadır. Cappelli vd., 2000 yılında Gabor benzeri filtreler kullanarak döngülü bir şekilde birkaç çekirdek noktadan büyüyen sentetik parmak izleri üretmişlerdir. Bu çalışmada, delta ve çekirdek pozisyonlarından başlayarak matematiksel bir akış modeli yardımıyla oluşturulan papil çizgisi yönelim haritası, ikinci adımda yeğlilik haritasına dönüştürülmektedir. Daha sonra, papil çizgilerine benzer yapılar ve öznitelik noktaları doğrusal filtreleme yöntemi ile oluşturulmakta ve nihayetinde özel bir gürültü eklenerek imgelere gerçekçi bir görüntü verilmektedir. Cappelli vd. (2002)'de bu çalışmayı daha ileriye götürmüş, aynı ana (master) parmak izine gerçekte de karşılaşılan farklı bozulmalar uygulayarak bir veri tabanı oluşturmuşlardır. Benzetimleri yapılan bu bozulmalar kayma ve dönme, papil çizgisi kalınlık değişkenliği, parmak yüzeyinin uğradığı deformasyon ve ter gözenekleri gibi unsurlardan doğan gürültüdür. FVC2000'e katılan yarışmacı algoritmalar üretilen bu sentetik veri tabanında da test edilmiş, sonuçlar gerçek veri tabanları üzerinde elde edilen diğer sonuçlara benzer olmuştur. Cappelli vd. (2004b)'de bu algoritma SFinGe adlı bir uygulama olarak araştırmacıların kullanımına sunulmuştur.

SFinGe'den farklı bir parmak izi üretme tekniği Imdahl vd. (2015)'te önerilmiştir. Bu çalışmadaki sentetik parmak izleri, bir veritabanından rastgele seçilen gerçek oryantasyon haritası üzerinde, birbirinden bağımsız ve özdeş dağılan siyah ve beyaz noktalardan oluşan bir başlangıç imgesi ve Gabor filtreleri kullanılarak oluşturulmuştur. Üretilen parmak izlerinin gerçekçiliği yerel öznitelik noktalarının histogramları karşılaştırılarak değerlendirilmiştir.

Cappelli ve Maltoni (2009)'da parmak izlerinde bulunan çekirdek ve delta noktalarının uzamsal dağılımlarını incelemişler, elde ettikleri istatistiksel model sayesinde daha gerçekçi parmak izlerinin üretilebileceğini savunmuşlardır. Benzer bir noktadan yola çıkan bir başka çalışmada (Zhao vd., 2012) hem tekil noktalarının hem de yönelim doğrultularının ve öznitelik noktalarının istatistiksel dağılımları incelenmiş, modelleri oluşturulmuştur. Böylece bu modellerden üretilen parametreler doğrultusunda oluşturulan parmak izlerinin daha gerçekçi olması sağlanmıştır.

Bu örneklerden farklı olarak, hedefe yönelik saldırı amaçlı yapılan çalışmalarda öznitelik şablonunun orjinal parmak izini geri çatmaya müsait olduğu gösterilmiştir. Feng ve Jain, (2009) ve Feng ve Jain, (2011)'de bunun faz imgeleri oluşturularak başarılabilirliğini göstermiş, öznitelik haritasından geri çatım ile oluşturulan parmak izi otomatik tanıma sisteminde kimliğine saldırılan kişi olarak tanınmıştır. Daha sonra bu geri çatım papil çizgisi yapılarının yönelim ve faz yama sözlükleri ile kodlanması sayesinde iyileştirilmiştir (Cao ve Jain, 2015b). Yapılan deneylerde, yüksek kalitede parmak izleri için saldırılan kişinin gerçek parmak izine 95,79% oranı ile eşleşme sağlandığı gösterilmiştir.

2.1.2 Öğrenme tabanlı yaklaşımlar

İlkine oranla daha yeni sayılabilecek bu grup, yukarıda sıralanan üç hedefe de yönelik çalışmalar barındırmaktadır.

Bontrager vd., 2018’de bir saldırı tekniği önerilmiş ve ilk defa derin bir mimariye sahip çekişmeli üretici ağlar (ÇÜA) kullanılarak parmak izleri oluşturulmuştur. Daha sonra aynı ağ “kurt” olarak da adlandırılan, herhangi bir parmak izine eşleşme olasılığı yüksek olan parmak izlerini gizli değişken evrimi yöntemi ile tespit etmiştir. Tespit edilen bu izlerin satışa hazır ticari bir sistem üzerine giriş teşebbüsleri en üst güvenlik seviyesinde %22 başarı oranına erişmişlerdir.

Evrimsel otomatik kodlayıcıların orjinal gizli parmak izlerinden yüksek kalitede parmak izleri elde ettikleri bir başka çalışmada (Svoboda vd., 2017), yapay sinir ağı SFinGe uygulaması kullanılarak üretilen sentetik bir veri tabanı ile eğitilmiştir. IIIT-D gizli parmak izi veri tabanı (Sankaran vd., 2012) üzerinde, kendi geliştirdikleri yazılımlar kullanılarak yapılan deneylerde 1. sırada eşleşme oranı %57,69’dan %62,69’a çıkmıştır. IIIT-D MOLF veri tabanı (Sankaran vd., 2012) üzerinde yapılan deneylerde ise en iyi 25. sıra eşleşme oranı %3,07’den %16,14’e çıkmıştır. Daha sonra Roy vd. (2018) eşleşme olasılığını maksimize eden daha iyi ana parmak izleri üretmek için evrimsel teknikler önermişlerdir.

Cao ve Jain (2018)’de ÇÜA kullanılarak çok sayıda parmak izi imgesi üretilmiş ve bu sentetik veri kümesinin kalitesi, çeşitliliği ve özellik noktası konfigürasyonları açısından gerçeğe daha yakın olduğu gösterilmiştir. Benzer bir çalışmaya Fahim ve Jung (2020)’de de yer verilmiştir. ÇÜA’nın eğitimini istikrarlı hale getirmek için gradyanların sürekliliğinin şartlı kayıp katkılması ile sağlandığı bu çalışmada üretilen örneklerin çeşitliliği ölçülmüştür. Son olarak, Mistry vd. (2020)’de 100 milyon sentetik parmak izi imgesi ÇÜA kullanılarak üretilmiş ve bu veritabanı ile yapılan arama sonucu doğruluğunun benzer boyutlarda gerçek veriler ile yapılan arama sonuçlarına benzer olduğu gösterilmiştir.

2.2 Parmak İzi ve Derin Öğrenme

Kontrollü olarak toplanan referans parmak izlerini tanıma amacıyla derin öğrenme algoritmalarının kullanımı diğer bilgisayarla görü alt alanlarına kıyasla oldukça azdır. Veri eksikliğine bağlı olarak, bu yaklaşım özellikle gizli parmak izi tanıma alanında daha da sınırlı kalmıştır. Bu projede üretilen sentetik verilerin gerçeğe yakınlığını ölçmek için kullanılan parmak izi tanıma sistemlerine ait dört alt alanda önerilen derin öğrenme yaklaşımları şu şekildedir:

2.2.1 Parmak izi sınıflandırma

Bu alandaki ilk çalışma 2016 yılında karşımıza çıkmaktadır. Bu çalışmada (Wand, vd. 2016) 4-sınıflı sınıflandırma işlemi üç gizli katmana sahip bir istiflenmiş seyrek otomatik kodlayıcı kullanılarak yapılmış ve %91.4 doğruluk elde edilmiştir. Michelsanti vd. (2017)'de parmak izleri ön-eğitilmiş evrişimsel yapay sinir ağları (EYSA) kullanılarak sınıflandırılmış ve %94.05 başarımla sağlanmıştır. Tertychnyi vd. (2018) ise VGG16'yı baz alan bir derin yapay sinir ağı ile düşük kalitedeki parmak izi imgelerini sınıflandırmıştır.

Listyalina ve Mustiadi (2019)'da ImageNet veritabanında önceden eğitilmiş GoogLeNet ile transfer öğrenmesi kullanan bir yaklaşım önerilmiştir. Ağın ilk 10 katmanı dondurularak ve son katman parmak izi sınıflandırma görevi için uyarlanarak eğitilen model 5 sınıflı ve 4 sınıflı sınıflandırmada sırasıyla %94,7 ve %96,2 doğruluk elde etmiştir.

2.2.2 Özellik noktası tespiti

Derin öğrenme yaklaşımının öznelik noktalarının çıkarımı için kullanılmasının önerildiği ilk çalışmada (Sankaran vd., 2014) referans parmak izi imgelerinden yamalar çıkartılmış ve çıkartılan yamalar öznelik içerip içermediklerine göre iki istiflenmiş otomatik kodlayıcının eğitiminde kullanılmışlardır. Böylelikle parmak izi yamaları için iki farklı tanımlayıcı elde edilmiştir. Daha sonra tüm parmak izi yamaları için hesaplanan tanımlayıcılar kullanılarak yine iki ayrı (öznelik içeren ve içermeyen yamalar için) eğitimli sınıflandırıcı eğitilmiştir. Bu sistem sayesinde bilinmeyen bir parmak izi yaması geldiğinde öncelikle iki otomatik kodlayıcı ile tanımlayıcıları çıkartılır, daha sonra iki tanımlayıcı kendisine karşılık gelen sınıflandırıcıya sokulur ve elde edilen iki sınıf skoru ağırlıklı ortalaması alınarak birleştirilir ve bir karara varılır. Bu çalışma da derin öğrenme için referans parmak izi veri kümeleri kullanılmış, sistemin gizli parmak izleri için çalışacak bir genelleştirebilme yeteneğine sahip olduğu varsayılmıştır.

Daha sonrasında, Tang vd. (2016)'da öznelik tespiti için farklı bir derin mimari önerilmiştir. Bu çalışmada, işlenmemiş gizli parmak izi imgelerini bir öznelik tespit skoru haritasına eşlemek için tam bir EYSA kullanılmıştır. Çıkartılan öznelik noktaları etrafındaki ufak yamalar bir başka EYSA'ya verilerek sınıflandırmaları yapılmış ve yönelimleri tespit edilmiştir. Hesaplamaların hızlandırılması için, eğitilen iki ağda evrişim katmanları ortak kullanılmıştır. Bu çalışmada derin ağların eğitimi için Çin emniyeti tarafından toplanan ve öznelik noktaları işaretlenen 4205 adet gizli parmak izi kullanılmıştır. Maalesef bu veri kümesi başka araştırmacıların kullanımına açık olmadığından çalışmanın geliştirilmesinin mümkün olmadığı gibi raporlanan sonuçların tekrar üretilmesi de imkansızdır.

Jiang vd. (2016)'da yama tabanlı bir yaklaşımla EYSA kullanılması önerilmiştir. Bu doğrultuda iki ağı eğitilmiştir: aday özellik noktaları yamalarını tespit eden JudgeNet ve JudgeNet tarafından tespit edilen aday yamalar içindeki ayrıntı noktalarının kesin konumunu tespit eden LocateNet. Deneyler için gizli bir parmak izi veri tabanı kullanılmış ve %94.59 kesinlik, %91.63 geri çağırma ve %93.08 F1 skoru elde edilmiştir.

Buna benzer bir mimari Darlow ve Rosman (2017) tarafından da önerilmiştir, ancak iki ağ yerine, yama merkezini özellik noktası olan ve olmayan olarak sınıflandıran tek bir ağ (MeNet) kullanılmıştır. Daha sonra son işlem yoluyla özellik noktalarının kesin konumlarını belirlenmiştir. Tam boyutlu parmak izi görüntülerinde 30x30 bir pencere kaydırılarak MeNet için girdiler elde edilmiştir. MeNet çıktısı olarak elde edilen olasılık haritası medyan filtresi ile düzeltilmiş ve yinelemeli eşikleme ile özellik noktalarının konumları elde edilmiştir. Yaklaşım FVC veritabanları, FVC2000, FVC2002 ve FVC2004 (Dorizzi vd., 2009) üzerinde test edilmiştir. Bu veritabanlarındaki parmak izi görüntüleri ise ticari özellik noktası çıkarıcılar kullanılarak etiketlenmiştir.

Tang vd. (2017)'de gizli parmak izlerinde daha iyi sonuçlar elde etmek için alan bilgisi ile derin öğrenmenin temsil etme gücünü birleştiren bir yaklaşım önerilmiştir. Önceden yaygın olarak kullanılan papil çizgisi yönelimi tahmini, segmentasyon, iyileştirme ve özellik noktası çıkarma adımları sabit ağırlıklı evrişimli çekirdekler olarak tasarlanmış, bu katmanlar, serbest ağırlıklara sahip ek evrişim katmanlarıyla genişletilmiş, böylece ağın arka plan ayrıntılarını da öğrenmesi sağlanmıştır. FingerNet olarak adlandırılan bu mimari FVC2004 ve NIST SD27 veritabanları üzerinde test edilmiştir. Ancak elde edilen sonuçların, segmentasyon ve iyileştirme başarısına güçlü bir şekilde bağlı olduğu görülmüştür.

Nguyen vd. (2019)'da alan bilgisi ve derin öğrenme yaklaşımı iki ağla birleştirilmiştir: CoarseNet ve FineNet. Papil çizgisi yönelimleri, iyileştirilmiş görüntüler, segmentasyon haritaları ve aday özellik noktası yamaları elde etmek için CoarseNet kullanılmıştır.. Ardından, FineNet ile aday yamalarda daha güvenilir özellik noktaları saptanmıştır. FVC2004'te %85.9 hassasiyet, %84,8 geri çağırma ve NIST SD27'de %71,2 hassasiyet, %75,7 geri çağırma elde edilmiştir.

Daha yeni bir çalışmada (Zhou vd., 2020), tamamen evrişimli bir ağı paylaşan iki ağ ile iki aşamalı bir algoritma önerilmiştir. İlk aşamada, parmak izi görüntüsü yalnızca bir özellik noktası içerebilen küçük hücrelere bölünür ve paylaşılan evrişimsel ağdan elde edilen öznitelik haritası kullanılarak aday yamalar seçilmiştir. Bunun için, her hücrenin özellik noktasına sahip olma olasılığı hesaplanmış ve daha yüksek puanlı hücreler belirlenmiştir. İkinci aşamada ise, aynı öznitelik haritasını kullanılarak, yamanın merkezinde özellik noktası

olma olasılığı, konumu ve yönü hesaplanmıştır. FVC2002 DB1-A veritabanında %87,90 hassasiyet, geri çağırma ve F1 skoru rapor edilmiştir.

Ne yazık ki, özellik noktaları çıkarma için parmak izi sınıflandırmada olduğu gibi ortak kullanılan bir kıyaslama veri seti yoktur. Elle işaretlenmiş gerçek özellik noktaları mevcut olan tek veri seti FVC2002'dir. Bu nedenle, bu projede de bu veri kümesi kullanılmıştır.

2.2.3 Papil yönelim çizgisi kestirimi

Papil çizgisi yönelimi için derin öğrenme yaklaşımı öneren çalışmalar diğer adımlara göre daha azdır. Bu alanda ilk karşımıza çıkan çalışmada (Cao ve Jain, 2015) yönelim kestirimi parmak izi imgesinden çıkartılan küçük yamalar için bir sınıflandırma problemi olarak ele alınmıştır. Bu işlem için öncelikle çok sayıda papil çizgisi yönelim haritasından 128 temsilci çizgi örüntüsü belirlenmiştir. Daha sonra bu temsilci örüntülerin her biri için 10.000 parmak izi yaması kullanılarak sınıflandırıcı bir EYSA eğitilmiştir. Eğitim kümesindeki yamalar gizli parmak izi örnekleri sınırlı olduğu için referans veri tabanlarından alınmış, yamalara eklenen örüntü gürültüsü ile gizli parmak izi görüntüsünün benzetimi yapılmıştır.

Diğer iki çalışma ise (Schuch vd., 2017a, Schuch vd. 2017b) aynı yazarlar tarafından yapılmıştır. Schuch vd. (2017a)'da, sınıflandırmada iyi sonuçlar veren EYSA'ları regresyon için kullanabilme amacı ile derin beklenti adı verilen bir algoritma önerilmiştir. Bu algoritmanın temeli sınıflandırma sonucu sınıflara yayılan olasılık dağılımlarını ağırlıklar olarak kullanmaktır. Schuch vd. (2017b)'de ise EYSA'lar doğrudan regresyon için eğitilmişlerdir.

2.2.4 Parmak izi eşleştirme

Bu alanda karşılaştığımız ilk çalışmada (Ezeobiesi ve Bhanu, 2018), yine yama tabanlı bir yaklaşımla ve derin öğrenme kullanılarak parmak izleri arasındaki benzerlik skorları hesaplanmıştır. NIST SD27 veri kümesinde %81.35 kimlik tespiti başarımları rapor edilmiştir.

(Li vd. 2019)'da benzer bir yaklaşımla EYSA kullanılarak yamalardan yerel ve parmak izi imgesinin tamamından global öznitelik vektörleri çıkarılmış, daha sonra bu vektörler arasındaki uzaklık kullanılarak eşleştirme kararı verilmiştir. Bu yöntem ile NIST SD4'te kimlik tespitinde %99.83 başarımları elde edilmiştir.

Cui vd. (2019)'da ise yerdeğişim regresyon ağı kullanılarak piksel ölçeğinde yerdeğişim alanı hesaplanmış ve parmak izi imge çiftleri böylece karşılaştırılmıştır. Böylece parmak izi eşleştirme performanslarında artış elde edildiği gösterilmiştir.

Anand ve Kanhangad (2020)'de yüksek çözünürlüklü parmak izi imgelerinde bulunan gözenekler EYSA temelli bir ağ ile tespit edilmişler ve etraflarındaki yamalar kullanılarak tanımlanmışlardır. Bu tanımlayıcılar kullanılarak parmak izleri karşılaştırılmış ve doğrulama testleri yapılmıştır. PolyU HRF veri kümesinde kısmi ve bütün parmak izlerinde sırasıyla %2.27 ve %0.24 eş hata oranı elde edilmiştir. Yine gözeneklerin kullanıldığı bir başka çalışmada (Liu vd., 2020), her bir gözenek EYSA'lar ile tanımlanmış, ve gözenek eşleştirmeleri bu tanımların Ağırlıklandırılmış Rastgele Örnek Fikir Birliği (WRANSAC) algoritmasında kullanılması ile gerçekleştirilmiştir.

Son olarak, He vd. (2020)'de uzamsal dönüştürücü ağlar kullanılarak parmak izi imgelerinden kimlik doğrulaması yapılmış, FVC2006 DB1'de %3.587 eş hata oranı elde edilmiştir.

Yukarıda bahsedilenlerden farklı olarak birden fazla görevi aynı anda yerine getirmeyi hedefleyen derin mimariler de bulunmaktadır. Örneğin, Cao ve Jain (2017) hem papil çizgisi yönelimlerinin kestirimi hem de öznitelik noktası çıkarımı için EYSA kullanan bir sistem geliştirmişlerdir. Gizli parmak izini temsil etmek üzere 3 farklı tanımlayıcı şablonu önerilmiştir. İlk iki şablon öznitelik şablonu üçüncüsü ise örüntü şablonudur. İlk öznitelikler Cao ve Jain (2015)'teki EYSA tabanlı yöntem kullanılarak belirginleştirilen papil çizgilerinden Cao vd. (2016)'da anlatılan şekilde çıkartılmıştır. İkinci öznitelik kümesi ise Cao vd. (2014)'te önerildiği üzere kabadan inceye bir sözlük yaklaşımı kullanılarak belirginleştirilen papil çizgilerinden elde edilmiştir. Son olarak, düzenli bir şekilde örtüşmeyen bloklara ayrılan parmak izi imgesinde her bloğun birbirine zıt yönlü iki öznitelik içerdiği varsayılmıştır. Bu üç öznitelik kümesi için öznitelik tanımlayıcıları yine EYSA kullanılarak hesaplanmışlardır. Bunun için, bir öncelikle öznitelik noktasının etrafında farklı konum ve büyüklüklerde 14 yama çıkartılmış ve 14 farklı EYSA aynı öznitelik noktalarını tanımak (sınıflandırmak) üzere eğitilmiştir. Daha sonra, EYSA sınıflandırıcısının en sonundaki tam bağlantılı katmanın çıktısı 128 boyutlu bir tanımlayıcı öznitelik vektörü olarak kabul edilmiştir. Bu EYSA'nın eğitimi için yine bir referans parmak izi veri tabanı kullanılmış, gizli izler üzerinde de çalışacağı varsayılarak herhangi bir benzetim yapılmamıştır. Çalışmanın sonunda, Cao ve Jain sonuçların daha da geliştirilebilmesi için EYSA'ların gerçek ve büyük bir gizli parmak izi veri kümesi ile eğitilmesi gerektiğini vurgulamışlardır.

3. GEREÇ ve YÖNTEM

Projedeki iş paketlerine paralel olarak gereç ve yöntemler parmak izi üretme ve derin öğrenme ile parmak izi işleme adımlarını gerçekleştirme olarak iki kısımda ele alınacaktır.

3.1 Sentetik Parmak İzi Üretme

C, D ve E kodlu iş paketlerinde farklı teknikler ile parmak izleri üretmek hedeflenmiştir. Bu hedefler kullanılan yaklaşımlara göre üç gruba ayrılabilir:

3.1.1 Model tabanlı parmak izi üretme

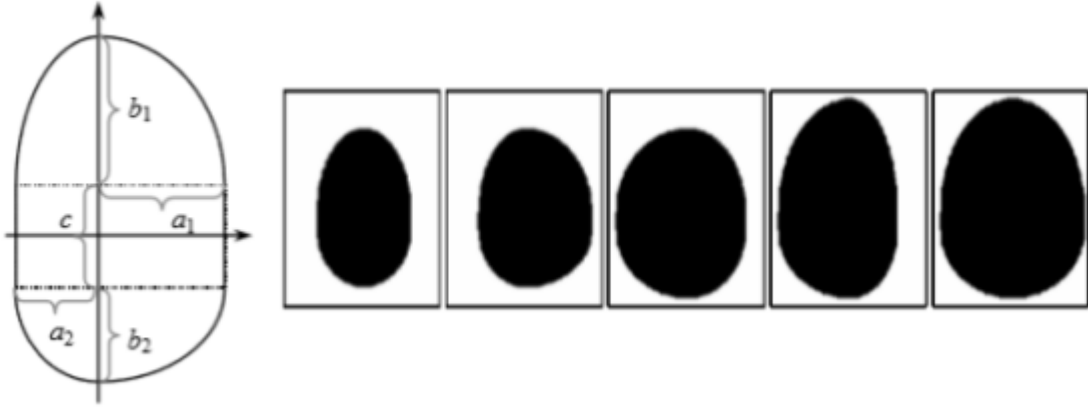
Proje önerisine göre var olan yöntemler ile parmak izi üretme ve bunların uyarlanması işi için SFinGe (Cappelli vd., 2004) uygulaması kullanılarak sentetik bir veri tabanı üretilmesi planlanmıştır. Ancak, araştırmacıların kullanımına açık olduğu varsayılan SfinGe uygulamasının akademik kullanım için hazırlanan ve 100.000 parmak ile sınırlandırılmış temel sürümünün 4.900€ olduğu öğrenilmiştir. Bu sebepten dolayı alternatif bir uygulama arayışına girilmiş ve Anguli (Ansari, 2011) uygulaması incelenip uygun bulunmuştur.

SFinGe'in aksine, Anguli ücretsiz kullanılabilen bir araçtır ve bu sebepten dolayı bu çalışma dışında da sentetik parmak izi görüntülerini üretmek için seçilmiştir. Örneğin, 2018'de People ECCV Satellite Challenge'da, Track 3 yarışması için temel gerçek parmak izi görüntüleri üretmek için kullanılmıştır (WCCI 2018).

Bu proje kapsamında, sentetik olarak üretilen eğitim verilerinin ve bu verilerdeki değişkenliğin parmak izi sınıflandırma performansını nasıl etkilediğini analiz etmek için, Anguli yazılımı kullanılarak oluşturulan sentetik veriler, 7 farklı eğitim setine yol açacak farklı varyasyonlara tabi tutulmuştur.


İlk olarak, Anguli kullanılarak bir papil çizgisi yönelimi ve yoğunluk haritası oluşturulmuş ve böylece gürültüsüz bir ana parmak izi elde edilmiştir. Daha sonra, farklı sentetik eğitim veri setleri oluşturmak için, aşağıda listelenen bozulmalar ana parmak izine harici olarak eklenmiştir:

1. Parmak izi alanı: Parmak izlerinin şekli; parmağın boyutu, baskı açısı, baskı şiddeti gibi etkenlerden dolayı farklılık gösterir. Parmak izlerinin temas yüzeylerinde oluşturduğu geometrik şekil, elips ve dikdörtgenler kullanılarak modellenebilir. Şekil 3.1'de örnek bir parmak izi alanı parametrik olarak gösterilmiştir. Bu resimde koordinat düzleminde bulunan her bölge birer elips ve birer dikdörtgen kullanılarak oluşturulmuştur. a_1 , a_2 , b_1 ve b_2 parametreleri elipsler oluşturulurken kullanılırken, ek olarak c parametresi dikdörtgenlerin oluşturulması için kullanılır. Dört çeyrek elips ve dikdörtgen bir araya getirilip aşağıdaki örneklerde gösterilmiş olan parmak izi alanlarını oluştururlar.



Şekil 3.1. Dört elips ile oluşturulan parmak izi alanı modeli ve örnek parmak izi alanları (Maltoni vd., 2009)


2. Ölçekleme, döndürme ve öteleme: İmgeler merkezleri etrafında (-10.5, + 10.5) aralığından eşit şekilde rastgele örneklenen dereceler ile döndürülmüştür. Aynı şekilde, (0.5, 1.32) aralığından örneklenen faktörler ile ölçeklenmiş ve x ve y yönlerinde (-20, + 20) piksel aralığından örneklenen değerler kadar ötelenmiştir.
3. Arka plan: Arka plan görüntüleri çok aşamalı olarak üretilmiştir: İlk olarak, farklı kağıt benzeri temel dokular oluşturulmuştur. Daha sonra, parmak izi görüntülerinde sıklıkla bulunan rakamlar, sınıf etiketleri ve parmak bilgileri gibi işaretler ve ek açıklamalar rastgele bir yerde ve ölçekte arka plan üzerine yazdırılmıştır. Ardından, farklı sayı, konum, açı ve boyuttaki çizgiler ve noktalar eklenmiş ve Gaussian bir filtre uygulanarak bulanıklaştırılmıştır.



Şekil 3.2. Üretilen arka planlardan örnekler

4. Pertürbasyonlar: Papil çizgisi pertürbasyonları, bu çizgilerdeki süreksizlikler ve mürekkep desenindeki düzensizliklerdir. Bu tür bozulmalara sahip örnek gerçek

parmak izi ekleri, Şekil 3.3.a'da gösterilmektedir. Parmak izleri, görsel olarak sırt belirginliğini etkileyen parlak ve karanlık bölgelere sahip olabilir. Şekil 3.3.b'de gerçek bir parmak izini ve mürekkep yoğunluğu haritasını gösterir. Görsel olarak gerçekçi, gürültülü sırt deseni görüntüleri oluşturmak için, bu bozulmalar üretim sürecine dahil edilmelidir.




Şekil 3.3. (a) Gerçek parmak izi görüntülerindeki papil çizgisi devamsızlıkları ve yoğunluk düzensizliği (b) Gerçek bir parmak izine medyan filtre uygulanarak elde edilen ve tekdüze olmadığı görülen yoğunluk düzensizliği

Bu bozulmanın simüle edilmesi için şu yöntem önerilmiştir:

- Pertürbasyon imgesi tamamen beyaz olacak şekilde iklendirilir.
- Her bir piksel için $[0, 1]$ aralığında tekdüze dağılılan bir skor değeri örneklenir.
- Pikseller skor değerleri bir P parametresinden küçük ise ve ana parmak izinde papil çizgisi üzerinde ise siyaha dönüştürülür
- Pertürbasyon imgesine Gauss bulanıklaştırması uygulanır.

Farklı P parametreleri ile oluşturulmuş örnek pertürbasyon imgeleri Şekil 3.4'te görülebilir.

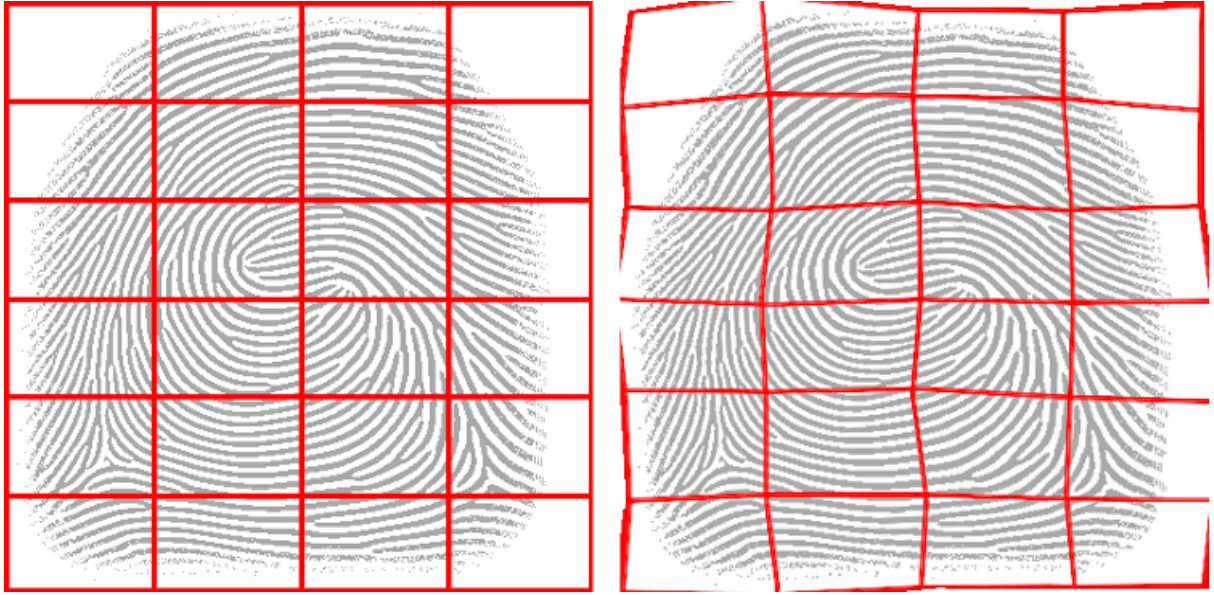


Şekil 3.4. $[P_{max}, P_{min}]$ aralığında örnekleme ile iklendirilerek oluşturulmuş pertürbasyon imgeleri (a) $P_{max} = 0.85$, $P_{min} = 0.15, 0.35, 0.65, 0.85$ (b) $P_{min} = 0.15$, $P_{max} = 0.15, 0.35, 0.65, 0.85$.

5. Deri deformasyonları: Parmak izi alınan yüzeye bastırıldığında meydana gelen parmak şekli deformasyonlarını simüle etmek için düzenli bir ızgara üzerinde parçalı afin dönüşüm uygulanmıştır.



Şekil 3.5. Kırmızı ve yeşil parmak izleri FVC2002 DB1-A'dan alınmıştır ve aynı parmağa aittirler. Bu izler hizalandığında ve üstüste bindirildiğinde nasıl bir deformasyon farkı olduğu açıkça ortaya çıkmaktadır.




Şekil 3.6. Ana parmak izine oturtulan düzenli ızgara ve deformasyon sonucu aldığı şekil.

6. Papil kalınlığı değişimi: Parmak ucu kuruyorsa, papil çizgileri daha ince ve nemli ise daha kalın görünür. Bunu simüle etmek için morfolojik operatörler uygulanmıştır. [-4.+4] aralığında tekdüze dağıldığı varsayılan T parametresi ile kontrol edilen bu işlem Şekil 3.7’de resmedilmiştir.




Şekil 3.7. Negatif T değerleri kuruluk ya da düşük baskı kuvvetini modellerken, pozitif T değerleri ıslaklık ya da yüksek baskı kuvvetini modeller.

7. Skarlar: Deri kıvrımlarını ve izlerini simüle etmek için rastgele uzunluk, kalınlık, açı ve sayıda elipsler eklenmiştir.



Şekil 3.8. (a) Gerçek parmak izlerindeki örnek skarlar (b) Tek bir skar oluşturulması (c) Birden fazla skar eklenmiş ana parmak izi görüntüsü


Toplam 7 eğitim veri seti aşağıdaki değişkenlerle oluşturulmuştur: v0: Ham Anguli ana parmak izi, v1: 1 + 2, v2: 1 + 2 + 3, v3: 1 + 2 + 4 + 5, v4: 1 + 2 + 3 + 4 + 5, v5: 1 + 2 + 3 + 4 + 5 + 6 ve v6: 1 + 2 + 3 + 4 + 5 + 6 + 7.



Şekil 3.9. Oluşturulan sentetik veri kümelerinden her bir parmak izi sınıfı için örnekler

Çalışmanın daha sonraki aşamalarında ana parmak izinin Anguli kullanmak yerine kendi geliştirdiğimiz kodla üretilmesi hedeflenmiştir. Buna yönelik, Maltoni vd. (2009)'da tanımlanan adımlar ve önerilen yöntemler izlenmiş ve bazı alt adımlarda geliştirmeler önerilmiştir:


1. Papil çizgisi yönelim haritasının oluşturulması: Parmak izlerinde bulunan papil çizgilerinin yönelimlerini modellemek için Sherlock and Monro Modeli'nden (Sherlock ve Monro, 1993) yola çıkılmıştır. Bu model ile yönelim imge hesaplaması çekirdek (I_s) ve delta (d_s) noktalarını kullanarak karmaşık sayılar düzleminde yapılmaktadır. Parmak izindeki her bir nokta için bir Θ açısı hesaplanmaktadır. Şekil 3.10'ta Sherlock and Monro modeli kullanılarak, sağ kement sınıfına ait oluşturulmuş örnek bir yönelim haritası gösterilmiştir. Ancak oluşturulan harita iyi bir yaklaşım olmasına rağmen gerçek bir parmak izi ile kıyaslandığında çok başarılı değildir.



Şekil 3.10. Sherlock and Monro modeli kullanılarak, sağ kement sınıfına ait oluşturulmuş örnek bir yönelim haritası (Maltoni vd., 2009)

Bu işlem için kullanılan formüldeki (Denklem 1) $\arg(c)$ fonksiyonu, c karmaşık sayısının faz açısını verir ve z noktasındaki Θ açısı, bu noktanın deltalar ile yaptığı faz açılarının toplamı ile çekirdeklerin yaptığı faz açılarının toplamalarının farklarının yarısına eşittir. Vizcaya ve Gerhardt, (1996)'da modele, her bir çekirdek ve delta için lokal olarak açılar düzeltme yeteneği bulunan parçalı ve doğrusal g fonksiyonları eklenmiştir. Bu model her bir tekil nokta çevresini 8 eşit açısal parçaya böler ve z noktasının düzeltme değerini doğrusal aradeğerleme yaparak hesaplar. Böylece tekil noktalara göre açı düzeltmesi uygulanmış olur.(Şekil 3.11)

$$\theta = \frac{1}{2} \left[\sum_{i=1}^{n_d} g_{ds_i}(\arg(z - ds_i)) - \sum_{i=1}^{n_c} g_{ls_i}(\arg(z - ls_i)) \right], \quad (1)$$



Şekil 3.11. Vizcaya ve Gerhardt, (1996)'de önerilen Sherlock and Monro modelinin geliştirilmiş hali ve sonuç olarak iyileştirilen yönelim haritası (Maltoni vd., 2009)


Yay sınıfı için ise farklı bir yöntem izlenmiştir ve bu örüntü sinüs fonksiyonu kullanılarak simüle edilmiştir:

$$\Theta = \beta \sin(f(x))$$


where $\frac{\pi}{2} \leq f(x) \leq -\frac{\pi}{2}$ and $0.75 \leq \beta \leq 1.4$

$$f(x) = \left[f_{min} + (f_{max} - f_{min}) \frac{(x - x_{min})}{(x_{max} - x_{min})} \right] \quad (2)$$

Buradaki (Denklem 2) f fonksiyonu imgedeki x koordinatlarını sinüzoidal eğriye eşlemektedir. Denklemdeki β parametresi sinüs fonksiyonunun büyüklüğünü belirlemektedir. Bu model ile oluşturulan eğriler Şekil 3.12'de gösterilmiştir. Üretilen değişkenliğin çok yüksek olmadığı açıktır, bu sebeple Vizcaya ve Gerhardt, (1996) benzeri ek düzeltmeler hesaplanmış, böylece değişkenliğin artması sağlanmıştır (Şekil 3.13).



Şekil 3.12. β parametresinin yay örüntüsüne olan etkisi




Şekil 3.13. (a) Düzeltme yapılmamış yay yönelim haritası (b) a'daki haritanın düzeltilmiş hali (c) Eklenen düzeltme yön ve büyüklükleri

2. Frekans imgesi üretilmesi: Papil çizgisi frekansı, yerel bir bölgede papil çizgilerine dik uzanan hat boyunca birim uzunluk başına kaç çizginin görüneceğini belirler. Gerçek parmak izi görüntülerinde, genellikle parmak izinin üst kısmının parmak izinin geri kalanına göre daha düşük bir frekansa sahip olduğu ve bir parmak izindeki farklı bölgelerin farklı papil frekanslarına sahip olabileceği gözlemlenir. Ayrıca tekil noktalar

da yerel frekansları etkiler. Böylece, gerçek parmak izlerinde papil çizgisi frekanslarının rastgele olmadığı sonucuna varılabilir. Ancak, bu çalışma için parmak izinin tüm parçaları için frekans haritaları rastgele oluşturulmuştur. Gerçek parmak izi görüntülerini inceleyerek gerçekçi frekans haritaları oluşturmak geleceğe yönelik bir çalışma olarak kalmıştır.

Papil çizgisi frekansları, tekillikler etrafındaki alanlar dışında yerel komşu çizgiler arasında yumuşak geçişlere sahiptir. Başka bir deyişle, yakın çizgiler tutarlı frekans değerlerine sahiptir. Bu nedenle, çift-küçük aradeğerleme tekniği kullanılarak tutarlı gürültü haritaları oluşturulması yöntemi önerilmiştir. Farklı çözünürlüklerde (2x2, 3x3 ve 5x5) rastgele üç tekdüze gürültü görüntüsü oluşturulur ve daha sonra aradeğerleme uygulanarak aynı boyuta (400x400) ölçeklendirilirler. Son frekans görüntüsü ise bu görüntüler toplanıp minimum-maksimum normalizasyonu uygulanarak elde edilir (Bu çalışmada normalizasyon için minimum ve maksimum frekanslar deneysel olarak 0.11 ve 0.17 olarak belirlenmiştir.). Şekil 3.14 bu süreci göstermektedir.

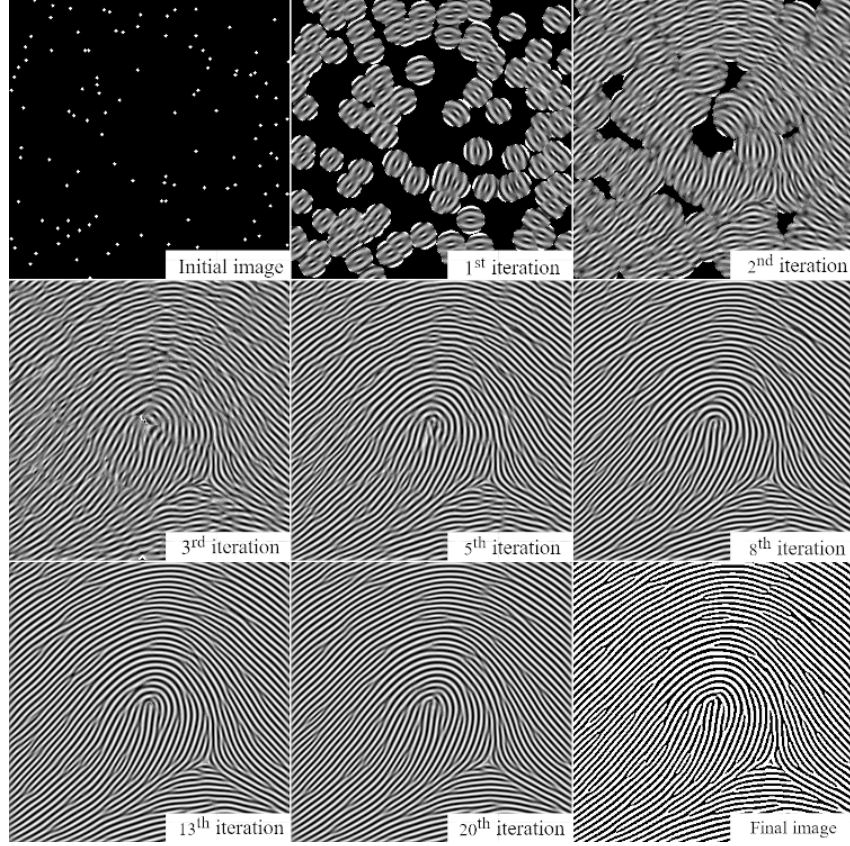


Şekil 3.14. Örnek bir frekans haritası oluşumu.

3. Papil çizgisi üretilmesi: Ana parmak izi üretiminin son aşaması olan papil çizgisi üretimi, önceden elde edilmiş olan parmak izi alanı, papil çizgisi yönelim haritası ve frekans imgesi çıktılarını kullanır. Bu aşamada imge üzerine Gabor filtreleri ile tekrarlı evrişim uygulanır. Gabor filtreleri 2 boyutlu sinüzoid ve 2 boyutlu gaussian fonksiyonlarının çarpılması ile elde edilir. Her bir parmak izi noktası için yönelim haritası sinüzoidin açısını, frekans imgesi ise sinüzoidin frekansını belirlemek için kullanılır.

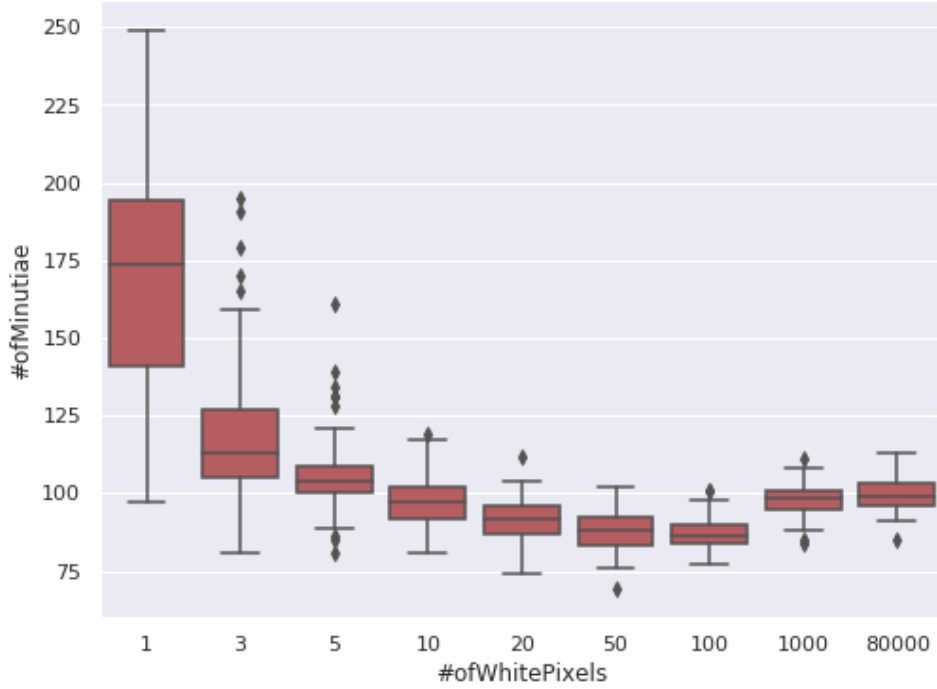
Şekil 3.15'te rastgele üretilmiş imge üzerinde tekrarlı olarak uygulanan evrişim işleminin sonuçları gösterilmiştir. İmge N kere evrişim işleminden geçirildikten sonra eşiklenir ve ana

parmak izi bu işlem sonucunda üretilmiş olur. Her tekrarda daha pürüzsüz bir parmak izi üretildiği gözlemlenmiştir.



Şekil 3.15. Farklı sayıda yineleme uygulanarak üretilen bir ana parmak izi

Çalışmamızda aynı frekans ve yönelim haritaları fakat farklı başlangıç imgeleri kullanılarak oluşturulan ana parmak izlerinin davranışları değerlendirilmiş, başlangıç imgesinde bulunan beyaz nokta (tohum) sayısının oluşan parmak izi örüntüsündeki özellik noktası miktarına olan etkisi de incelenmiştir. Elde edilen sonuç Şekil 3.16'da görülebilir.




Şekil 3.16. Aynı frekans ve yönelim haritası kullanıldığı durumda, artan başlangıç imgesi beyaz nokta sayısının üretilen ana parmak izindeki özellik noktası miktarı ile olan ilişkisi

Yukarıda anlatıldığı üzere, üretilen sentetik parmak izi veri kümesi içinde her bir imgenin frekans ve eğilim haritaları bellidir. Bu sebeple frekans ve yönelim kestirimi algoritmaları için doğrudan kullanılabilirler. Ancak, aynı avantaj özellik noktaları için geçerli değildir. Ana parmak izinin mdel tabanretilmesi yaklaşımında özellik noktalarına bağlı üretim yapabilmek üzerine çalışmamıza rağmen bunu mümkün kılacak bir yöntem geliştirmeyi başaramadık. Ancak, ana parmak izinin alt üreme aşamalarında özellik noktalarının yerini yüksek doğruluk ile tespit edecek bir yöntem geliştirdik.

Basitçe, son evrişim yinelemesinden sonra elde edilen tepki imgesi üzerinde eşikleme olarak açıklayabileceğimiz bu yöntemin aşamaları şöyledir (Şekil 3.17):

1. Tepki imgesi $[-1,1]$ aralığına ölçeklenir.
2. Her bir piksel için özellik noktası olup olmama olasılığı $P(x) = 1 - |\tanh(x)|$ formülü ile hesaplanır.
3. Olasılık değerleri için 0.8 eşiği uygulanır.
4. Medyan filtre ile gürültüler giderilir.
5. Sonuç görüntüsü iskelet haline getirilir ve maksimum bastırma ile özellik noktası lokasyonları tespit edilir.




Şekil 3.17. (a) Tepki imgesi (b) Özellik noktası olasılık haritası (c)Eşik uygulanmış olasılık haritası (d) Medyan filtre uygulanmış olasılık haritası (e) İskelet haline getirilmiş olasılık haritası (f) tespit edilen özellik noktaları


Sonuç olarak elde edilen; sınıfı, yönelim ve frekans haritaları ile özellik noktaları bilinen parmak izi örnekleri Şekil 3.18'de verilmiştir.

Yukarıda anlatılan yöntemler ile 7 farklı sentetik parmak izi veri kümesi oluşturulmuştur:

- V0: Tüm bozulmalar uygulanmıştır.
- V1: Papil çizgisi kalınlığı değişimi uygulanmamıştır.
- V2: Deri deformasyonu uygulanmamıştır.
- V3: Ölçekleme, döndürme ve öteleme uygulanmamıştır.
- V4: Papil çizgisi pertürbasyonları uygulanmamıştır.
- V5: Arka plan uygulanmamıştır.
- V6: Son-işlem (sigmoid düzeltme ve parlaklık ayarı) uygulanmamıştır.



Şekil 3.18. Yukarıdan aşağı sırasıyla sol kement, sağ kement, tak tipi, yay ve helezon sınıflarına ait sentetik parmak izi örnekleri



Şekil 3.19. Aynı parmak izinin farklı veri kümelerindeki görüntüsü

3.1.2 Öğrenme tabanlı parmak izi üretme

Beş farklı çekişmeli üretici ağ (ÇÜA) ile deneyler yapılmış ve ağlar NIST SD04 veri kümesi kullanılarak eğitilmiştir. Bu veri seti, 4000 adet 8 bit gri tonlamalı parmak izi görüntüsünden oluşmaktadır. Bu parmak izleri beş kategoride sınıflandırılmıştır, ancak eğitim için tek bir sette birleştirilmiştir. Tüm modeller kabaca 400 dönem için eğitilmiş ve 64000 görüntü üretilmiştir. Elde edilen sonuçlar şöyledir:

1. DCGAN: DCGAN, CNN mimarileriyle GAN'ları büyütmenin yolunu açmıştır. Model, havuzlama katmanlarını, ayırıcı için kaydırmalı evrişim katmanları ve üretici için kesirli kaydırmalı evrişim katmanları ile değiştirmiştir. Üreteçte, sonuncu dışındaki tüm katmanlar ReLU aktivasyonu kullanır. Jeneratör çıktı katmanı Tanh, ayırıcı ise LeakyReLU kullanır. Modelin eğitimi için Adam iyileştirici ve ikili çapraz entropi kaybı kullanılmıştır. İlk eğitim için orijinal DCGAN makalesinde (Radford vd., 2015) önerilen parametreleri kullanılmıştır. Bu parametreler:
 - Öğrenme hızı = 0.0002
 - Resim boyutu = 64x64
 - Gizli vektör boyutu = 100
 - LeakyReLU negatif eğim = 0,2
 - Adam iyileştirici Beta değerleri = (0,5, 0,999)

Bu parametreler ile maalesef yeterli kalitede imge üretilenmemiştir. İmge ve gizli vektör boyutlarını arttırmak fayda sağlamamış, eğitim süresini de kayda değer şekilde uzatmıştır.

2. LSGAN: Bu mimari, ayırıcıdaki çapraz entropi kaybını en küçük kare kaybıyla değiştirerek GAN'lardaki kaybolan gradyan sorunlarını ortadan kaldırmaya çalışmıştır (Mao vd., 2017). LSGAN'ın normal GAN'lara göre daha istikrarlı eğitimle daha kaliteli görüntüler oluşturduğunu iddia edilmektedir. Projede denenen mimarileri karşılaştırmak için aynı eğitim parametreleri ve evrişim katmanları kullanılmıştır. LSGAN DCGAN'a göre önemli ölçüde daha iyi sonuçlar vermiş, ancak parmak izi görüntüsünü geliştirmek için gösterilen çabalara pek tatmin edici sonuçlara ulaşamamıştır.

Bunun üzerine gerçek veri setleri iyileştirmeler uygulanmış olarak eğitime sokulmuştur. Üretilen örnekler başta umut verici olsa da modellerde aşırı uyum problemi baş göstermiş ve sonuçlar her dönemde kötüye gitmiştir.

3. WGAN: Wasserstein GAN'da, model dağılımının gerçek dağılıma göre hesaplanması iyileştirilmeye çalışılır (Arjovsky vd., 2017). Mimari, hem ayırıcıda hem de üretici

doğrusal katmanlar kullanır. Bu modelin ilk uygulaması, hiçbir ayrıntı içermeyen görüntüler vermiştir.

4. LSGAN: WGAN'dan elde edilen tecrübeler ile Least Squared GAN'da en küçük kare kaybı kullanmak yerine, ayırmacıya ağırlık sınırlandırma eklenmiştir. Orjinalinde LSGAN, DCGAN mimarisini farklı kayıp fonksiyonları ile kullanır ve herhangi bir ağırlık kırpması uygulamaz. Bu mimarinin gerçek doğasını korumak için deneylerde kayıp fonksiyonu değiştirilmemiştir. Bu yaklaşım gerçekçi görünen görüntüler sağlamıştır, ancak görüntüler yine de iyileştirme yapılamayacak kadar bulanık üretilmiştir.

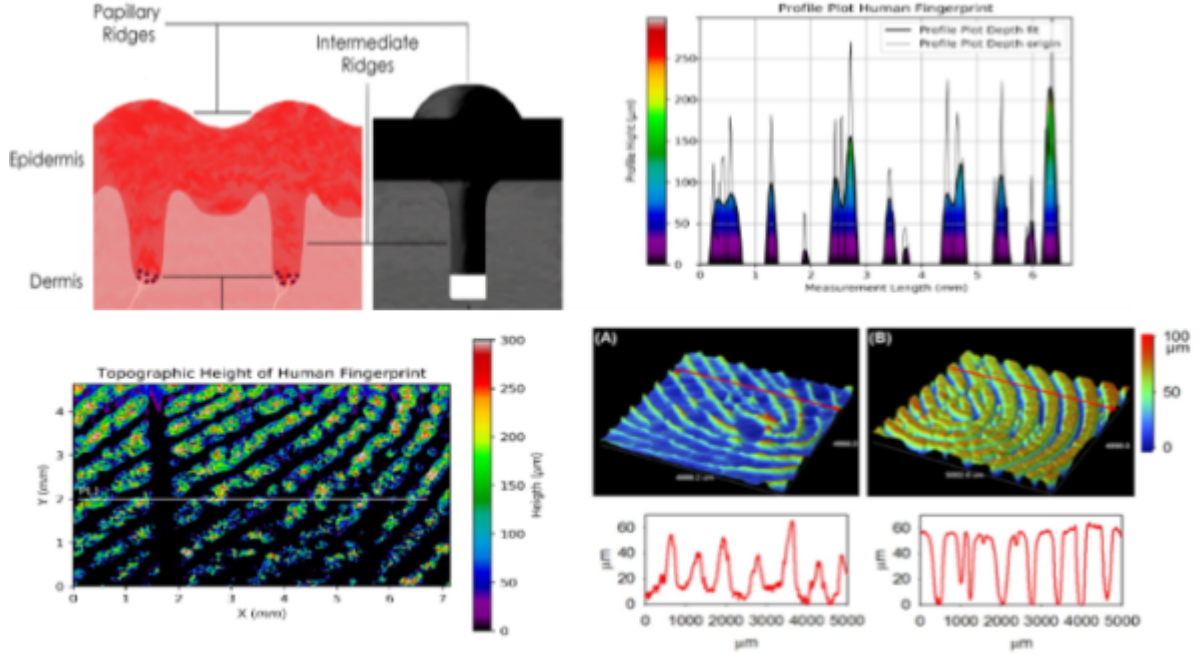
Parmak izi imgelerinin gerçeğe yakınlığını ölçmek adına Fingerprint Minutiae Viewer kullanılarak özellik noktaları tespit edilmeye çalışılmış ve NIST Parmak İzi Kalitesi (NFIQ) puanı hesaplanmıştır. Bazı özellik noktaları tespit edilebilse bile kalite puanları düşük bulunmuştur.

5. WGAN-GP: Geliştirilmiş Wasserstein GAN (WGAN-GP), WGAN'ların ağırlık sınırlandırılmasının eniyileme problemine yol açtığı savı ile geliştirilmiştir (Gulrajani vd., 2017). Ayrıca dikkatli parametrize edilmezse, WGAN'ların kaybolan ya da patlayan gradyana yol açtığı iddia edilmiştir. WGAN-GP'de farklı olarak yığın normalizasyonu uygulanmaz. Bu yaklaşım ile gerçekçi görünen imgeler üretilebilmiştir ancak detaylı bakıldığında yapay olgular farkedilebilmektedir.


Umut vadeci sonuçlar elde edilmesi üzerine, bu yöntem ile sınıf-bazlı eğitim yapılarak sınıflara özel üreticiler geliştirilmiştir. Böylece, istenilen parmak izi sınıfına ait imgeler üretme kabiliyeti edinilmiştir.

3.1.3 Simülasyon tabanlı parmak izi üretme

1. Üç boyutlu parmak ucu modellemesi: Detaylı ana parmak izleri kullanılarak aynı detayda, bu ana parmak izine sahip, üç boyutlu bir parmak objesi oluşturulması sağlanmıştır. Bir çok çalışmada belirtildiği üzere, parmak uçlarındaki papil çizgisi derinlikleri 150 - 200 mikrometre arası kabul edilmiştir. Ana parmak izleri derinlik haritaları olarak kullanılıp parmak ucuna aktarılmışlardır.




Şekil 3.20. Parmak izini oluşturan deri yapısının incelemesi ve profil grafikleri




Şekil 3.21. Örnek bir ana parmak izi ve bu izin aktarıldığı parmak ucu modeli

2. Gizli parmak izi bırakılması simülasyonu: Sentetik gizli parmak izi görüntüsü üretilebilmesi için oluşturulan 3B parmak ucu modellerinin çeşitli yüzeylere dokunup iz bırakmaları sağlanmıştır. 3B görselleştirme ve render alma için Blender programı kullanılmıştır. Bu programda bulunan “Dynamic Paint” isimli, araç yardımı ile parmağın dokunduğu ve iz bıraktığı alanlar hesaplanmıştır.
3. Gizli parmak izi yüzeye sürülerek bırakılması simülasyonu: Oluşturulan 3B parmak ucu bir yüzeye üzerinde hareket ettirilmiş, temas eden noktaların haritası çıkarılarak izin bulaşması simüle edilmeye çalışılmıştır.



Şekil 3.22. 3B parmak ucunun düz bir yüzeye ve banknotun üzerine dokundurulması ile parmak izinin kısmi bırakılması sonuçları



Şekil 3.23. 3B parmak ucunun düz bir yüzeye sürtünmesi ile parmak izinin bulanık şekilde bırakılması sonuçları

3.2 Derin Öğrenme ile Parmak İzi İşlem Adımları

Projede elde edilen sentetik verilerin gerçeğe parmak izlerine ne kadar yakın olduğu, parmak izi işleme alt adımları için eğitilen derin yapay sinir ağları modellerinin başarımına olan etkileri açısından değerlendirilmiştir. Bu amaçla aşağıda detaylandırılan sistemler geliştirilmiştir.

3.2.1 Parmak izi sınıflandırması

Model mimarilerinin etkisini gözlemlemek ve son teknoloji sonuçlar elde etmek için parmak izi sınıflandırması için farklı modeller eğitilmiştir. Modellerin eğitiminde PyTorch kullanılmıştır. PyTorch'un geliştiricilere sağladığı birçok model mimarisi vardır. Deneyler bunlardan ikisi ile gerçekleştirilir: VGG (Simonyan ve Zisserman, 2014) ve ResNet (He vd., 2016).

Model eğitimi aşamasında, özellikle eğitim veri kümesi boyutunun küçük olduğu durumlarda derin öğrenmede kullanılan popüler bir teknik olan transfer öğrenmenin etkisi de analiz edilmiştir. Transfer öğrenmenin arkasındaki ana fikir, daha az verinin bulunduğu problemler için önceden eğitilmiş modellerin ağırlıklarında depolanan bilgiyi kullanmaktır. NIST SD4'ün

veri kümesi boyutu sınıflandırma için o kadar yetersiz olmasa da, bu çalışmada diğer veri kümelerinden bilgi aktarmanın performansına olan etkisi gözlemlenmiştir.

Transfer öğrenme için iki yol denenebilir:

1. Eğitilmiş olan ağı öznelik çıkarmak için kullanmak ve yalnızca son katman ağırlıklarını eğitmek ya da elde edilen özneliği SVM gibi farklı bir sınıflandırıcıya beslemek
2. Küçük fakat hedeflenen işleme uygun bir eğitim veri kümesi ile ağı parametrelerini kısmen ya da tamamen ince ayarlamaya tabi tutmak


Bu proje kapsamında, ilk yolda yalnızca son katman ağırlıkları eğitilmiş, ikinci yolda ağı parametrelerinin tamamı ince ayarlama ile değiştirilmiştir.

Ayrıca, eğitim seti boyutunun etkisini gözlemlemek için modeller farklı sayıda eğitim görüntüsü ile eğitilmiştir. Derin öğrenme sistemleri verilere açık olduğundan, beklenti, daha fazla verinin daha iyi performans sonuçları vermesidir.

3.2.2 Özellik noktası tespit etme

Hiç bir ön işlem kullanmadan , ham parmak izi görüntüsü üzerinde özellik noktalarının tespit edilmesi hedeflenmiştir. Ayrıca, yama boyutlarının, ağı mimarisinin ve veri arttırımının sonuçlara olan etkisini gözlemlemek amacıyla farklı deneyler tasarlanmıştır.

Buna yönelik olarak, imgelerden kayan pencere yöntemi ile çıkarılan yamalar (1) merkezlerinde bulunan 10x10 büyüklüğündeki kare içerisinde ve (2) tüm yamada özellik noktası olması ve olmaması açısından ikili sınıflandırılmışlardır. Eğitim veri kümesinde özellik noktası olan ve olmayan yama sayısı eşitlenmiştir. Yama boyutunun etkisini gözlemlemek amacıyla hem 30x30 hem de 50x50 büyüklüğünde yamalar ile deneyler yapılmıştır. İkili sınıflandırmanın çok karmaşık bir problem olmamasından dolayı, VGG yerine Şekil 3.24'te gösterilen basit bir EYSA ve ResNet18 test edilmiştir. Ek olarak, veri arttırımının etkisini gözlemlemek amacı ile rastgele yatay ve dik çevirme işlemi tüm yamalara uygulanmış ve sentetik olarak büyütülen eğitim veri kümesi EYSA üzerinde denenmiştir.



Şekil 3.24. Yamaları ikili sınıflandırmak üzere tasarlanan EYSA

Toplamda 12 ağ yamaları ikili sınıflandırmak için eğitilmiştir: 8 model veri arttırımı ile (2 yama boyutu x 2 farklı yama çıkarma yöntemi x 2 model) ve 4 model veri arttırımı olmaksızın (2 yama boyutu x 2 farklı yama çıkarma yöntemi x 1 model)

Sınıflandırma işlemi sonrası, elde edilen tepki imgesi her pikselde hesaplanan özellik noktasına sahip olma olasılığı kullanılarak oluşturulur. Ancak bu imge çok gürültülüdür ve son-işlem uygulanması gerekmektedir. Eşikleme, morfolojik operasyonlar, ve maksimum-olmayan bastırma işlemleri sonucu özellik noktaları tespit edilir.

3.2.3 Papil çizgisi yönelimi kestirme

Papil çizgisi yönelimini kestirme için de yama temelli bir yaklaşım geliştirilmiştir. Ancak bu kez farklı olarak, geliştirilen derin yapay sinir ağı modeli sınıflandırma değil regresyon için eğitilmiştir. Aslında, papil çizgisi yönelim kestirimi görevi açıların gruplandırılması ile bir sınıflandırma problemi ya da doğrudan bir regresyon problemi olarak ele alınabilir. Çalışmalarımızda iki yaklaşım da denenmiş, ancak FVC yarışmasında hata ölçümlerininin ortalama kare hatası ile yapılması ve literatürde bulunan günümüze yakın çalışmaların daha çok regresyon üzerine odaklanması sebebi ile EYSA kullanarak yönelimlerin 0-180 sürekli aralığında kestiriminin yapılması hedeflenmiştir. EYSA tabanlı bir ağ tasarlanarak Python dili ve PyTorch kütüphanesi ile kodlanmıştır.

Model, her birinde evrişim, yığın normalizasyonu, maksimum havuzlama ve seyreltme (dropout) katmanları olan ve aktivasyon fonksiyonu olarak ReLu kullanılan üç evrişim bloğu içermektedir. Bu blokların ardında ise tam bağlantılı ve yine seyreltme uygulanan 5 doğrusal katman bulunmaktadır. Son katman çıktısının boyutu 1 olup, papil çizgisi yönelimini kestirimini yapmaktadır.

Eğitim için kayıp fonksiyonu olarak ortalama kare hatası kullanılmış, her deney için 500 dönem sürmüştür. Öğrenme hızı her dönemde dairesel öğrenme hızı prensibine göre güncellenmiştir. 27x27 büyüklüğünde yamalar ile yapılan kestirim işlemi için 3 farklı eğitim kurgusu gerçekleştirilmiştir.

1. Yalnızca gerçek veriler ile eğitim
2. Yalnızca sentetik veriler ile eğitim
3. Gerçek ve sentetik verileri birleştirerek eğitim

4. BULGULAR

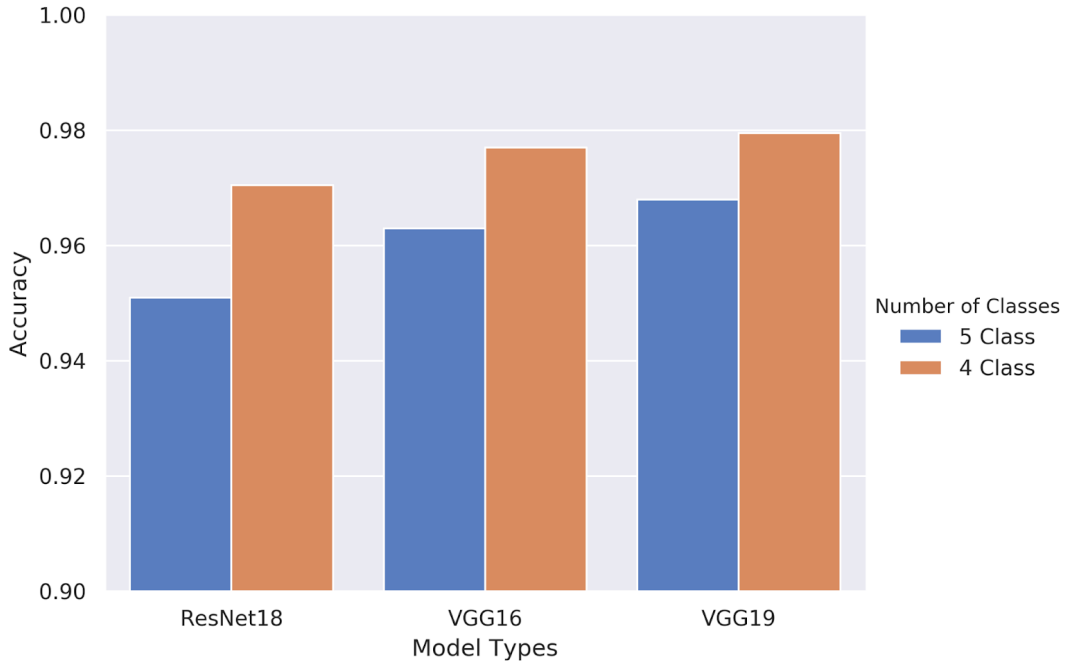
Proje kapsamında önerilen ve uygulanan yaklaşımlar ile yapılan deneyler ve bu deneylerin sonuçları aşağıdaki bölümlerde sunulmaktadır.

4.1 Parmak izi sınıflandırması

Parmak izi sınıflandırması performansları, eğitilen model tipine, transfer öğrenme yaklaşımına ve eğitim kümesi boyutuna göre incelenmiştir. Tüm testlerde NIST SD4 veri kümesi kullanılmıştır. Bu veri kümesi, 2000 parmaktan ikişer parmak izi imgesi toplanarak oluşturulmuştur ve 5 farklı parmak izi sınıfından her biri için 400 parmak izi imgesi bulunmaktadır. İmgeler 512x512 büyüklüğündedir. Deneyler için ilk 1000 parmak eğitim, ikinci 1000 parmak testler için kullanılmıştır. Performans metriği olarak sınıflandırma doğruluğu hesaplanmıştır. Tak ve yay sınıfları birbirine çok benzer olduklarından literatürde bu sınıfların birleştirilmesi ve parmak izlerinin 4 sınıfa sınıflandırılması sıklıkla karşımıza çıkmaktadır. Bu sebeple, 4-sınıf sınıflandırma doğrulukları da raporlanmıştır.

4.1.2 Modellere göre

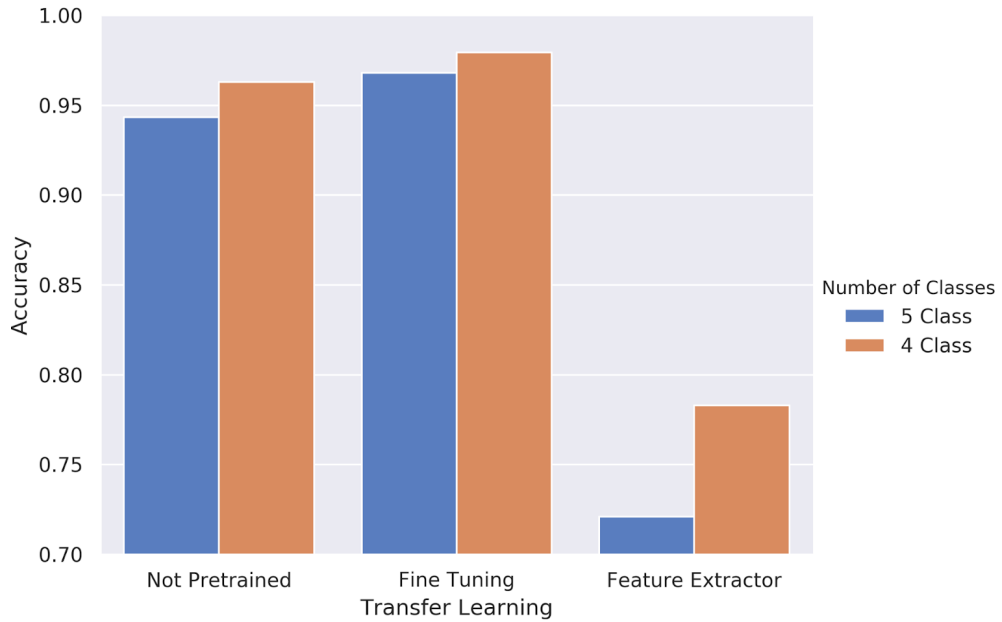
VGG16, VGG19 ve ResNet18 modelleri karşılaştırılmıştır. Karşılaştırma, her bir model için yukarıda bahsedilen tüm deney konfigürasyonlarında sağladıkları en yüksek başarımlar oranları arasında yapılmıştır. Sonuçlar Şekil 4.1'de görülebilir.



Şekil 4.1. 3 farklı model ile elde edilen en yüksek doğruluk değerleri

4.1.2 Transfer öğrenme yaklaşımına göre

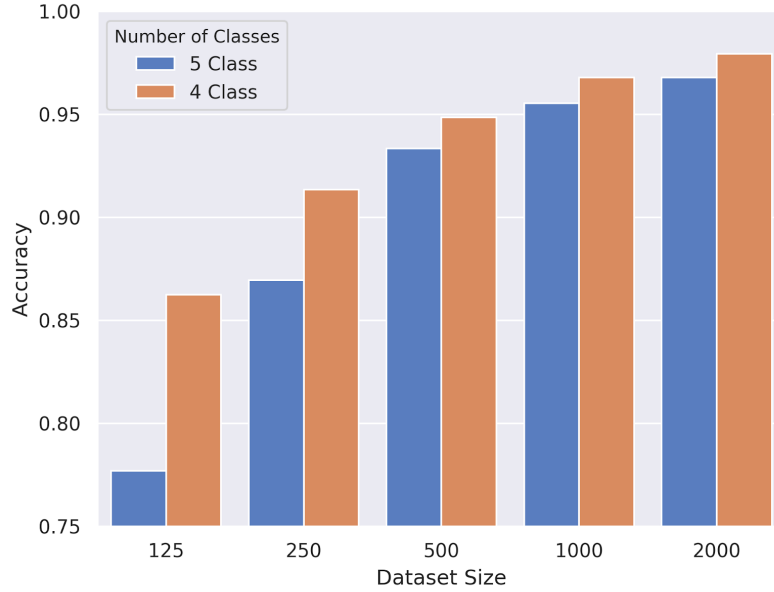
Tüm modeller transfer öğrenme olmaksızın ve önceden bahsedilen iki transfer öğrenme yaklaşımı kullanılarak toplam 3 kez eğitilmişlerdir. Karşılaştırma yine her bir model için yukarıda bahsedilen tüm deney konfigürasyonlarında sağladıkları en yüksek başarımlar arasında yapılmıştır. Sonuçlar Şekil 4.2'de görülebilir.



Şekil 4.2. 3 farklı transfer öğrenme yaklaşımı için elde edilen en yüksek doğruluk değerleri

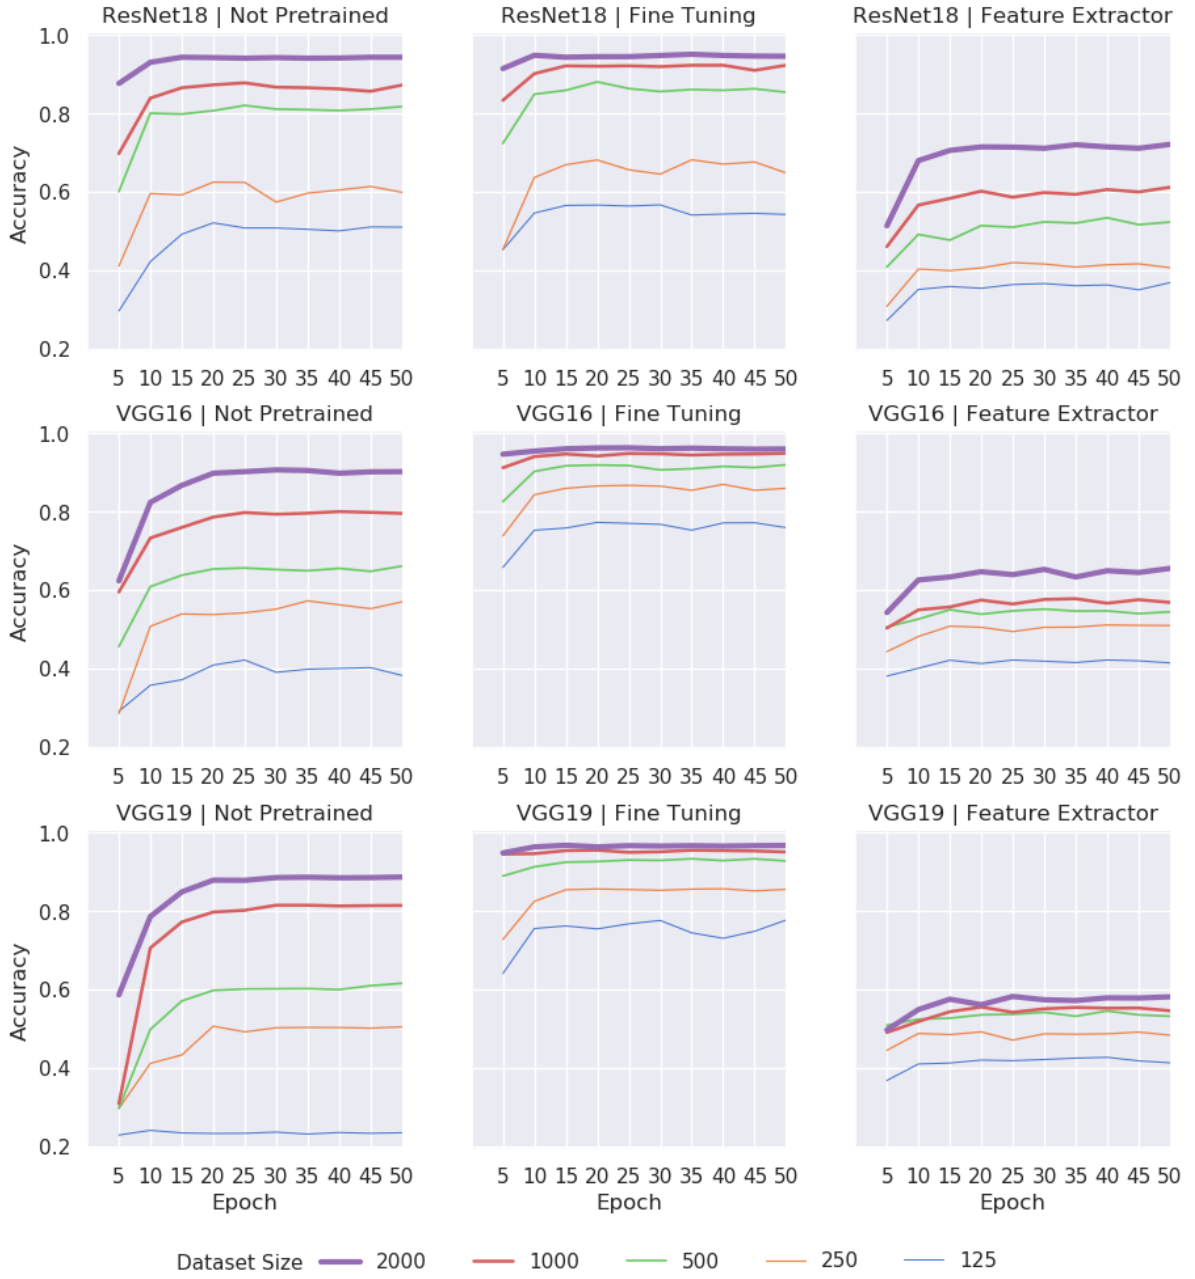
4.1.3 Eğitim kümesi büyüklüğüne göre

Bu deney için 5 farklı eğitim kümesi büyüklüğü denenmiştir: 125, 250, 500, 1000 ve 2000. Her eğitim kümesi için tekdüze parmak izi sınıfı dağılımı korunmuştur. Test kümesi is değiştirilmemiştir. Karşılaştırma yine her bir model için yukarıda bahsedilen tüm deney konfigürasyonlarında sağladıkları en yüksek başarımlar arasında yapılmıştır. Karşılaştırmalı sonuçlar Şekil 4.3'te görülebilir.



Şekil 4.3. 5 farklı eğitim kümesi büyüklüğü için elde edilen en yüksek doğruluk değerleri

Ayrıca Şekil 4.4'te farklı modeller, farklı transfer öğrenme yaklaşımları ve farklı büyüklükte eğitim kümeleri kullanarak her 5 eğitim döneminde elde edilen 5-sınıf sınıflandırma test sonuçları gösterilmektedir. Tablo 4.1'de ise son yıllarda yayınlanmış olan çalışmalarda elde edilen sonuçlar karşılaştırma yapılmaktadır.



Şekil 4.4. 5-sınıf sınıflandırma için her eğitim döneminde elde edilen test doğruluk değerleri

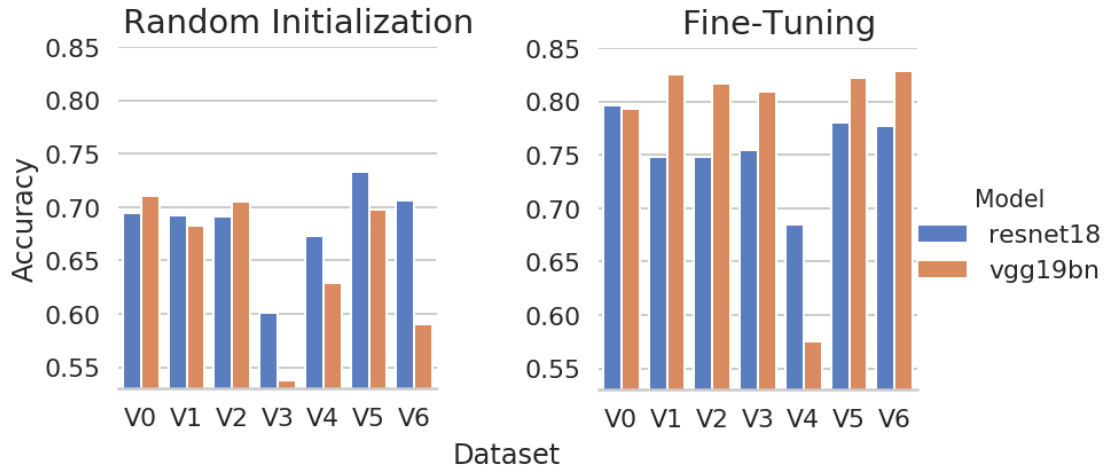
Tablo 4.1. Sınıflandırma performansları karşılaştırması

Method	5 class	4 class
Tang vd. (2019)	-	95.1%
Listyalina ve Mustiadi (2019)	94.7%	96.2%
Michelsanti vd. (2017)	-	95.05%
Proposed method	96.8%	97.95%

4.1.4 Sentetik veriler ile eğitime

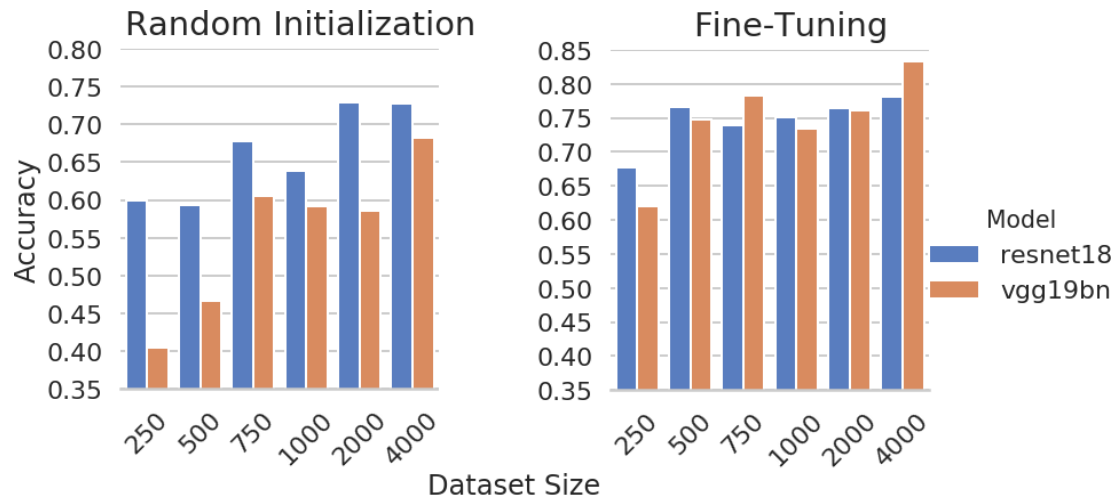
Yukarıdaki sonuçlar artan eğitim kümesi büyüklüğü ile performansların iyileştiğini göstermiştir. Bu sebeple, eğitim kümesini sentetik veriler ile büyütmenin doğuracağı sonuçlar, sentetik verilerin gerçek verilere olan benzerlikleri konusunda bize fikir verecektir. Bu doğrultuda, ResNet ve VGG-19 kullanılarak, sentetik parmak izi veri kümeleri ile 5 farklı deney kurgulanmıştır:

1. Farklı bozulmalara sahip sentetik veri kümeleri ile eğitime: Transfer öğrenme kullanılarak ve kullanmadan, 2 farklı model 7 farklı sentetik veri kümesi ile eğitilmiştir. Sonuçlar Şekil 4.5'te verilmiştir.



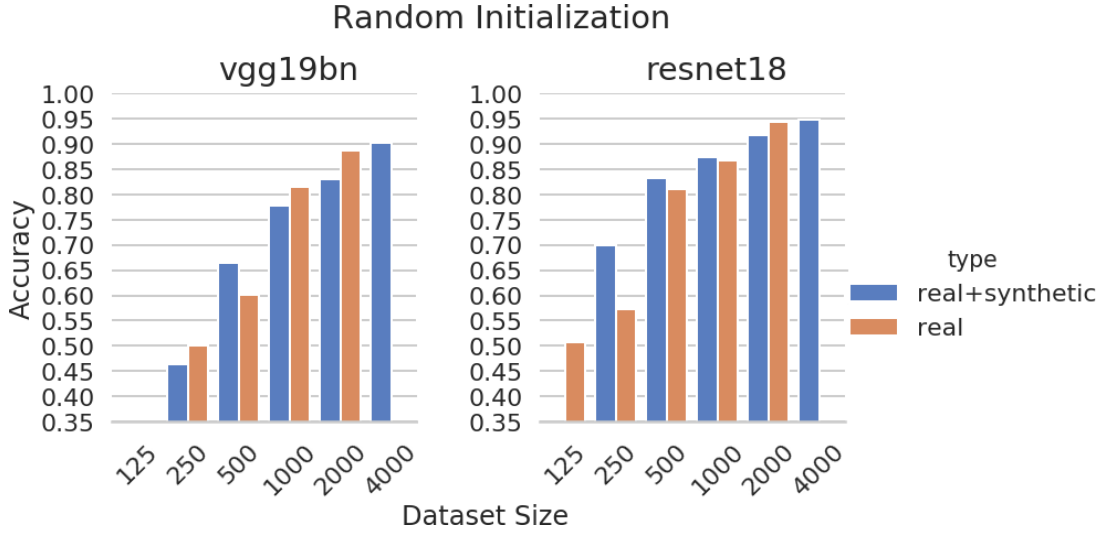
Şekil 4.5. 5-sınıf sınıflandırma için farklı bozulmalara sahip sentetik eğitim kümeleri ile elde edilen doğruluk değerleri

2. Farklı büyüklükteki sentetik veri kümeleri ile eğitime: Transfer öğrenme kullanılarak ve kullanmadan, 2 farklı model V0 sentetik veri kümesinin farklı büyüklükteki alt kümeleri kullanılarak eğitilmiştir. Sonuçlar Şekil 4.6'da verilmiştir.

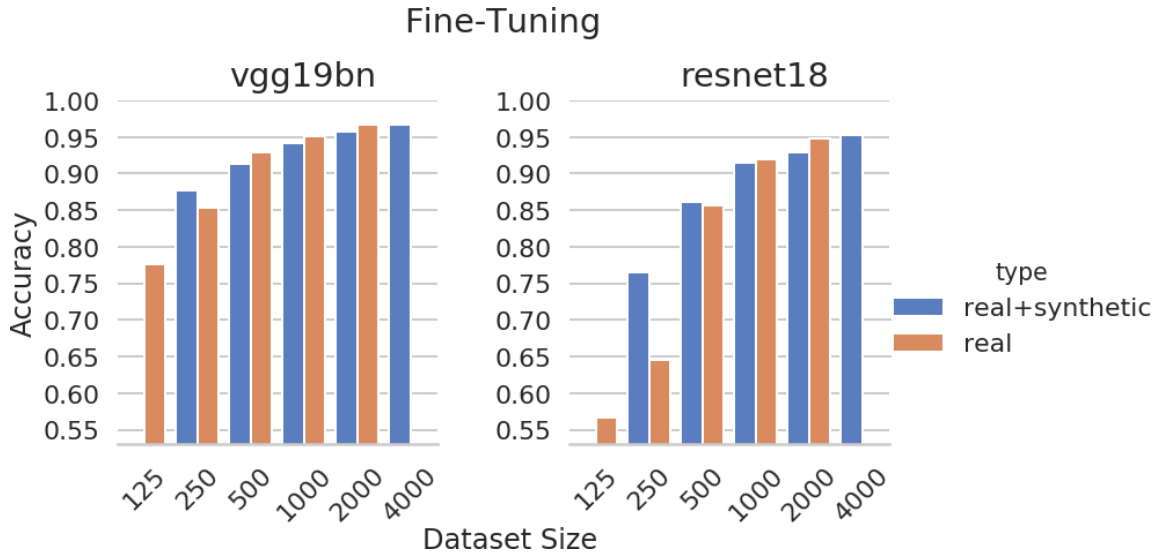


Şekil 4.6. 5-sınıf sınıflandırma için farklı büyüklükteki eğitim kümeleri ile elde edilen doğruluk değerleri

3. Farklı büyüklükteki gerçek ve sentetik-gerçek karışık veri kümeleri ile eğitime: Transfer öğrenme kullanılarak ve kullanmadan, 2 farklı model farklı büyüklükteki gerçek veri kümeleri, tek başlarına ve V0 sentetik veri kümesinin farklı büyüklükteki alt kümeleri ile birlikte, kullanılarak eğitilmiştir. Sonuçlar Şekil 4.7 ve 4.8'de verilmiştir.

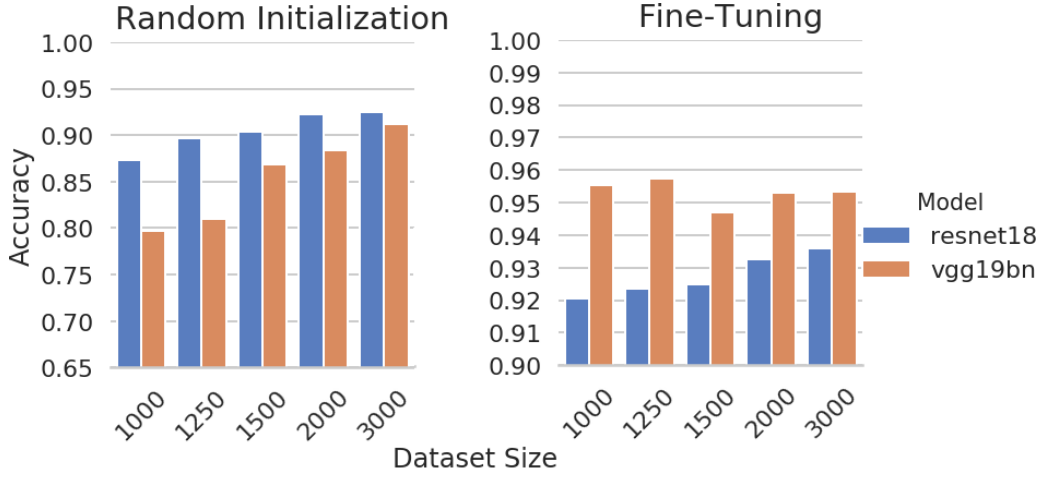


Şekil 4.7. 5-sınıf sınıflandırma için gerçek ve gerçek+sentetik eğitim kümeleri ile ve transfer öğrenme kullanmadan elde edilen doğruluk değerleri



Şekil 4.8. 5-sınıf sınıflandırma için gerçek ve gerçek+sentetik eğitim kümeleri ile ve transfer öğrenme kullanarak elde edilen doğruluk değerleri

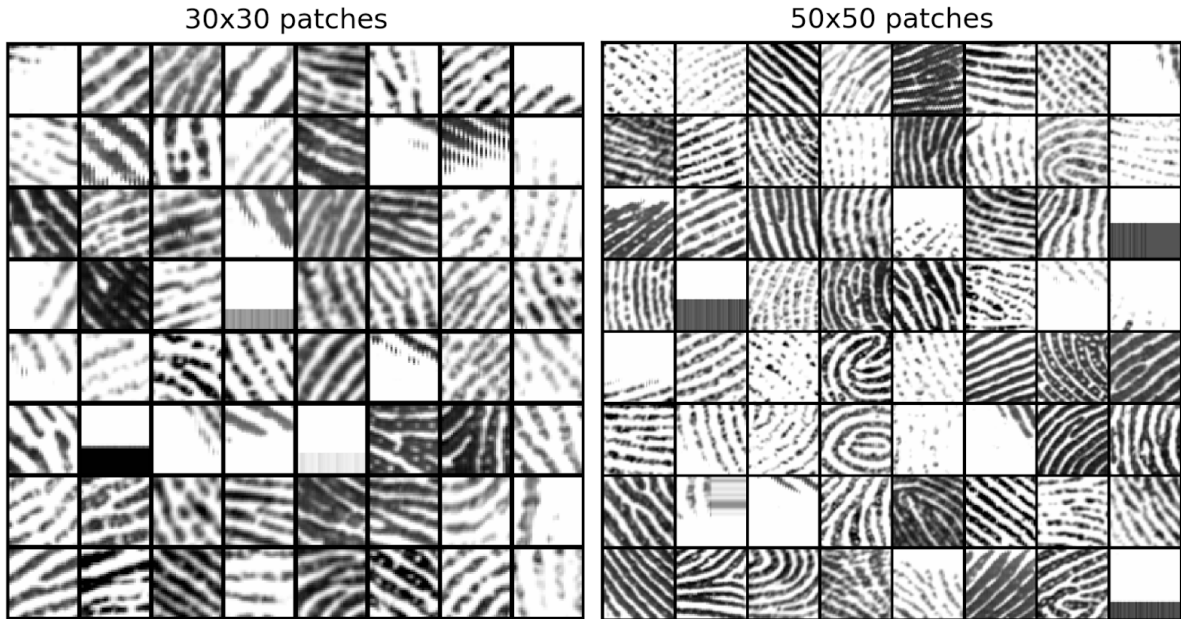
4. Sabit büyüklükteki gerçek ve farklı büyüklükte sentetik veri kümeleri ile eğitime: Transfer öğrenme kullanılarak ve kullanmadan, 2 farklı model, gerçek eğitim kümesine (1000 imge) farklı boyutlarda V0 alt kümeleri eklenerek oluşturulan karışık eğitim kümeleri ile eğitilmiştir. Sonuçlar Şekil 4.9'da verilmiştir.



Şekil 4.9. 5-sınıf sınıflandırma için gerçek 1000 gerçek veriye farklı sayılarda sentetik veri eklenerek oluşturulan eğitim kümeleri ile ve transfer öğrenme kullanarak ve kullanmadan elde edilen doğruluk değerleri

4.2 Özellik noktası tespit etme


Yöntem bölümünde bahsedilen 2 model, FVC 2002 DB1-A veri kümesi kullanılarak test edilmiştir. 100 farklı parmağın sekizer parmak izi imgesinden oluşan bu veri kümesinde 388x374 boyutlarında 800 örnek bulunmaktadır. Deneyler için 100 parmak, %80 eğitim ve %20 test için birbiriyle kesişmeyen alt kümelere bölünmüştür. Örnek yamalar Şekil 4.10'da görülebilir.



Şekil 4.10. 30x30 ve 50x50 yama örnekleri


Eğitim ve test kümelerinden yamalar elde edilmiş ve özellik noktası içerip içermeme durumuna göre etiketlenmiştir. Deneyler için daha önce açıklandığı gibi 12 model eğitilmiştir.

Test edilmesi için iki farklı yama çıkarma ve etiketleme yaklaşımı önerilmiştir. Özellik noktası olmayan yamaların tamamında hiç özellik noktası olmaması gereken yaklaşımda, özellikle 50x50 büyüklüğünde yamaların genellikle parmak izinin kenar bölgelerinden toplandığı dikkati çekmiştir. Çünkü, özellik noktalarının sık görüldüğü orta bölümde 30x30 büyüklüğünde özellik noktası olmayan bir alan bulmak güçleşmektedir. Özellik noktasının merkezdeki 10x10 büyüklüğündeki kare içinde olmamasını yeterli bulan yaklaşım ise yama çıkarma işlemini daha tekdüze hale getirmektedir (Şekil 4.11).



Şekil 4.11. 50x50 yama örnekleri. Üstte: Yamanın tamamında bulunmaması zorunlu. Altta: Yamanın merkezindeki 10x10 büyüklüğündeki karede bulunmaması zorunlu.

Kayan pencere ile parmak izi imgesinden çıkarılan yamalar sınıflandırıldıktan sonra özellik noktası olasılık haritası oluşturulmakta ve son-işleme adımları ile temizlenmektedir. Bu adımlar arasında morfolojik operasyonların önemli olduğu gözlemlenmiştir. (Şekil 4.12)



Şekil 4.12. Morfolojik operasyonların yapılmaması yanlış tespitleri arttırmaktadır.

Farklı yama büyüklükleri ve yama etiketleme yaklaşımları ile eğitilen modellerin elde ettiği performans değerleri Tablo 4.2'de verilmiştir. Elde edilen F1 skoru Zhou vd. (2020)'de rapor edilen skora (%87.9) çok yakındır. Elde ettiğimiz geriçağırım daha yüksek (%87.9) fakat kesinlik daha düşüktür (%87.9).

Tablo 4.2. Farklı deney kurguları ile elde edilen sonuçlar (1) özellik noktası için yamanın tamamına bakıldığını (2) ise merkezindeki 10x10'luk kareye bakıldığını göstermektedir.


	30x30 (1)		30x30 (2)		50x50 (1)		50x50 (2)	
	C	RN18	C	RN18	C	RN18	C	RN18
DP	5800	5912	5674	5718	6222	6131	5847	3461
YP	1220	2552	1565	2684	3299	5307	3288	1850
YN	488	376	620	576	488	579	398	2784
Kesinlik (%)	82.62	69.85	78.38	68.06	65.35	53.60	64.01	65.17
Geriçağırım (%)	92.24	94.02	90.15	90.85	92.73	91.37	93.63	55.42
F1 Skoru (%)	87.17	80.15	83.85	77.82	76.67	67.57	76.03	59.90

4.3 Papil çizgisi yönelimi kestirme

Tüm eğitimler 500 dönem sürmüştür ve şu sonuçlar elde edilmiştir:


- a. Yalnızca gerçek veriler ile eğitime (85282 yama imgesi) sonucu elde edilen ortalama kare hatası ve 500 dönem için elde edilen eğitim ve test kayıp değerleri aşağıda verilmiştir.

	Minimum kayıp miktarı
Eğitim	0.0387
Test	0.0420




- b. Yalnızca sentetik veriler ile eğitime (251119 yama imgesi) sonucu elde edilen ortalama kare hatası ve 500 dönem için elde edilen eğitim ve test kayıp değerleri aşağıda verilmiştir.

	Minimum kayıp miktarı
Eğitim	0.0217
Test	0.0420



- c. Gerçek ve sentetik verileri birleştirerek eğitime (336401 yama imgesi) sonucu elde edilen ortalama kare hatası ve 500 dönem için elde edilen eğitim ve test kayıp değerleri aşağıda verilmiştir.

	Minimum kayıp miktarı
Eğitim	0.0224
Test	0.0474



5. TARTIŞMA, SONUÇ ve ÖNERİLER

5.1 Parmak izi sınıflandırması

Parmak izi sınıflandırması sonuçları varolan çalışmalara üstünlük elde edilmiştir. Aynı zamanda sınıflandırma performansının farklı etmenlere göre nasıl değiştiğine dair içgörü sağlamıştır.

Sonuçlar, performansların Tang vd. (2019), Listyalina ve Mustiadi (2019) ve Michelsanti vd. (2017) gibi literatürde önerilen birçok sistemden daha iyi performans gösterdiğini ve minimum çabayla derin öğrenme sistemlerinin eğitiminin parmak izi sınıflandırmasında çok iyi sonuçlar elde edebileceğini göstermektedir.

5.1.2 Modellere göre

Bu kısımda, en iyi performans gösteren model, şaşırtıcı olmayan bir şekilde, karmaşıklığı nedeniyle VGG19'dur. VGG19'u VGG16 takip etmektedir ve en kötü performans da ResNet18'e aittir. Ancak ResNet18'in doğruluğu yine de VGG modellerine oldukça yakındır.

Sonuçlar, her iki mimarinin de gerçekten güçlü olduğunu göstermektedir. Beklendiği gibi ResNet18'in eğitimi VGG ağlarına kıyasla çok daha kısa sürmüştür ve yine de VGG ağlarına benzer sonuçlar elde edilmiştir.

Bu sonuçlar, parmak izi sınıflandırması için derin öğrenmenin kullanılmasının pratik olduğunu ve oldukça doğru sonuçlar verdiğini göstermektedir. Herhangi bir özellik mühendisliğine veya (veri setinin ortalama ve standart sapmasını kullanarak normalize edilmesi hariç) karmaşık bir ön işleme ihtiyacı duymadan, derin öğrenme sistemleri hem

dört sınıflı hem de beş sınıflı sınıflandırmada literatürle karşılaştırılabilir yüksek sonuçlar elde edebilmektedir.

5.1.2 Transfer öğrenme yaklaşımına göre

Bu kurulumda, ince ayarlı modeller, şaşırtıcı olmayan bir şekilde başı çekiyor. Parmak izi veri kümesi ImageNet veri kümesine çok benzemese de, ağların önceden eğitilmiş ağların ağırlıklarıyla ilklendirilmesi, ağlara daha fazla veri getirdiği için performansa katkıda bulunmaktadır. Ancak yine veri seti ImageNet verisinden farklı olduğu için öznelik çıkarıcı kurulumda ağlar iyi sonuçlar alamamaktadır. Bir önceki ağda öğrenilen bilgiler, parmak izi verilerini açıklamak için yeterli görünmemektedir.

Sonuç olarak, ağlar yeterli miktarda probleme özgü veri ile eğitilirse, transfer öğrenmenin parmak izi sınıflandırması için çok iyi ve hatta son teknoloji sonuçlar elde edebileceği gözlemlenmiştir.

Ayrıca ağlar eğitilirken edinilen bir diğer gözlem ise ince ayarlı modellerin yakınsamasının daha kolay olduğudur. Önceden eğitilmemiş ağlar bazen yakınsama yapamamakta ve özellikle VGG ağları için eğitim sürecinin yeniden başlatılması gerekmektedir. Ancak, zaten iyi bir şekilde başlatıldıkları için ince ayarlı ağlar için durum böyle değildir.

5.1.3 Eğitim kümesi büyüklüğüne göre

Sonuçlar, beklendiği üzere, veri kümesi boyutlarındaki artışın model performanslarını iyileştirdiğini göstermektedir. Bu nedenle derin öğrenme modellerinin daha fazla eğitim örneği ile daha iyi performans gösterebileceği ifade edilebilir. Ancak doğruluklar bir noktadan sonra doyuma ulaşmaya başlar. 1000 veri kümesi boyutuna ve 2000 veri kümesi boyutuna sahip modeller arasındaki doğruluk artışı, 125 veri kümesi boyutuna ve 250 veri kümesi boyutuna sahip modeller arasındaki artıştan daha düşüktür. Bu gözlemlerle daha fazla eğitim örneği ile model performansları gelişse de, iyileştirmenin duracağı bir maksimum noktanın olması kuvvetle muhtemeldir denilebilir. Ancak 2000 veri ile o maksimum noktanın olduğu veri miktarını söylemek mümkün değildir. Bununla birlikte, hem dört sınıflı hem de beş sınıflı sınıflandırmada, artan veri seti boyutları ile oluşan doğruluklardaki iyileşme dikkat çekicidir.

5.1.4 Sentetik veriler ile eğitime

1. Farklı bozulmalara sahip sentetik veri kümeleri ile eğitime:

V0 veri kümesiyle ve ön eğitim olmadan, ResNet18 ve VGG19 ağları için gerçek veriler üzerindeki sınıflandırma doğrulukları sırasıyla %69.45 ve %71.00'dir. **V1**, **V2**'nin doğruluğu, uygulanan hariç tutmalardan önemli ölçüde etkilenmemektedir. Bu da bahsi geçen varyasyonların gerçek bozulmaları pek temsil etmediğine dair bir ipucu olabilir. Ancak, **V3** ve **V4** doğrulukları her iki model için de keskin bir şekilde düşmektedir. Bu, poz varyasyonu ve papil çizgisi pertürbasyonlarının faydalı varyasyonlar getirdiğini ve bunları dışlamanın sentetik parmak izi veri kümelerinin temsil gücünde bir kayba neden olduğunu göstermektedir. İlginç bir şekilde, ResNet için ön eğitim olmadan **V5** daha iyi bir doğruluk elde etmektedir. Bu gelişmenin nedeni ağ mimarisi ile ilgili olabilir. ResNet artıklardan öğrenir ve daha derin katmanlarda, arka plan bilgisi parmak izi bilgisini yayabilir ve geçersiz kılabilir. Başka bir deyişle, model parmak izi yerine arka plandan bilgi çıkarmaya çalışabilir. Bu nedenle arka planı kaldırmak ResNet modelinin parmak izinin kendisine odaklanmasını ve daha iyi öğrenmesini sağlayabilir.

Bir başka ilgi çekici sonuç, aktarım öğrenmesi olmadan VGG modelinde **V6** ile elde edilmektedir. Bu kurulum, %60'ın altında bir doğruluk sağlamaktadır. İşlem sonrası adımın devre dışı bırakılması, sentetik görüntülerin NIST veri kümesindeki gerçek parmak izlerinden farklı piksel yoğunluğu aralıklarına sahip olmasına neden olur ve VGG modeli, gerçek parmak izine iyi genellenemeyen sentetik yoğunluk dağılımını öğrenmiş olabilir.

Özetlemek gerekirse, ağları eğitmek için transfer öğreniminin kullanılmadığı durumlarda poz varyasyonları ve papil çizgisi pertürbasyonlarının sentetik veri kümeleri için önemli hale gelmektedir. Ayrıca model mimarilerine göre doğruluklar varyasyonlardan olumlu veya olumsuz etkilenir. Örneğin, VGG modeli arka plan eksikliğini tolere edebilir, ancak performansı piksel yoğunluğu dağılımlarındaki farklılıktan olumsuz etkilenir.

Ön eğitimle, **V0** ile eğitilen ResNet ve VGG modelleri sırasıyla %79.65 ve %79.35 doğruluk elde etmektedir. **V0** ile eğitilen ResNet, diğer ResNet modelleri arasında en iyi performansı elde etmiş bulunmaktadır. ResNet modelleri, bağlamı parmak izlerinin bağlamından çok farklı olan ImageNet veri kümesi üzerinde önceden eğitilmiştir. Bu nedenle, en fazla varyansa sahip veri kümesinde en iyi performansı elde etmek şaşırtıcı değildir. **V4** ile elde edilen sonuçlardan, her iki önceden eğitilmiş ağ için en önemli bozulmaların papil çizgisi pertürbasyonları olduğu açıkça görülmektedir.

Bunun nedeni, ImageNet veri kümesinin bu tür gürültüleri içermemesi olabilir, bu nedenle parmak izi oluşturma sürecinden papil çizgisi pertürbasyonlarının kaldırılması önemli bir bilgi kaybına neden olabilir.

Hem transfer öğrenmeli hem de transfersiz öğrenmede en önemli varyasyonların papil çizgisi pertürbasyonları olduğu, çünkü yokluğunda performanslarda keskin düşüslere neden olduğu görülmüştür. Ek olarak, ön eğitim kullanılmadığında poz varyasyonlarının daha önemli olduğu gözlemlenmiştir. Önceden eğitilmiş modeller, ImageNet veri kümesinden döndürme - ölçekleme - öteleme varyasyonlarını öğrenmiştir, dolayısıyla **V3** ile performans kaybı çok kritik değildir. **V1**, **V2** veri kümeleri, yapılandırılmalarda önemli bir performans kaybına sahip değildir. Bu varyasyonların gerçek bozulmaları pek temsil etmeyeceğinden şüphelenilmektedir ve gelecekteki çalışmalarda ayrıca incelenmeli ve geliştirilmelidir.

2. Farklı büyüklükteki sentetik veri kümeleri ile eğitime:

1000, 2000 boyutlarındaki veri kümesiyle, hem transfer öğrenmeli hem de transfersiz öğrenme için, doğruluklar 750 boyutuna kıyasla biraz azalmaktadır. Bu azalma, sentetik veri setinde 750. ile 2000. arasındaki örneklerin kalitesi ile açıklanabilir. Bu görüntüler, sınıflandırıcıların genelleme yeteneğine katkıda bulunan yeterince iyi varyasyonları içermeyebilir. Ancak genel olarak eğitimde daha fazla sentetik veri kullanıldığında performansların daha iyi olduğu sonucuna varabilmekteyiz. 4000 sentetik parmak izi görüntüsüyle ince ayarlı önceden eğitilmiş VGG ağı, gerçek parmak izi verisi olmayan bir eğitim seti için dikkate değer olan %83.30 doğruluk elde etmektedir.

3. Farklı büyüklükteki gerçek ve sentetik-gerçek karışık veri kümeleri ile eğitime:

Her durumda, karma veri kümelerinin performansları, eşit büyüklükteki tamamen gerçek veri kümelerinkine çok yakındır. Eğitim veri kümesinin yarısı sentetik olsa bile, modeller yalnızca gerçek görüntüler kullanılarak eğitim yapıldığındakine benzer sonuçlar elde edebilmektedir. Aktarım öğrenimi olmadan elde edilen sonuçlar, bazı durumlarda karma verilerin gerçek verilerden daha iyi performans gösterebileceğini bile göstermektedir. Örneğin, ResNet modellerinde karma veriler, 250, 500, 1000 boyutlarındaki veri kümesi için gerçek verilerden daha iyi performans göstermiştir. Bu, sentetik verilerin, özellikle gerçek veri kümesi boyutları çok büyük olmadığında yararlı varyasyon katkıları sağlayabileceğini göstermektedir. Aynı sonuç, veri seti boyutu 500 olan VGG modeli için de gözlenmektedir.

Ek olarak, karışık veri seti performansları, aynı sayıda gerçek görüntüye sahip gerçek veri seti performansları ile karşılaştırıldığında (N gerçek + N sentetik küme ile N gerçek veri karşılaştırması gibi), sonuçlar sentetik veri eklemenin hemen hemen her durumda performansı arttırdığını göstermektedir. Bu da bize sabit miktarda gerçek veri olduğunda, sentetik veri eklemenin performansları iyileştirdiğini göstermektedir. Ancak beklendiği üzere, gerçek veri kümesi boyutu arttıkça bu gelişme de azalmaktadır.

Önceden eğitilmiş modeller söz konusu olduğunda, sınıflandırıcılar ImageNet veri kümesinden bazı bilgileri aktardıkları için önceden eğitilmemiş sürümlerden daha doğru sonuçlar elde edebilirler. Ancak, karma veri kümesi doğrulukları hala gerçek değerlere çok yakındır ve aynı sayıda sentetik verinin gerçek bir veri kümesine eklenmesinin performansları da iyileştirdiği açıkça görülmektedir. 4000 boyutundaki karışık veri kümesiyle ince ayar yapılmış ve önceden eğitilmiş VGG modeli, %95.30 doğrulukla en iyi performansı elde etmektedir. Bu oranla NIST SD4 eğitimindeki maksimum görüntü sayısı olan 2000 gerçek görüntüyle ince ayar yapılmış aynı modelin %94.80 sonucunu geride bırakmaktadır. Bu değerler de bize sentetik verileri dahil ederek eğitim örneklerinin sayısını artırarak parmak izi sınıflandırma performanslarını iyileştirmenin mümkün olduğunu göstermektedir.

4. Sabit büyüklükteki gerçek ve farklı büyüklükte sentetik veri kümeleri ile eğitime:


Şekil 4.9'da görüldüğü üzere, artan sentetik veri boyutu ile elde edilen doğruluklar arasında, özellikle ön eğitim kullanılmadığında, tüm durumlar için güçlü bir korelasyon gözlemlenmektedir. Genel olarak sonuçlar, artan miktarda sentetik verinin sınıflandırıcıların performansını iyileştirebileceğini kanıtlamaktadır. Bir istisna, önceden eğitilmiş VGG ağının artan sentetik veri sayısından her zaman olumlu etkilenmemesidir. Bunu da parmak izlerinin sınıflandırılmasının çok karmaşık bir problem olmadığı ve önceden eğitilmiş VGG'nin ImageNet veri setinden temel özellikleri öğrenmiş olmasından dolayı sınıflandırıcıyı eğitmek için 1000 gerçek parmak izi görüntüsünün zaten yeterli olduğuna, dolayısıyla sentetik veri setinin herhangi bir iyileştirme ekmediği yönünde açıklayabiliriz. Diğer bir olasılık, sentetik veri seti varyasyonlarının, önceden eğitilmiş ağların doğruluğunu geliştirmek için yeterince temsili olmamasıdır. Ne yazık ki, böyle bir analiz yapmak için daha çok gerçek veriye ihtiyaç bulunmaktadır.

5.2 Özellik noktası tespit etme

Sonuçlar, kendi tasarladığımız basit modelin ResNet18 mimarisine kıyasla tüm deney konfigürasyonlarında daha iyi performans elde ettiğini göstermektedir. Bu, çok karmaşık olmayan problemler ve küçük girdi boyutları söz konusu olduğunda çok derin mimarilere gerek olmadığı fikrini desteklemektedir. 3 evrişimli ve 3 tam bağlantılı katmana basit mimari, verilerin temel yapısını daha iyi yakalamaktadır. Ek olarak, hiç özellik noktası içermeyecek şekilde önerilen yama çıkarma yaklaşımının 30x30 yama boyutu ile hem kendi geliştirdiğimiz hem de ResNet18 modeli ile diğer tüm konfigürasyonlardan daha iyi performans gösterdiği gözlemlenmektedir. Hatta, 82.62 hassasiyet, %92.24 geri çağırma ve %87.18 F1 puanı ile en iyi sonucu basit modelimiz elde etmiş ve Zhou vd. (2020)'de verilen sonuçlara çok yakın sonuçlar elde edilmiştir. Yama boyutu küçük olduğu için, özellik noktası olan ve olmayan yamalar arasındaki katı ayırım ağı olumlu etkilemiş olabilir.

30x30 ve 50x50 boyutunda yamalar karşılaştırıldığında, her iki model mimarisinde de 50x50 yama boyutunun 30x30 yama boyutuna göre oldukça kötü performans gösterdiği görülmektedir. Bunun ana nedeni, özellikle esnek yaklaşımda, yetersiz bilgilendirici yamaların çıkarılması olabilir. Ancak katı yaklaşımın uygulanması ile iki yama boyutu için de bu sorunun çözülmesine yardımcı olmadığı görülmektedir. Bunun nedeni, özellik noktası yok şeklinde etiketlenen yamalarda özellik noktalarını görülmesi olabilir. Bununla birlikte, özellik noktası olan ve olmayan yamaları katı olarak ayıran yama çıkarma yaklaşımı ve 30x30 yama boyutu ile basit ağ modeli, herhangi bir ön işleme ve öznel çıkarma adımı içermeyen yama tabanlı bir yaklaşım için yeterince iyi performans göstermektedir.

Diğer bir gözlem ise, görüntü kalitesi düşük olduğunda yamaların yanıltıcı bilgiler içerebileceğidir. Bunun temel nedeni, düşük kaliteli görüntülerin normalde özellik noktası olmayan birçok bağlantısız papil çizgisi içermesidir. Bu kopuk çizgiler, imgeden küçük yamalar alındığında, papil uçlarına benzetilebilir. Bu, hem eğitim hem de test sırasında sorun yaratır. Ağ, eğitim sırasında, özellik noktası yamalarına çok benzeyen fakat aksi etiketle işaretlenen yamaları görür. Test zamanında ise ağ, kopuk papil çizgilerinde birçok sahte özellik noktası tespit eder. Birçok yamada, ağ aslında mantıklı tahminlerde bulunur çünkü insanlar bile bu yamaları doğru bir şekilde sınıflandırmayabilir. Bazı düşük kaliteli görüntülerin yama örnekleri, Şekil 5.1'de gösterilmektedir.



Şekil 5.1. Düşük kalitede 50x50 yamalar

Düşük kaliteli görüntüler sorunlara neden olabileceğinden, özel ağ kullanılarak modellerin performansları görüntü kalitesine göre de analiz edilmiştir. Kesinlik, geri çağırma ve F1 skoru, yüksek, orta ve düşük kalite düzeyleri için Tablo 5.1’de verilmiştir. Modellerin yüksek kaliteli görüntüler üzerinde oldukça iyi performans gösterdiği gözlemlenmektedir. Sonuçlar özellikle birinci yaklaşımla yüksek kaliteli 30x30 yamalarda (%88.09 kesinlik, %93.90 geri çağırma ve %90.91 F1 Skoru) oldukça tatmin edicidir. Ancak beklendiği gibi orta ve düşük kaliteli görüntülerde model performansları özellikle kesinlik açısından düşmektedir. Gerçek özellik noktalarının çoğu doğru bir şekilde algılansa da, sahte özellik noktaları performansı aşağı çekmektedir. Bu sonuçlar, özellikle düşük kaliteli görüntülerde eğitim öncesi ön işlemenin önemini göstermektedir.

Tablo 5.1 En iyi sistemin performans metriklerinin parmak izi kalitesine göre alt kırılımı

	Kesinlik (%)	Geriçağırım (%)	F1 Skoru (%)
Yüksek	88.09	93.90	90.91
Orta	80.63	92.38	86.10
Düşük	73.53	87.75	80.02
Hepsi	82.62	92.24	87.17

Yukarıdaki analize ek olarak, basit ağ modeli ile veri artırımının etkisi de gözlenmiştir. Veri artırımı olan ve olmayan sonuçlar Tablo 5.2'de gösterilmektedir. Aynı büyüklükteki verilere veri artırımı uygulanarak performanslar önemli ölçüde iyileştirilmiştir. Bu sonuç aynı zamanda veri kümesi boyutunun etkisi olarak da yorumlanabilir. Modele daha fazla değişkenlik sunmak görünmeyen veriler üzerinde iyi performans göstermesi ve genelleme yeteneğini artırması anlamına gelmektedir

Tablo 5.2 Veri artırımının performanslara olan etkisi

	Veri artırımı yok				Veri artırımı var			
	30(1)	30(2)	50(1)	50(2)	30(1)	30(2)	50(1)	50(2)
DP	5474	5441	5853	5441	5800	5674	6222	5847
YP	1917	2469	5326	4777	1220	1565	3299	3288
YN	814	853	857	804	488	620	488	398
Kesinlik (%)	74.06	68.79	52.36	53.25	82.62	78.38	65.35	64.01
Geriçağırım (%)	87.05	86.45	87.23	87.13	92.24	90.15	92.73	93.63
F1 Skoru (%)	80.04	76.61	65.44	66.10	87.17	83.85	76.67	76.03

Sonuç olarak, tüm ağlar, geri çağırma metriği açısından iyi performans göstermektedir; bu, hepsinin gerçek özellik noktalarını doğru bir şekilde tespit edebildikleri anlamına gelir (bir model hariç). Aralarındaki fark, tespit ettikleri sahte özellik noktalarının sayısıdır. Bununla birlikte, modeller, hiçbir ön işleme ve kalite geliştirme adımı uygulanmamasına rağmen umut verici sonuçlar göstermektedir. Eğitimde önemsiz olmayan yamaların miktarını artırmak veya testte piksel kaydırma penceresi yaklaşımıyla piksele alternatif bir yaklaşım, algılanan sahte özellik noktalarının sayısını azaltmaya yardımcı olabilir.

5.3 Papil çizgisi yönelimi kestirme

Sentetik veriler deneme yapılan ağ yapısı ve 500 eğitim dönemi ile sonuçlarda bir iyileşme sağlayamamıştır. Bunun sebebi, imgelerin tek tek değil yamalar halinde kullanılmasından ötürü, gerçek örnek sayısının yeterli olması ve eğitim için ek örnekler ihtiyacı duyulmaması olarak düşünülebilir. Ancak, ilk deneyde aşırı uyum gösterme problemi ile karşılaşılması ve son deneyde test kaybının düşmeye devam edecek gibi görünüyorsa farklı normalizasyon yöntemleri ve farklı sentetik veri kümeleri (imge sayısı, imge büyüklüğü ya da deformasyonlar açısından) ile iyileştirmenin başarılabilirliğini düşündürmektedir.

Kaynaklar

- Anand, V., Kanhangad, V. 2020) "Porenet: Cnn-based pore descriptor for high-resolution fingerprint recognition", IEEE Sensors Journal, 20(16), 9305-9313.
- Ansari, Afzalul Haque: Generation and storage of large synthetic fingerprint database. ME Thesis, Jul, 2011.
- Arjovsky, M., Chintala, S., Bottou, L. 2017. "Wasserstein generative adversarial networks", International Conference on Machine Learning, 214-223.
- Bontrager, P., Roy, A., Togelius, J., Memon, N., Ross, A. 2018. "Deepmasterprints: Generating masterprints for dictionary attacks via latent variable evolution", International Conference on Biometrics Theory, Applications and Systems, 1-9.
- Cao, K., Chugh, T., Zhou, J., Tabassi, E., Jain, A. K. 2016 "Automatic latent value determination", IEEE International Conference on Biometrics, 1-8.
- Cao, K., Jain, A. K. 2015. "Latent orientation field estimation via convolutional neural network", International Conference on Biometrics, 349-356.
- Cao, K., Jain, A. K. 2015. "Latent orientation field estimation via convolutional neural network", International Conference on Biometrics, 349-356.
- Cao, K., Jain, A. K. 2015. "Learning fingerprint reconstruction: From minutiae to image", IEEE Transactions on information forensics and security, 10(1), 104-117.
- Cao, K., Jain, A. K. 2017. "Automated latent fingerprint recognition", arXiv preprint arXiv:1704.01925.
- Cao, K., Liu, E., Jain, A. K. 2014. "Segmentation and enhancement of latent fingerprints: A coarse to fine ridge structure dictionary", IEEE Transactions on Pattern Analysis and Machine Intelligence, 36(9), 1847-1859.
- Cappelli, R., Erol, A., Maio, D., Maltoni, D. 2000. "Synthetic fingerprint-image generation", IEEE International Conference on Pattern Recognition, 3, 471-474.
- Cappelli, R., Maio, D., Maltoni, D. 2002. "Synthetic fingerprint-database generation", IEEE International Conference on Pattern Recognition, 3, 744-747.
- Cappelli, R., Maio, D., Maltoni, D. 2004. "SFinGe: An approach to synthetic fingerprint generation", International Workshop on Biometric Technologies, 147-154.
- Cappelli, R., Maltoni, D. 2009. "On the spatial distribution of fingerprint singularities", IEEE Transactions on Pattern Analysis and Machine Intelligence, 31(4), 742-448.
- Cui, Z., Feng, J., Zhou, J. 2019. "Dense fingerprint registration via displacement regression network", International Conference on Biometrics, 1-8.
- Darlow, L. N., Rosman, B. (2017). "Fingerprint minutiae extraction using deep learning", International Joint Conference on Biometrics, 22-30.
- Dorizzi, B., Cappelli, R., Ferrara, M., Maio, D., Maltoni, D., Houmani, N., Garcia-Salicetti S., Mayoue, A. 2009. "Fingerprint and on-line signature verification competitions at ICB 2009" International Conference on Biometrics, 725-732.
- Ezeobijesi, J., Bhanu, B. 2018. "Patch based latent fingerprint matching using deep learning", IEEE International Conference on Image Processing, 2017-2021.
- Fahim M. A. I. , Jung, H. Y. 2020. "A Lightweight GAN Network for Large Scale Fingerprint Generation," in IEEE Access, 8, 92918-92928.

- Fellbaum, A. 1998. WordNet: An Electronic Lexical Database. BradfordBooks.
- Feng, J., Jain, A. K. 2009. "FM model based fingerprint reconstruction from minutiae template", International Conference on Biometrics, 544-553.
- Feng, J., Jain, A. K. 2011. "Fingerprint reconstruction: From minutiae to phase", IEEE Transactions on Pattern Analysis and Machine Intelligence, 33(2), 209-223.
- Galton, F. 1965. Fingerprints (Reprint). Da Capo Press.
- Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., Courville, A. 2017. "Improved training of wasserstein gans", arXiv preprint arXiv:1704.00028.
- He, K., Zhang, X., Ren, S., Sun, J. 2016. "Deep residual learning for image recognition", Conference on Computer Vision and Pattern Recognition, 770-778.
- He, Z., Liu, E., Xiang, Z. 2020. "Partial Fingerprint Verification via Spatial Transformer Networks", International Joint Conference on Biometrics, 1-10.
- Imdahl, C., Huckemann, S., Gottschlich, C. 2015. "Towards generating realistic synthetic fingerprint images", IEEE International Symposium on Image and Signal Processing and Analysis, 78-82.
- Jain, A., Ross, A. 2007. "Introduction to biometrics". Handbook of Biometrics. Editörler: Jain, A., Flynn, P. and Ross, A. Springer Science & Business Media.
- Jiang, L., Zhao, T., Bai, C., Yong, A., Wu, M. 2016. "A direct fingerprint minutiae extraction approach based on convolutional neural networks", International Joint Conference on Neural Networks, 571-578.
- Johnson, P., Hua, F., Schuckers, S. 2013. "Texture modeling for synthetic fingerprint generation", IEEE Conference on Computer Vision and Pattern Recognition Workshops, 154-159
- Kofman, A. "The FBI is building a national watchlist that gives companies real-time updates on employees", The Intercept. "1. Giriş"
<https://theintercept.com/2017/02/04/the-fbi-is-building-a-national-watchlist-that-gives-companies-real-time-updates-on-employees>
 Son Erişim Tarihi: 27.06.2021
- Lee, H. C., Ramotowski, R., Gaensslen, R. E. 2001. Advances in Fingerprint Technology. CRC Press.
- Li, R., Song, D., Liu, Y., Feng, J. 2019. "Learning global fingerprint features by training a fully convolutional network with local patches", International Conference on Biometrics, 1-8.
- Listyalina, L., Mustiadi, I. 2019. "Accurate and Low-cost Fingerprint Classification via Transfer Learning", International Conference on Science in Information Technology, 27-32.
- Listyalina, L., Mustiadi, I. 2019. "Accurate and Low-cost Fingerprint Classification via Transfer Learning", International Conference on Science in Information Technology, 27-32.
- Liu, F., Zhao, Y., Liu, G., & Shen, L. 2020. "Fingerprint pore matching using deep features", Pattern Recognition, 102, 107208.
- Maltoni, D., Cappelli, R. 2009. "Advances in fingerprint modeling", Image and Vision Computing, 27(3), 258-268.
- Maltoni, D., Maio, D., Jain, A., Prabhakar, S. 2009. Handbook of Fingerprint Recognition. Springer Science & Business Media.
- Maltoni, D., Maio, D., Jain, A. K., Prabhakar, S. 2009. "Synthetic fingerprint generation". Handbook of fingerprint recognition, pp. 271–302.
- Mao, X., Li, Q., Xie, H., Lau, R. Y., Wang, Z., Paul Smolley, S. 2017. "Least squares generative

adversarial networks", International Conference on Computer Vision, 2794-2802.

Michelsanti, D., Ene, A. D., Guichi, Y., Stef, R., Nasrollahi, K., Moeslund, T. B. 2017. "Fast fingerprint classification with deep neural networks", International Conference on Computer Vision Theory and Applications, 202-209.

Michelsanti, D., Ene, A.D., Guichi, Y., Stef, R., Nasrollahi, K., Moeslund, T.B. 2017. "Fast fingerprint classification with deep neural networks", International Conference on Computer Vision Theory and Applications, 202-209.

Nguyen, D. L., Cao, K., Jain, A. K. 2018. "Robust minutiae extractor: Integrating deep networks and fingerprint domain knowledge", International Conference on Biometrics, 9-16.

Peralta, D., Triguero, I., Garcia, S., Saeys, Y., Benitez, J. M., Herrera, F. 2017. "On the use of convolutional neural networks for robust classification of multiple fingerprint captures", arXiv:1703.07270

Radford, A., Metz, L., Chintala, S. 2015. "Unsupervised representation learning with deep convolutional generative adversarial networks", arXiv preprint arXiv:1511.06434.

Roy, A., Memon M., Togelius J., Ross A. 2018. "Evolutionary Methods for Generating Synthetic MasterPrint Templates: Dictionary Attack in Fingerprint Recognition," International Conference on Biometrics, 39-46.

Sankaran, A., Vatsa, M., Singh, R. 2012. "Hierarchical fusion for matching simultaneous latent fingerprint", Proceedings of International Conference on Biometrics Theory, Application and Systems, 377-382.

Sankaran, A., Vatsa, M., Singh, R. 2014. "Latent fingerprint matching: A survey", IEEE Access, 2, 982-1004.

Schuch, P., Schulz, S. D., Busch, C. 2017. "ConvNet regression for fingerprint orientations" Scandinavian Conference on Image Analysis, 325-336.

Schuch, P., Schulz, S. D., Busch, C. 2017. "Deep expectation for estimation of fingerprint orientation fields", International Joint Conference on Biometrics, 185-190.

Sherlock, B.G., Monro, D.M. 1993. "A model for interpreting fingerprint topology", Pattern recognition, 26(7), pp.1047-1055.

Simonyan, K., Zisserman, A. 2014. "Very deep convolutional networks for large-scale image recognition". arXiv preprint arXiv:1409.1556.

Svoboda, J., Monti, F., Bronstein, M. M. 2017. "Generative convolutional networks for latent fingerprint reconstruction", arXiv preprint arXiv:1705.01707.

Tang, Y., Gao, F., Feng, J. 2016. "Latent fingerprint minutia extraction using fully convolutional network", arXiv preprint arXiv:1609.09850.

Tang, Y., Gao, F., Feng, J., Liu, Y. 2017. "FingerNet: An unified deep network for fingerprint minutiae extraction", International Joint Conference on Biometrics 108-116.

Tang, Y., Li, R., Liu, Y., Feng, J. 2019. "FClassNet: a fingerprint classification network integrated with the domain knowledge", Science China Information Sciences, 62(12), 1-3.

Tertychnyi, P., Ozcinar, C., Anbarjafari, G. 2018. "Low-quality fingerprint classification using deep neural network", IET Biometrics, 7(6), 550-556.

V. Mistry, J. J. Engelsma and A. K. Jain, "Fingerprint Synthesis: Search with 100 Million Prints," 2020 IEEE International Joint Conference on Biometrics (IJCB), 2020, pp. 1-10

Vizcaya, P.R. and Gerhardt, L.A., 1996. "A nonlinear orientation model for global description of fingerprints", Pattern Recognition, 29(7), pp.1221-1231.

Wang R., Han C., Guo T. 2016. "A novel fingerprint classification method based on deep learning," International Conference on Pattern Recognition, 931-936.

WCCI 2018, Fingerprint inpainting and denoising "3.1.1 Model tabanlı parmak izi üretme"

<http://chalearnlap.cvc.uab.es/dataset/32/description/>

Son erişim tarihi: 01.07.2021

Zhao, Q., Jain, A. K., Paulter, N. G., Taylor, M. 2012. "Fingerprint image synthesis based on statistical feature models", IEEE Conference on Biometrics: Theory, Applications and Systems, 23-30.

Zhou, B., Han, C., Liu, Y., Guo, T., Qin, J. 2020. "Fast minutiae extractor using neural network", Pattern Recognition, 103, 107273.

TÜBİTAK
PROJE ÖZET BİLGİ FORMU

Proje Yürütücüsü:	Dr. Öğr. Üyesi NESLİ ERDOĞMUŞ
Proje No:	217E092
Proje Başlığı:	Gizli Parmak İzlerinin Sentetik Üretimi
Proje Türü:	Uluslararası
Proje Süresi:	30
Araştırmacılar:	
Danışmanlar:	
Projenin Yürütüldüğü Kuruluş ve Adresi:	İZMİR YÜKSEK TEKNOLOJİ ENSTİTÜSÜ
Projenin Başlangıç ve Bitiş Tarihleri:	01/07/2018 - 01/01/2021
Onaylanan Bütçe:	318633.0
Harcanan Bütçe:	154614.34
Öz:	<p>Parmak izi tanıma sistemleri sınır geçişleri, kişisel bilgilerin korunumu ve güvenliği ve adli incelemeler gibi bir çok alanda önemli bir yer tutmaktadır. Parmak izi, pasaportlardan, cep telefonlarına kadar gündelik hayata nüfus etmiş olması bir yana, kriminal vaka çözümlerinde de halen en çok kullanılan araçların başında gelmektedir. Bu önem, dünya nüfusundaki ve nüfus hareketliliğindeki artış ile birleşince otomatik parmak izi eşleştirme ve tanıma araştırmaları hız kazanmıştır.</p> <p>Ancak kişisel ve/veya adli veri olması, elde edilmesindeki güçlükler ve uzmanlık gereksinimi nedeni ile gizli parmak izlerinin araştırma amaçlı toplanmaları ve erişime açık hale getirilmeleri diğer araştırma alanlarına kıyasla güç olabilmektedir. Öte yandan çok sayıda parmak izi örneğine sahip olmak iki açıdan önem arz etmektedir:</p> <ol style="list-style-type: none">1. Gerçek olay çözümlerinde ve kimlik tespitinde, parmak izi taraması büyük oranda milyonlarca kayıtlı parmak izi görüntüsü üstünde yapılmaktadır. Laboratuvar ortamında gerçekçi performans değerleri elde etmek için benzer büyüklükte veri kümeleri gerekmektedir.2. Son yıllarda çok geniş bir uygulama alanı bulan ve bunların birçoğunda elde edilen başarımlar oranlarını çok daha ileri seviyelere taşıyan derin öğrenme yaklaşımlarının performansları ile eğitim veri kümesinin büyüklüğü arasında olumlu bir bağıntı mevcuttur. Yapay derin sinir ağlarının eğitimi için geniş veri kümelerine ihtiyaç vardır. <p>Bu projede, yukarıda bahsedilen etkenlerden ikincisine odaklanılmış ve sentetik gizli parmak izi görüntülerinin parmak izi işleme ve tanıma sistemlerinin eğitimi ve testlerinde kullanılmak üzere üretilmesi hedeflenmiştir. Gerçek parmak izi eşleştirme senaryolarında tarama yapılan veri kümelerinin büyüklüğü ve derin öğrenme yaklaşımları ile elde edilen başarımların veri büyüklüğüne olan bağımlılığı sebebi ile sentetik ve gerçeğine yakın veri üretme beraberinde büyük avantajlar getirecektir.</p> <p>Proje kapsamında üretilen parmak izlerinin ne kadar gerçeğe yakın oldukları, derin öğrenme sistemlerinin başarımlarını ne kadar arttırdıkları ölçüsüne göre değerlendirilmektedir. Bu doğrultuda, parmak izi tanıma ve eşleştirme alt adımlarından sınıflandırma, özellik noktası tespiti ve papil çizgisi yönelimi kestirimi görevleri için derin yapay sinir ağları geliştirilmiş ve eğitim için kullanılan sentetik parmak izi verilerinin bu ağların performanslarına olan etkileri ölçülmüştür. Örnek sayısının az olduğu sınıflandırma görevinde dikkate değer bir artış gözlemlenirken, yama-tabanlı geliştirilen ve bu sebeple az örnek sayısı probleminin bertaraf edildiği özellik noktası tespiti ve papil çizgisi yönelimi kestirimi görevlerinde benzer bir etki gözlemlenmemiştir.</p> <p>Parmak izi üretimi için biri model, biri de istatistik tabanlı olmak üzere iki yaklaşım denenmiştir. Model tabanlı sistemde parmak izlerinin sınıfı, özellik noktaları, papil çizgisi yönelim ve frekansı gibi tüm faktörler kontrol/tespit edilebildiği için bu yöntemler üretilen parmak izleri için performans testleri yapılmıştır. Ancak, istatistik tabanlı sistemde çekişmeli üretici ağlar eğitilmiş, ancak imgelerin parmak izi sınıfı dışında bir meta veriye bağlı olarak üretilmeleri sağlanamamıştır.</p>

Abstract:	<p>Fingerprint recognition systems have an important place in many areas such as border crossing, protection and security of personal information and forensic investigations. Fingerprints are still one of the most used tools in criminal case analysis, aside from having penetrated into daily life from passports to mobile phones. This importance, combined with the increase in the world population and its mobility, has accelerated automatic fingerprint matching and recognition research.</p> <p>However, collecting private data such as fingerprints and making them accessible for research purposes may be difficult compared to other research fields, due to several facts; such as fingerprints being private and/or forensic data, difficulties in obtaining them and the need for expertise. On the other hand, having a large number of fingerprint samples is important in two respects:</p> <ol style="list-style-type: none"> 1. In real event analysis and identification, fingerprint scanning is largely done on millions of recorded fingerprint images. Datasets of similar size are required to obtain realistic performance values in a laboratory setting. 2. There is a positive correlation between the performance of deep learning approaches, which have found a wide range of applications in recent years and the size of the training dataset. Large datasets are needed for training artificial deep neural networks. <p>Due to the size of the datasets scanned in real fingerprint queries and the dependence of the performances obtained with deep learning approaches on the data size, producing synthetic and realistic data brings great advantages. This project focuses on the second of the factors mentioned above and aims to produce synthetic latent fingerprint images for use in training of fingerprint processing and recognition systems.</p> <p>The fingerprints produced within the scope of the project are evaluated according to how close they are to reality and how much they increase the success rates of deep learning systems. In this direction, deep artificial neural networks were developed for classification, minutiae detection and ridge orientation estimation tasks, which are sub-steps of fingerprint recognition and matching, and the effects of synthetic fingerprint data used for training on the performance of these networks were measured. While a remarkable increase was observed in the classification task with a small number of samples, a similar effect was not observed in the minutiae detection and ridge orientation estimation tasks, which have adopted patch-based approaches and therefore eliminated the small sample size problem.</p> <p>One model-based and one statistics-based approach are implemented for fingerprint generation. Since all factors such as class, feature points, ridge orientation and frequency can be controlled/detected in the model-based system, performance tests have been made for the fingerprints produced by these methods. However, in the statistics-based system, several generative adversarial networks are trained, but the synthetic images could not be produced depending on any metadata except the fingerprint class.</p>
Anahtar Kelimeler:	Parmak izi üretme, parmak izi işleme, parmak izi tanıma, derin öğrenme, çeşitli üretici ağlar
Fikri Ürün Bildirim Formu Sunuldu Mu?:	Evet
Projenin Yapılan Yayınlar:	1- Impact of variations in synthetic training data on fingerprint classification (Bildiri - Uluslararası Bildiri - Poster Sunum),