

# Kısıtlanmış Boltzmann Makinesi Ve Farklı Sınıflandırıcılarla Oluşturulan Sınıflandırma İş Hatlarının Başarımının Değerlendirilmesi

*Araştırma Makalesi/Research Article*

Bahadır KARASULU

Bilgisayar Mühendisliği Bölümü, Mühendislik Fakültesi, Çanakkale Onsekiz Mart Üniversitesi, Çanakkale, Türkiye.

[bahadirkarasulu@comu.edu.tr](mailto:bahadirkarasulu@comu.edu.tr)

(Geliş/Received:23.12.2017; Kabul/Accepted:09.05.2018)

DOI: 10.17671/gazibtd.370281

**Özet**— Literatürdeki birçok sınıflandırıcı yöntemi en yüksek sınıflandırma doğruluğuna ulaşılması için kullanılmaktadır. Kısıtlanmış Boltzmann makinesi gözetimsiz öğrenmenin yapıldığı bir yapay sinir ağı olmasının yanı sıra, öznelik elde etmekte kullanılan öğrenen bir bileşen olarak önem kazanmıştır. Çalışmamızda Bernoulli tipli kısıtlanmış Boltzmann makinesi ve farklı sınıflandırıcılar kullanılarak oluşturulan beş farklı iş hattının başarımları kıyaslanmaktadır. Bu iş hatlarında sırasıyla lojistik regresyon, karar ağacı, Gauss saf Bayes, Ada Boost ve rasgele orman sınıflandırıcı kullanılmıştır. Sınıflandırma sonucu değişiklikleri, bu sınıflandırıcıların elde ettiği tek başına sınıflandırma sonuçlarına kıyasla iş hatları kullanılarak gözlemlenmiştir. Deneysel sonuçlar, MNIST el yazısı rakam tanıma veri kümesi kullanılarak elde edilmiştir. Bu deneylerde kısıtlanmış Boltzmann makinesinin üstün parametrelerinin iki farklı düzeni kullanılmıştır. Bu sonuçlara göre, tek başına sınıflandırıcının sınıflandırma doğruluğunun deneylerdeki iş hatları kullanımı sayesinde daha iyi hale geldiği görülmüştür. En yüksek başarımlar %97,19'luk bir sınıflandırma başarı oranıyla elde edilmiştir. Önerilen iş hattı tasarımını kullanan modeller ilgili bireysel sınıflandırıcı ortalama başarımlarını en az %1 ilâ en çok %33 arasında iyileştirmiştir. Makalede tartışmaya da yer verilmektedir.

**Anahtar Kelimeler**— kısıtlanmış Boltzmann makinesi, sınıflandırma, makine öğrenmesi, el yazısı, rakam tanıma.

## Performance Evaluation of Classification Pipelines Builded with Restricted Boltzmann Machine and Several Classifiers

**Abstract**— Many classification methods in the literature are used to achieve the highest classification accuracy. The restricted Boltzmann machine is an artificial neural network with unsupervised learning, however it is gained importance as a learning component to extract attributes. In our study, we compared the performances of five different pipelines builded with the Bernoulli-type restricted Boltzmann machine and different classifiers. Experiments have been carried out on these pipelines by using logistic regression, decision tree, Gaussian naive Bayes, Ada Boost, and random forest classifier, respectively. The classification resultant changes were observed through the use of pipelines compared to the stand alone classification results obtained by these classifiers. Experimental results were obtained with the use of MNIST handwriting digit recognition data set. In these experiments, two different orders of hyper parameters of the restricted Boltzmann machine were used. According to these results, it was seen that the classification accuracy of the stand alone classifier became better through the use of pipelines in the experiments. The highest performance was achieved with a classification success rate of 97.19%. Models using the proposed pipeline design have improved the average performance of related individual classifiers from at least 1% to at most 33%. Discussions are also included.

**Keywords**— restricted Boltzmann machine, classification, machine learning, handwriting, digit recognition.

### 1. GİRİŞ (INTRODUCTION)

Günümüzde makine öğrenmesi hayatımızın birçok alanında kullanılmaktadır. Özellikle nesne tanıma ve takibi yoluyla güvenlik sistemlerinin oluşturulması, el yazısı tanıma, ses parçasından konuşma analizi, insan

yüzü tespiti ve kimlik doğrulama üzerinde oldukça fazla çalışılmış, makine öğrenmesini kullanarak çözülmeye çalışılan problemlerin olduğu alanlardır. Büyük veri ile çalışılırken ham veriden anlamlı bilgiye (knowledge) ulaşılması yoluyla gerçek hayat problemlerinin çözümüne yönelik yaklaşımlar kullanılmaktadır. Veri analizi ve

sınıflandırma bu işin daha yüksek doğrulukla başarılmasını sağlamaktadır. Son yıllarda, birleşik olasılık dağılımını temel alan örnekleme, tahmin ve çıkarsamaya dayanan çözümler günümüz büyük veri ortamlarında karşılaşılan böyle problemlerin çözümünde kullanılmaya başlanmıştır. Bu açıdan olasılıksal çizgesel modeller, rasgele değişkenler arasındaki bağımsızlığı açıkça ortaya koyabilmeleri ve büyük birleşik dağılımlar için güçlü bir çıkarsama yapabilmeye imkan tanımaları nedeniyle önemlidirler. Markov Rasgele Alanı (Markov Random Field, MRA), uzamsal veya ilişki alanından oluşan problemlerin modellenmesinde koşullu olasılığı kullanmaktadır. Çizge (graph) fikrinden yola çıkılarak düğümlerdeki koşullu olasılığa dayalı eşleştirmelerden yararlanılmıştır. Literatürde sıklıkla karşılaşılan Boltzmann Makinesi böyle bir MRA temel alınarak oluşturulmuş, bazı düğümleri "gizli" bazı düğümleri ise "görünür" olarak verilen ve bu düğümlerin değişkenleri temsil ettiği bir çizge yapısındaki Yapay Sinir Ağıdır (Artificial Neural Network, YSA). Buna benzer bazı oluşturucu modeller (generative models) günümüzün yeni trend konusu olan derin öğrenme mimarileri arasında yer almaktadır. Derin öğrenme mimarilerinde YSA'lar bir veya birden fazla gizli katmanı olan ağlar olarak tasarlanmaktadır. Derin öğrenmede, özellikler (features) veriden otomatik olarak elde edilirler, elle belirlenmelerine veya hesaplanmalarına gerek duyulmaz. Böylece farklı sınıflandırma görevleri için etkin olarak ilgili makine öğrenmesi yöntemi kullanılabilir. Derin öğrenmede katmanların bir sıradüzeni ile çalışmakta üst üste yığılan (stacked) katmanlı bir yapı sayesinde rasgele oluşturulan özellikler kullanılarak öğrenme gerçekleşmektedir. Sınıflandırma görevine dair bir maliyet fonksiyonunun eniyilemesi bu özelliklerin öğrenme fazı boyunca dereceli olarak rafine bir hale getirilmesi yoluyla yapılmaktadır. Derin İnanç Ağları (Deep Belief Networks, DİA), Evrişimli Yapay Sinir Ağı (Convolutional Artificial Neural Network, EYSA) ve Kısıtlanmış Boltzmann Makinesi (Restricted Boltzmann Machine, KBM) gibi derin öğrenme mimarileri doğrudan veriden özellik elde etmeyi sağlamakla beraber, daha fazla sayıda ek ağ katmanı ve sinir düğümünü kullanmaları nedeniyle daha yüksek hesapsal karmaşıklığa da neden olmaktadır [1,2].

Literatürde birçok sınıflandırma ve regresyon yöntemi bulunmaktadır. Bunlardan en sık kullanılanlar k-Enyakın Komşuluk (k-Nearest Neighbor, k-EK), Karar Ağaçları (decision trees, KA), Rasgele Orman Sınıflandırıcı (random forest classifier, ROS), Gauss Saf Bayes (Gaussian Naive Bayes, GSB) sınıflandırıcı, Ada Boost sınıflandırıcı ve Lojistik Regresyon Sınıflandırıcı (LRS) yöntemi olarak bilinmektedir. Bunlar yoğunlukla elle belirlenmiş özellikleri kullanmaktadırlar. Karakoç vd. çalışmasında [3] belirtildiği gibi, elle modellenmesi yapılmış bir yoldan özellik elde edilmeyen derin öğrenme mimarilerinde, basit işlemler veriye uygulanırken kullanılan parametrelerden en uygun olanını öğrenme söz konusudur. Bu bakış açısıyla, verinin problemi ne kadar iyi temsil ettiği, parametre sayısı ve bunları güncellemek için izlenecek çeşitli stratejiler önem

kazanmaktadır [3]. Daha yüksek sınıflandırma doğruluğuna ulaşmak için topluluk sınıflandırması (ensemble classification) yaklaşımlarına başvurulabilmektedir. Bu yolla birden çok öğrenim yöntemi birleştirilerek belirli durumlar için daha iyi sonuçlar elde edilmesi mümkün olmaktadır. Bireysel olarak kullanılan öğrenme yöntemlerini iyi yönde geliştiren bir çabadır [1]. Literatürdeki çalışmalarda sunulan test sonuçlarına göre herhangi bir sınıflandırıcının başarımları kıyaslamalı olarak değerlendirilebilmektedir. Çalışmamızda da nesnel başarımlar ölçütleri bu nedenle kullanılarak kıyaslama yapılabilir deneysel sonuçlar ortaya konulmuştur.

Çalışmamızda KBM'nin Bernoulli tipli KBM olarak kullanıldığı ve bu yolla ayırt edici özelliklerin öğrenildiği, çeşitli topluluk sınıflandırması yaklaşımlarının oluşturulduğu iş hatlarının (pipeline) sınıflandırma başarımlarının değerlendirilmesi ve kıyaslanması üzerinde çalışılmıştır. Bu amaçla Bernoulli tipli KBM ve LRS, Bernoulli tipli KBM ve sırasıyla KA, ROS, GSB ve Ada Boost sınıflandırıcılarıyla ayrı ayrı kurulan beş adet farklı iş hattı literatürde sıkça kullanılan makine öğrenmesi veri kümesi üzerinden sınanmıştır. Sınama sonuçları, enformasyon teorisindeki nesnel ölçütlere uygun elde edilmiş ve deneysel sonuçlarda yer almaktadır. Çalışmamızın ana katkısı, böyle iş hatları kurularak sınıflandırma doğruluğunun ne şekilde iyileştirilebileceğini nesnel değerlerle karşılaştırmalı bir biçimde açıkça ortaya koyabilmesidir.

Makalenin organizasyonu şu şekildedir. İkinci bölümde Bernoulli tipli KBM, KA, ROS, GSB, Ada Boost ve LRS sınıflandırıcıları hakkında temel bilgiler verilmektedir. Üçüncü bölümde yapılan deneylerde kullanılan iş hattı tasarımına değinilmektedir. Dördüncü bölümde deneylerde kullanılan veri kümesinin detaylarına yer verilerek, iş hattında kullanılan farklı sınıflandırıcılarla elde edilen deneysel sonuçlar karşılaştırmalı olarak verilmektedir. Beşinci bölümde deneysel sonuçların değerlendirilmesi üzerinden çalışmanın ana katkısına dayanan tartışmaya ve varılan sonuçlara yer verilmektedir.

## 2. TEMEL BİLGİLER (BASIC KNOWLEDGE)

Literatürde birçok sınıflandırıcı ve regresyon yönteminin oluşu, bunlardan biri ile elde edilen sonucun diğerleri ile kıyaslanması yoluyla en iyisinin seçilmesinin makine öğrenmesi için yüksek doğrulukta sınıflandırma ve çıkarsama yapılmasında önem arz ettiğini göstermektedir. Boltzmann Makinesi (kısıtlanmamış hali) ikili düğümlerin bulunduğu katmanlardan oluşur, bunlar arasında tam bağlantılar mevcuttur ve hiç bir kısıtlama söz konusu değildir. Kısıtlanmış Boltzmann Makinesi (KBM), gözetimsiz öğrenme (unsupervised learning) için bir YSA modeli olarak ortaya çıkmıştır, fakat günümüzde daha çok özellik elde etmek için öğrenen bir bileşen olarak hem gözetimli öğrenme (supervised learning) algoritmaları ve sınıflandırıcılar için hem de derin öğrenme mimarilerinin oluşturulmasında kullanılmaktadır. KBM, Boltzmann

enerji fonksiyonuna yapılan kısıtlamalar nedeniyle bu ismi almıştır. Çalışmamızda kullanılan Bernoulli tipli KBM sayesinde gözetimsiz ön eğitim aşaması gerçekleştirilerek farklı sınıflandırıcılara buradan elde edilen öznelilikler girdi olarak verilmiştir. Bernoulli tipli KBM, olasılıksal bir modeli temel alarak gözetimsiz biçimde öznelilik öğrenen bir yapıdır. Bu yapıda girdiler ya ikili (binary) yapıda ya da 0 ile 1 arası değerlerdedir, böylece "açık" konuma getirilecek özel bir özneliliğe dair olasılık belirlenmiş olur. KBM, veri kümesindeki gizlenmiş haldeki bilgini temsilini ortaya çıkartmakta oldukça başarılıdır. Bernoulli tipli KBM kullanılarak veri kümesindeki öznelilikler kolaylıkla elde edilebilmekte, böylece ham sinyallerden özneliliklere önceden tanımlı olmayan (elle işaretlenmemiş) otomatik bir eşleştirme yapılabilmektedir. Bu açıdan, log-doğrusal MRA olan KBM sayesinde birçok derin öğrenme mimarisi de oluşturulabilmektedir [4]. En popüler eğimli yaklaşılama (gradient approximation) modellerinden birisi de Zıt İraksama (Contrastive Divergence) olarak bilinmektedir. Özellikle, örnekleme sürecini hızlandırmak için CD-1 ( $k=1$ ) yaklaşılama sayesinde bir adımlık işlem ile öğrenme KBM'larında oldukça sık kullanılır [5]. KBM'larında ikili düğümlerin iki katmanı mevcuttur. Birincisi "görünür", ikincisi "gizli" düğümlerin olduğu katmandır. Bu açıdan, KBM'larını iki parçalı (bipartite) çizge olarak görebiliriz [6]. Görünür katman, dışarıdan girdi olarak alınan veriyi temsil ederken, gizli katman ise öğrenme yeteneğini artırmaktadır. Gizli katmandaki düğümlerin dışarı ile ilişkisi yoktur. Bernoulli tipli KBM için gizli katmandaki düğümler Bernoulli olasılık dağılımına uygun tipte düğümlerdir. Görünür katmandaki düğümler birbirleri ile bağlantı kurmamakta, fakat gizli katmandaki düğümlerle yönsüz simetrik tam bağlantılar kurmaktadır. Kurulan modele göre, olasılıksal ikili tipte olan ( $i$ ) adet "görünür" ve ( $j$ ) adet "gizli" birimin belirli bir durumuna dair enerji fonksiyonu aşağıdaki Eşitlik 1 'deki gibi verilir [7]:

$$\text{Enerji}(v, h|\theta) = - \sum_{i=1}^{\text{gorunur}} \sum_{j=1}^{\text{gizli}} w_{ij} v_i h_j - \sum_{i=1}^{\text{gorunur}} a_i v_i - \sum_{j=1}^{\text{gizli}} b_j h_j \quad (1)$$

burada  $v_i \in \{0,1\}$  "görünür" ve  $h_j \in \{0,1\}$  "gizli" birimleri için  $\theta$  model parametresini gösterirken,  $a_i$  ve  $b_j$  ise sırasıyla "görünür" ve "gizli" birimlere dair yanlılık (bias) terimlerini gösterir. Buradaki  $w_{ij}$  terimi de iki katman arasındaki bağlantıların ağırlık matrisini göstermektedir. Buna göre; "görünür" ve "gizli" birimler koşulsal olarak bağımsızdırlar, ayrıca görünürden-görünür birimlere veya gizliden-gizli birimlere bir bağlantı söz konusu değildir. KBM eğitildiği zaman, görünür düğüm etiketi için veri dağılımını temsil eden örnekleri oluşturabilir. Bunun yanı sıra, Gauss veya Bernoulli tipli olasılıksal görünür düğümler de diğer katmanda bulunur. KBM'ları çizge biçiminde gösterilebilirler. Başka olasılıksal dağılım tipli düğümler de literatürde mevcuttur [5]. KBM,  $O(2^b)$  adet girdi bölgesini  $O(N)$  parametre kullanarak temsil edebilir. Burada  $b$ , seyrek gösterimde

sıfırdan farklı değerdeki elemanları ifade eder. Ayrıca,  $b=N$  olduğunda yoğun bir KBM modeli oluşturulmuş anlamına gelir [6]. Bunun yanı sıra çalışmamızda kullanılan KBM tabanlı öğrenme algoritmasının kendi karmaşıklığı öğrenilen bileşen sayısı  $d$  olmak kaydıyla  $O(d^2)$  olarak bulunabilir. Böylece modeldeki üstün parametrelerin (hyperparameter) veriye uygun ayarlanması gerekmektedir. KBM için bazı üstün parametreler olarak gizli katmandaki birim sayısı, görünür katmandaki birim sayısı, ağırlık güncellemesindeki öğrenme oranı ve öğrenme adım sayısı parametreleri literatürdeki çalışmalarda verilmektedir. Bir KBM'dan veri elde etmek istenildiğinde, bu katmanlardan birinin bulunduğu rasgele bir durumdan başlanır ve Gibbs örnekleme kullanılarak işleme devam edilir [7]. Böylece bir katmandaki tüm düğümler diğer katmandaki düğümlerin şu anki durumlarına koşut olarak güncellenmiş olur ve denge durumuna ulaşılan kadar bu işlem devam ettirilir. Bu konu hakkındaki daha detaylı bilgilere Hinton vd. [2], Bengio vd. [6] ve Bengio [7] çalışmalarından ulaşılabilir.

Karar Ağaçlarında (KA), öznelilikler her bir bölüm (partition) için rasgele dağıtılmaktadır. Bu yolla, en iyi olarak bulunan bölüm aynı eğitim verisi kullanılsa da değişebilmektedir. KA gözetimli öğrenme yapar. Böl ve yönet tipi ağaç yapılı bir veri modelidir. KA sınıflandırıcıları için, iç karar düğümleri ve uç yapraklar mevcuttur. Verilen her bir girdi için her düğümde uygun denetim işlemi yapılarak sonucuna göre dallardan biri seçilir. Bir KA için karar süreci kök düğümden başlayıp bir yaprak düğüme varana kadar özyineli olarak sürer. Bir bölümden sonraki tüm dalları göz önüne aldığımızda, bir dala düşen örnekler aynı sınıfa aitlerse o bölüm saf bir bölümdür. Böylece bölüm saf olduğu için tekrar bölmeye gerek kalmaz ve hangi sınıfa uygunsa o sınıfta etiketlenmiş bir yaprak elde edilmiş olur [8].

Rasgele Orman Sınıflandırıcı (ROS), karar ağaçlarının çuvalı (bagged decision trees) şeklinde oluşturulur. Eğitim kümesindeki örnekler yer değiştirme usulüne göre alınırlar. Ağaçlar bireysel sınıflandırıcılar arasındaki korelasyonu azaltacak bir biçimde oluşturulurlar. Ağaç oluşturmada en iyi bölme noktasının (split point) seçimi yerine özneliliklerin rasgele bir alt kümesi her bir bölüm için ele alınıp incelenir. Ada Boost (Adaptive Boosting) sınıflandırıcı, uyarlanır bir yükseltme sayesinde zayıf öğrenme algoritmasının sınıflandırma başarımını artırmaktadır. Bir topluluk algoritmasıdır. Veri kümesindeki ağırlıklandırılmış örneklerle çalışır. Bunların ne kadar iyi veya kötü sınıflandırılabilirlerine bakar. Bunlara ne kadar önem vereceği veya vermeyeceğine bağlı olarak sonuç modelini oluşturur. Topluluktaki sınıflandırıcıların eğitiminden sonra, oylama yoluyla bir sınıflandırma birleştirmesine gidilir. Ada Boost algoritmasının birçok sürümü vardır, çalışmamızda kullanılan sürümde, model eğitiminde örnekler seçilmektedir. Bu seçim işleminde olasılıklar hataya bağlı olarak değiştirilmektedir. Kümenin büyük olması gerekmez, fakat yeterince örnek mevcut olmalıdır.

Başarısı veriye bağlıdır, gürtültülü ve aykırı verilerden etkilendir [8].

Gauss Saf Bayes (GSB) sınıflandırıcı, Bayes teoremini temel alan olasılıksal bir sınıflandırıcıdır. Hesapsal etkinliği ve yüksek doğru sınıflandırma başarımı nedeniyle sınıflandırma açısından literatürdeki çalışmalarda tercih edilir olmuştur. Daha karmaşık algoritmalara göre daha iyi sonuçlar verebilmektedir [9]. Sınıflandırmayı temsil eden bir çizgesel model kullanılır. İşlem sonunda, katlıterim (multinomial) dağılımlı değişkene uygun olarak farklı sınıflardan biri seçilir. Sınıfların olasılıklarını hesaplamada Bayes kuralını kullanır. Bunun yanı sıra, önsel (prior) olasılıklarına dayanarak sınıf olasılıklarını gözlenebilirlerin olasılığı olarak belirtir. Böylece, önsel olasılıkla veriden gelen bilgiyi birleştirip, bir gözlenebilir değişkenin gözlenmesi sonrasında sonsal (posterior) olasılıkları hesaplar. Bu yolla, en az hata için sonsal olasılığı en yüksek olan sınıfı seçerek sınıflandırma kararı verilir. Çok değişkenli dağılım girdiler arasındaki bağımlılıklar yok sayılarak tek değişkenli birden fazla dağılıma bu yolla indirgenmiş olur. Konuyla ilgili detaylı bilgilere Alpaydın'ın kitabından [8] ulaşılabilir.

Lojistik regresyon, bir istatistiksel yöntem olarak veri kümesi analizinde kullanılacak bir tahmin yöntemidir. Bu yöntemeye dayanan sınıflandırıcı için iki kategorili (binary) bağımlı (sonuç) değişken, 0 veya 1 şeklinde kesikli (discrete) bir değişkendir. Bu değişken ile bağımsız değişkenler arasındaki ilişkiyi tanımlayabilmeyi amaçlar. Böylece bağımlı değişken olarak ifade edilen belirli gruplara üye olma durumunu en iyi açıklayan bağımsız değişkenler kombinasyonu belirlenebilir [10]. Bir bağımlı (sonuç) değişken için yapılan analizde kullanılan birçok dağılım fonksiyonu bulunur. Lojistik regresyon olarak adlandırılmasındaki kasıt, literatürde en çok kullanılanlardan biri olan lojit dönüşümü kullanmasıdır [11]. Bu yolla ilgilenilen bağımlı değişkenin karakteristiğine dair olasılığın lojit dönüşümünü tahminleyerek uygun katsayılarla (standart hata ve anlamlılık düzeyleri) bahsedilen ilişkinin ortaya konulmasıyla ilgili gruplara (çok sınıflı durumda) sınıflandırma yapılır. Lojistik regresyonu kullanırken,  $y$  bağımlı değişkeni ve  $x$  bağımsız değişkeni olmak üzere  $\pi(x) = E(y|x)$  eşitliğine uygun özel bir biçimde  $E(y|x) = \beta_0 + \beta_1 x$  olarak bu regresyonu şöyle ifade ederiz [11]:

$$\pi(x) = \frac{e^{\beta_0 + \beta_1 x}}{1 + e^{\beta_0 + \beta_1 x}} \quad (2)$$

Burada  $\beta_0$  ve  $\beta_1$  modelin uygun katsayılarıdır. Buna dair lojit dönüşüm ile aşağıdaki eşitlik elde edilir [11]:

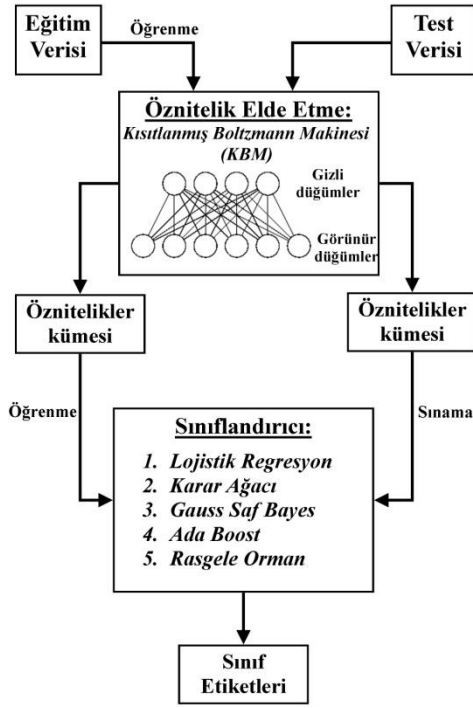
$$g(x) = \left[ \frac{\pi(x)}{1 - \pi(x)} \right] \quad (3)$$

Lojistik regresyonda, veri kümesinden örneklerin değerlerinin gözlemlenmesine dair olasılığın (likelihood) en büyüklemesini (maximization) sağlayan parametrelerin seçilmesi sayesinde, hatalar kareleri toplamının en az hale getirilmeye çalışıldığı çoklu regresyonda yapıldığının aksine bir olayın olma (gerçekleşmesi) olasılığının en büyüklemesiyle tahminleme yapılmasına dayanan sınıflandırma doğruluk oranı elde edilmiş olur. Çalışmamızda, L2 regülarizasyonu kullanılarak cezalandırmaya (penalty) uygun biçimde sınıf ağırlıkları Lojistik Regresyon Sınıflandırıcı (LRS) tarafından belirlenmiştir. Burada regülarizasyon, hesapsal olarak L1 regülarizasyonuna göre daha etkindir. Bu yolla, katsayıların aşırı uygunluk (overfitting) göstererek ezberlemeye neden olmasına da engel olunur. Fakat aykırı değerlere karşı da pek gürbüz (robust) olduğu söylenemez. LRS, tüm eğitim örnekleri üzerinden çalışarak ele alınan eniyileme probleminin amaç fonksiyonu değerini hesaplar. Burada bire karşı hepsi (one-vs-rest) şemasına uyulmakta, böylece bu eniyileme problemi tüm sınıflar için iki kategorili sınıflandırıcılara ayrıştırılmış olmaktadır [10,11].

Üçüncü bölümde yukarıda anılan çeşitli sınıflandırıcıların KBM ile bir iş hattı oluşturacak şekilde bir araya getirilmesi mimari yönden sistemin modüler yapısıyla açıklanmaktadır.

### 3. İŞ HATTI SİSTEM TASARIMI (SYSTEM DESIGN OF PIPELINE)

Çalışmamızda beş ayrı iş hattı, benzer veri akışı ve çalışma mantığına sadık kalacak biçimde aşağıda detayları verilen iş hattı sistemi ve buna ait sınıflandırıcı modülü ile kurulan alt tiplerine uygun olarak oluşturulmuştur. İş hattı sistemi temel iki modülden oluşmakta, elde edilen sınıflandırma sonucunun başarımı nesnel ölçütlerle tespit edilmektedir. Bu modüller sırasıyla, KBM modülü ve sınıflandırıcı tipini içeren sınıflandırıcı modüldür. Bu iş hattı sistemine veri kümesinin belirli bir bölümü eğitim verisi ve bir bölümü test (sınama) verisi şeklinde verilerek, öncelikle özniteliklerin elde edilmesi işlemi için *KBM modülü*'ne gönderilerek bu verilerin önışlemeden (preprocessing) geçirilmesi sağlanmaktadır. KBM modülü tarafından gözetimsiz bir biçimde öznitelikler öğrenilmekte ve böylece en uygun öznitelik kümesi elde edilmektedir. Bu öznitelik kümesi daha sonra diğer modül olan *sınıflandırıcı modülü*'ne geçirilerek uygun sınıflandırma yapılmakta, sınama işlemi yoluyla test aşamasına dair sınıflandırma sonuçları ilgili sınıf etiketleri şeklinde elde edilmekte ve bu sonuçların veri kümesindeki etiketlere ne derecede uyumlu olup olmadığı sistemin toplam sınıflandırma doğruluk başarısı olarak tespit edilmektedir. Aşağıdaki Şekil 1 'de iş hattı sisteminin mimari tasarımı şematik olarak görülmektedir.



Şekil 1. Önerilen İş Hattı Sisteminin Yapısı Ve Sınıflandırıcı Modül Alt Tipleri

(The structure of proposed pipelining system and classification module sub-types)

Bu iş hattı sisteminin deneylerde kullanılacak öznitelik kümesini oluşturan modülü olan KBM için üstün parametrelerin çeşitli değerleri deney veri kümesi ile deneyerek en iyi sonuçlar elde edilmiştir. KBM için üstün parametreler olarak; öğrenme oranı, öğrenme adım sayısı ve gizli katmandaki birim sayısı çalışmamızdaki iş hattı sistemine verilmektedir. Üstün parametrelerin farklı iki düzeni için farklı iki deney aynı veri kümesi üzerinden beş farklı iş hattının her biri için gerçekleştirilmiştir. Sistemde ilgili deneylerde LRS için gerekli regülasyon gücü katsayısı değeri sabit bir değer olarak alınmıştır. Ayrıca, deneylerde topluluk sınıflandırmasına dayanan Ada Boost için yükseltmenin durdurulacağı en fazla kestirimci sayısı parametresi ve ROS için ormandaki ağaç sayısı parametresi sabit bir değer olarak atanmıştır.

#### 4. DENEYSEL SONUÇLAR (EXPERIMENTAL RESULTS)

Literatürdeki sınıflandırıcıların başarımını ölçmek için birçok yol vardır. Bunlardan enformasyon teorisinde olup en çok rağbet gören bazı ölçütlerden olan kesinlik (precision), anma (recall), F1-skoru ve doğruluk başarısı (accuracy rate) ölçütleri çalışmamızda kullanılarak başarım değerlendirilmesi yapılmıştır. Bu ölçütlere en temelde iki sınıf üzerinde çalışan bir sınıflandırıcı için bakıldığında, bir örneğin bir sınıfa dahil olup olmamasına sınıflandırıcı artı ve eksi işaretli olarak karar veriyorsa, burada zaten artı olan bir örnek için sınıflandırıcı da artı olarak karar vermişse buna *doğru artı* (true positive, TP), tam tersine buna eksi olarak karar vermişse *yanlış eksi* (false negative, FN) ölçüsü olarak ifade edilir. Bu bakış açısıyla, sınıflandırıcı eksi işaretli bir örnek için artı demişse bu *yanlış artı* (false positive, FP) olur. Eksi

demişse bu ölçü *doğru eksi* (true negative, TN) olmaktadır [8], [12]. Bu bakış açısına göre,  $Kesinlik = \frac{|TP|}{(|TP|+|FP|)}$  ifadesiyle oransal olarak verilirken, bir diğer ölçüt olan  $Anma = \frac{|TP|}{(|TP|+|FN|)}$  olarak verilmektedir. Ayrıca bu ölçütlerin yanı sıra,  $Doğruluk\ Başarısı = \frac{(|TP|+|TN|)}{(|TP|+|FP|+|TN|+|FN|)}$  olarak verilir. F1-skoru ise kesinlik ve anma'nın harmonik ortalaması olarak ifade edilir. Bu ölçütlere uygun olarak Alıcı İşletim Eğrisi (Receiver Operating Characteristics, ROC) çizilebilmekte ve bu eğrinin altında kalan alan (Area Under Curve, AUC) hesapları yapılarak hem görsel biçimde hem de nesnel olarak sayısal değerlerle sınıflandırıcıları içeren iş hattı başarımları çalışmamızda kıyaslanmaktadır. Hem ROC hem de AUC açısından çoklu sınıflarla gösterim tercih edilmiştir. Aşağıdaki tablolar; ortalama kesinlik, ortalama anma, ortalama F1-skoru ve ortalama doğruluk başarısı değerleri her bir işhattıyla (her bir sınıflandırıcıyla) çalışmamızda kullanılan Modifiye/Karıştırılmış NIST (Mixed National Institute of Standards and Technology) elyazısı rakam tanıma (digit recognition) [13] (MNIST) orijinal veri kümesi üzerinden yapılan deneylerden elde edilen sonuçlarla oluşturulmuştur. Böylece çalışmamızdaki çeşitli sınıflandırıcıların tek başlarına (stand alone) kullanımlarındaki elde ettikleri sınıflandırma başarımları ile iş hattında bireysel modül olarak kullanımları sayesinde ortaklaşa çalıştıkları KBM modülünün onlara sağladığı başarımların iyileştirmesi açıkça ortaya konulmuş olmaktadır.

Çalışmamızda scikit-learn (version 0.18.1) isimli makine öğrenmesi ve veri madenciliği kütüphanesine [14], [15] ait fonksiyonlar kullanılarak önerilen iş hattına dair tasarımın gerçekleştirilmesi için Python dili kullanılmış, böylece çalışmamızdaki deneyler için kullandığımız uygulama yazılımı oluşturulmuştur. MNIST veri kümesinde altmış bin örnek eğitim kümesi için, on bin örnek ise test kümesi için ayrılmıştır. Her biri normalize edilmiş, sığıdığı çerçeveye ortalanmış elyazısı biçimdeki 0 ilâ 9 arası rakamları gösteren görüntülerden oluşmaktadır. Veri kümesindeki veri noktaları her bir rakam için yaklaşık uniform biçimde dağıtılmış, bu nedenle sınıflar arası dengesizlik oluşmamıştır. Bu veri kümesinde 0 ilâ 9 arası sınıf etiketleri verilmiş, her bir rakam 28x28 büyüklüğünde gri tonlu ham piksel yoğunluk (parlaklık) değerleri olarak 0 ilâ 255 arası değerler almaktadır. Bu değerler işaretli 8-bit tamsayı şeklindedir. Her bir rakam görüntüsü için her bir öznitelik vektörü 784-boyutlu olarak tasarlanmıştır. Çalışmamızda Bernoulli tipli KBM kullandığımız için, bu öznitelik vektörünün içerdiği 0 ilâ 255 arası değerleri ölçeklendirerek 0 ilâ 1 aralığına indirgeyecek ön işlem yapmamız gerekmektedir. Bu ön işlemden sonra ilgili iş hattının ilk modülü olan KBM'na bu değerler aktarılmıştır. KBM bu vektör yapısını kullanarak öznitelikleri elde etmiştir. Yapılan deneylerde KBM için iki farklı üstün parametre düzeni oluşturularak kullanılmıştır. Bunlar sırasıyla Tablo 1'de, KBM için 1 no'lu üstün parametre düzeni (ÜPD1) ve 2 no'lu üstün parametre düzeni (ÜPD2) şeklinde verilmektedir. Deneylerdeki iş hatlarında kullanılan KBM

ağının hem eğitimi hem de test aşamasında gizli katmanındaki düğümlerin (birimlerin) sayıları Tablo 1'de verilmiştir. Hem eğitim hem de test aşamalarında KBM üstün parametre düzenlerinden sadece seçilen bir tanesi kullanılmıştır. İlgili sınıflandırıcının iş hattı içerisinde kullanımı sırasında scikit-learn kütüphanesinde sınıflandırıcıya ait varsayılan değerler kullanılmıştır. Sınıflandırıcıların azami adım sayıları veya model ağaç derinlikleri ÜPD1 veya ÜPD2'nin öğrenme adım sayısına uygun olarak belirlenmiştir. Tablo 2'den Tablo 6'ya kadar sırasıyla KBM+LRS, KBM+KA, KBM+GSB, KBM+Ada Boost ve KBM+ROS şeklinde kurulan beş farklı iş hattına ait nesnel deney sonuçları 10 sınıf üzerinden alınan (0 ilâ 9 rakamlarının sınıfları) ortalama ölçüm sonuçları biçiminde başarımlar ölçütleri cinsinden verilmektedir.

Tablo 1. Kısıtlanmış Boltzmann Makinesi için iki farklı üstün parametre düzeni  
(Two different orders of hyper parameters for restricted Boltzmann machine)

Üstün parametre ismi	Üstün parametre düzenleri	
	1 nolu üstün parametre düzeni (ÜPD1)	2 nolu üstün parametre düzeni (ÜPD2)
Öğrenme oranı	0,01	0,06
Öğrenme adım sayısı	40	100
Gizli katmandaki birim sayısı	200	100

Tablo 2. KBM ve LRS kullanan iş hattının başarımlar değerlendirilmesi

(Performance evaluation of pipeline built with restricted Boltzmann machine and logistic regression classifier)

Ölçüt ismi	Başarımlar ölçütleriyle nesnel kıyaslama		
	Tek başına LRS sınıflandırıcı	ÜPD1 kullanan KBM+LRS sınıflandırıcı	ÜPD2 kullanan KBM+LRS sınıflandırıcı
Kesinlik	0,91	0,93	0,96
Anma	0,92	0,93	0,96
F1-skoru	0,92	0,93	0,96
Doğruluk Başarısı	0,9153	0,9332	0,9575

Tablo 3. KBM ve KA kullanan iş hattının başarımlar değerlendirilmesi

(Performance evaluation of pipeline built with restricted Boltzmann machine and decision tree classifier)

Ölçüt ismi	Başarımlar ölçütleriyle nesnel kıyaslama		
	Tek başına KA sınıflandırıcı	ÜPD1 kullanan KBM+KA sınıflandırıcı	ÜPD2 kullanan KBM+KA sınıflandırıcı
Kesinlik	0,88	0,91	0,91
Anma	0,88	0,91	0,91
F1-skoru	0,88	0,91	0,91
Doğruluk Başarısı	0,8753	0,9119	0,9137

Tablo 4. KBM ve GSB kullanan iş hattının başarımlar değerlendirilmesi

(Performance evaluation of pipeline built with restricted Boltzmann machine and Gaussian naïve Bayes classifier)

Ölçüt ismi	Başarımlar ölçütleriyle nesnel kıyaslama		
	Tek başına GSB sınıflandırıcı	ÜPD1 kullanan KBM+GSB sınıflandırıcı	ÜPD2 kullanan KBM+GSB sınıflandırıcı
Kesinlik	0,69	0,85	0,89
Anma	0,55	0,85	0,89
F1-skoru	0,51	0,85	0,89
Doğruluk Başarısı	0,5537	0,8465	0,8896

Tablo 5. KBM ve Ada Boost kullanan iş hattının başarımlar değerlendirilmesi

(Performance evaluation of pipeline built with restricted Boltzmann machine and Ada Boost classifier)

Ölçüt ismi	Başarımlar ölçütleriyle nesnel kıyaslama		
	Tek başına Ada Boost sınıflandırıcı	ÜPD1 kullanan KBM+Ada Boost sınıflandırıcı	ÜPD2 kullanan KBM+Ada Boost sınıflandırıcı
Kesinlik	0,72	0,83	0,77
Anma	0,72	0,83	0,77
F1-skoru	0,71	0,83	0,77
Doğruluk Başarısı	0,7165	0,8333	0,7671

Tablo 6. KBM ve ROS kullanan iş hattının başarımlar değerlendirilmesi

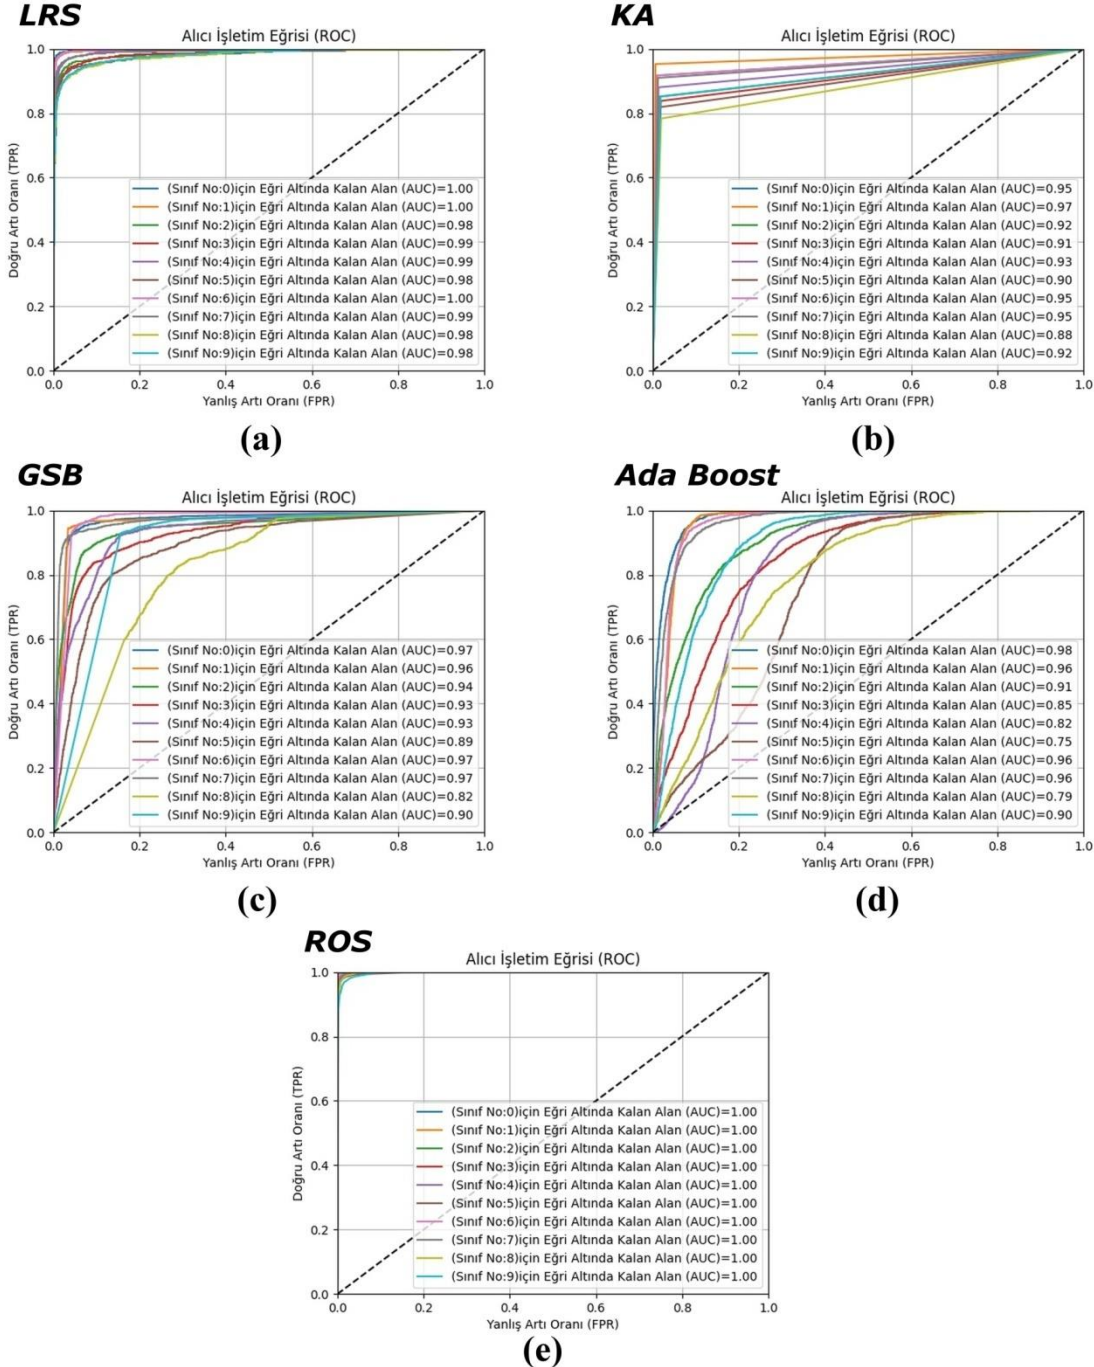
(Performance evaluation of pipeline built with restricted Boltzmann machine and random forest classifier)

Ölçüt ismi	Başarımlar ölçütleriyle nesnel kıyaslama		
	Tek başına ROS sınıflandırıcı	ÜPD1 kullanan KBM+ROS sınıflandırıcı	ÜPD2 kullanan KBM+ROS sınıflandırıcı
Kesinlik	0,97	0,97	0,97
Anma	0,97	0,97	0,97
F1-skoru	0,97	0,97	0,97
Doğruluk Başarısı	0,9689	0,9658	0,9719

Yukarıdaki Tablo 5 haricindeki Tablo 2 ilâ Tablo 6'ya kadar olan diğer tablolardan görüleceği gibi iş hattında kullanılan KBM'nin 2 no'lu üstün parametre düzeni (ÜPD2) sayesinde elde edilen sonuçlar, ilgili iş hattında kullanılan geleneksel sınıflandırıcının (LRS, KA, GSB, ROS) tek başına (iş hattı olmaksızın) elde ettiği sınıflandırma başarımına göre ve iş hattında KBM'nin 1 no'lu üstün parametre düzeni (ÜPD1) kullanıldığında elde edilen başarımlar değerine göre daha iyi sonuçlar vermiştir. Tablo 5'de bunun tersi bir durum söz konusu olmakta, bu sefer ilgili iş hattında kullanılan geleneksel sınıflandırıcının (Ada Boost) tek başına elde ettiği sınıflandırma başarımı KBM'nin 1 no'lu parametre düzeni (ÜPD1) sayesinde daha iyi hale getirilmektedir. Bu bakış açısıyla, bu çalışmanın temel iddiası olan geleneksel sınıflandırıcıların başarımlarının KBM kullanılan bir iş hattıyla daha iyi hale getirilebileceği, KBM'nin ÜPD1 düzeninin veya ÜPD2 düzeninin sinerjik olarak ilgili sınıflandırıcıyla birlikte kullanıldığı iş hattı için yapılan çeşitli deneyler sayesinde, geleneksel sınıflandırıcının tek

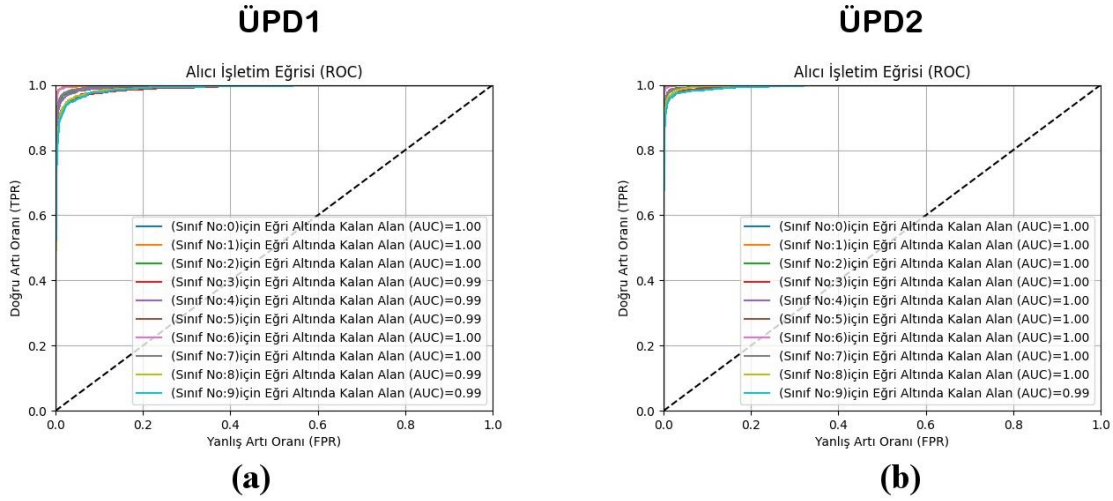
başına elde ettiği başarımına nazaran KBM kullanan iş hattının daha yüksek başarım değerlerine ulaştığı nesnel ölçütlere dayanarak kanıtlanmış olmaktadır. Burada KBM'nin parametrelerinin en iyi duruma getirilmesi ile öznelüklerin daha uygun bir şekilde elde edilmesi ve sınıflandırıcıya bu en uygun sonucun aktarılması rol oynamaktadır. Öznelük elde edici ne kadar iyiyse (başarılysa) sınıflandırıcının işi de o kadar kolaylaşmaktadır. Sınıf etiketlerinin verilen öznelüklerden yeni bir öznelük olarak elde edilmesi en iyi durumda mümkündür, fakat neredeyse mükemmel yakın bir sınıflandırıcı için öznelük elde etmeye bile gerek kalmayabilir, gerçek hayatta bu iki olgu arasında bir

denge vardır [12]. Çalışmamızda KBM modülü öznelük elde edici olarak çalışarak çeşitli sınıflandırıcıların sınıflandırma işini kolaylaştırıp, kurulan iş hattı sayesinde başarımını iyileştirip artırmaktadır. Şekil 2 'de çalışmamızda kullanılan çeşitli sınıflandırıcıların eğitim verisi ile eğitildikten sonra tek başlarına (stand-alone) çalıştırıldıklarında test verisini kullanarak elde ettikleri nesnel başarım sonuçları ROC grafikleri ve AUC değerleriyle verilmektedir. Aşağıdaki Şekil 3'den Şekil 7'ye kadar ilgili grafiklerde, ROC eğrisi grafiği şeklinde ve AUC değerleriyle sunulan sonuçlar test verileri ile yapılan deneyler sonucunda elde edilmiştir.




Şekil 2. Tek başına sınıflandırıcıların başarımlarının ROC ve AUC ile nesnel sonuçları (a) LRS, (b) KA, (c) GSB, (d) Ada Boost, (e) ROS.

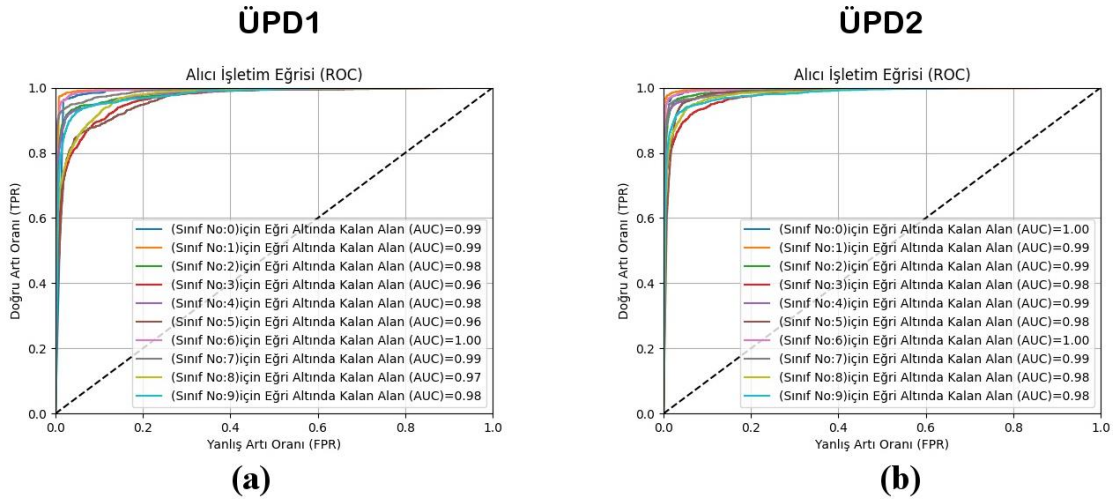
(Objective performance results obtained with ROC and AUC for performance of different stand-alone classifier, (a) logistic regression, (b) decision tree, (c) Gaussian naive Bayes, (d) Ada Boost, (e) random forest classifier)



Şekil 3. KBM ve LRS kullanan iş hattının başarımının ROC ve AUC ile kıyaslama sonuçları (a) ÜPD1, (b) ÜPD2. (Benchmarking results obtained with ROC and AUC for performance of pipeline built with restricted Boltzmann machine and logistic regression classifier, (a) hyper parameters' order#1, (b) hyper parameters' order#2)




Şekil 4. KBM ve KA kullanan iş hattının başarımının ROC ve AUC ile kıyaslama sonuçları (a) ÜPD1, (b) ÜPD2. (Benchmarking results obtained with ROC and AUC for performance of pipeline built with restricted Boltzmann machine and decision tree classifier, (a) hyper parameters' order#1, (b) hyper parameters' order#2)



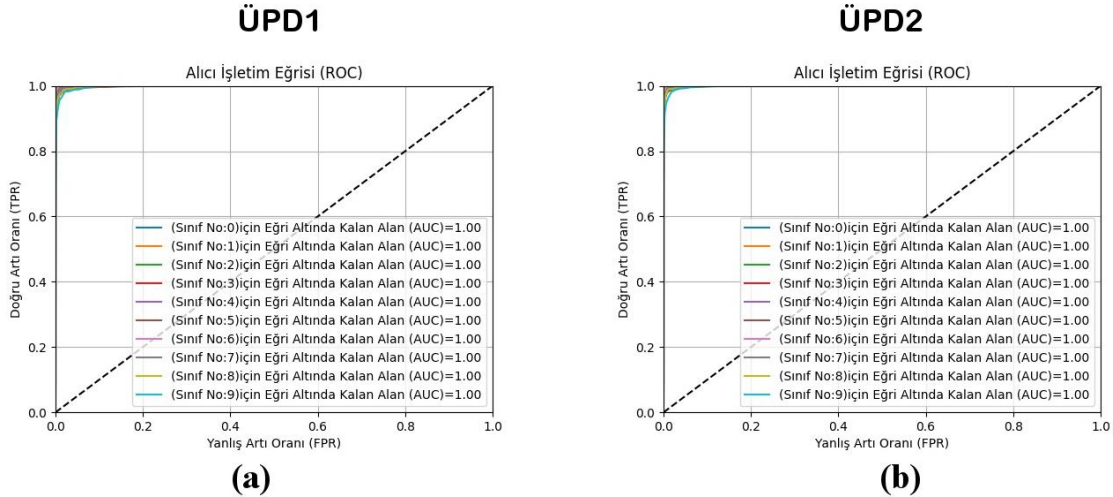
Şekil 5. KBM ve GSB kullanan iş hattının başarımının ROC ve AUC ile kıyaslama sonuçları (a) ÜPD1, (b) ÜPD2. (Benchmarking results obtained with ROC and AUC for performance of pipeline built with restricted Boltzmann machine and Gaussian naive Bayes classifier, (a) hyper parameters' order#1, (b) hyper parameters' order#2)





Şekil 6. KBM ve Ada Boost kullanan iş hattının başarımının ROC ve AUC ile kıyaslama sonuçları (a) ÜPD1, (b) ÜPD2.

(Benchmarking results obtained with ROC and AUC for performance of pipeline builded with restricted Boltzmann machine and Ada Boost classifier, (a) hyper parameters' order#1, (b) hyper parameters' order#2)



Şekil 7. KBM ve ROS kullanan iş hattının başarımının ROC ve AUC ile kıyaslama sonuçları (a) ÜPD1, (b) ÜPD2.

(Benchmarking results obtained with ROC and AUC for performance of pipeline builded with restricted Boltzmann machine and random forest classifier, (a) hyper parameters' order#1, (b) hyper parameters' order#2)

Oluşturulan iş hatları eğitim verileri ile eğitilmiş ve sonrasında test verileri ile iş hattının çalıştırılması yoluyla deney sonunda nesnel ölçüt değerleri (kesinlik, anma, doğruluk başarısı, yanlış artı oranı, doğru artı oranı) hesaplanmıştır. Şekil 6 'daki grafikte 1 no'lu üstün parametre düzenindeki (ÜPD1) KBM'nin, Şekil 3, Şekil 4, Şekil 5 ve Şekil 7'deki grafiklerde ise özellikle 2 no'lu üstün parametre düzenindeki (ÜPD2) KBM'nin iş hattının sınıflandırma doğruluğunu ve AUC değerini iyileştiren yöndeki etkisi gözlemlenmektedir. AUC değeri 1.00 değerine ne kadar yakınsa o kadar doğru bir sınıflandırma yapıldığı anlaşılmaktadır. Aynı bakış açısıyla, grafiklerdeki eğrilerin sol üst köşeye (upper left corner) yaklaşması da oldukça doğru bir sınıflandırmanın ilgili iş hattı kullanımıyla yapıldığını kanıtlamaktadır. Şekillerde özellikle Ada Boost sınıflandırıcının kullanıldığı iş hattının sınıflandırma doğruluk başarımının KBM kullanımıyla diğer sınıflandırıcılara göre dramatik bir

biçimde daha iyi bir iyileştirme sağladığı eğrilerin sol üst köşeye daha çok yaklaşmasından ve AUC değerlerinden görülmektedir. Buna en yakın iyileştirilmiş başarıma sahip ikinci iş hattı ise KBM+GSB bileşiminden oluşan iş hattıdır. Bunu daha iyi ifade etmek için başarımların değerlendirilmesindeki doğruluk başarımlarının verilen 0 ilâ 1 aralığındaki değerleri 0 ilâ 100 aralığına ilgili değerlerin 100 ile çarpılması yoluyla doğrudan dönüştürülmüştür. Yüzdeler oran cinsinden tek başına Ada Boost sınıflandırıcısının Tablo 5'teki doğruluk başarımları değeri %71,65 iken, KBM sayesinde ÜPD1 kullanımıyla %83,33 değerine yükselerek yaklaşık %12 başarımlar iyileştirmesi sağlanmıştır. Ayrıca tek başına GSB sınıflandırıcının başarımları Tablo 4'de doğruluk başarımları olarak %55,37 iken, KBM sayesinde ÜPD2 kullanımı ile yaklaşık %33 başarımlar iyileştirmesi sağlanarak %88,96 değerine ulaşmıştır.

Bu başarıyı iyileştirme sonuçları çalışmamızda önerilen iş hattı tasarımına dayanan modelin oldukça başarılı olduğunu nesnel değerlerle ve grafiklerle açıkça ortaya koymaktadır.

## 5. SONUÇLAR (CONCLUSION)

Özniteliklerin elde edilmesi ve temsili, bu öznitelikleri kullanacak sınıflandırıcının sınıflandırma başarımını doğrudan etkilemektedir. Daha anlamlı bir bilgiye ulaştıracak özniteliklerin büyük hacimli verilerden seçilebilmesi hem hesapsal maliyet hem de karmaşıklık açısından zor bir problemdir. KBM bu zor problemi oldukça makul süre zarfında görece az bir karmaşıklıkla çözebilmektedir. En uygun özniteliklerle oluşturduğumuz iş hattı akışında sınıflandırıcıların bireysel karakteristiklerinin elde edilen sonuçlara etki ettiği gözlemlenmiştir. Özellikle topluluk sınıflandırmasına dayanan Ada Boost sınıflandırıcısında ve olasılıksal altyapısıyla dikkat çeken GSB sınıflandırıcısında bu etki oldukça net bir biçimde sayısal deney sonuçlarından görülmektedir. İş hattında KBM için üstün parametre düzenlerinden 2 no'lu düzeni (ÜPD2) kullandığımızda Ada Boost dışında tüm sınıflandırıcıların başarımı artarken, Ada Boost başarımı 2 no'lu düzen kullanıldığında düşmüştür. Buna rağmen aynı veri kümesiyle tek başına Ada Boost sınıflandırıcısının elde ettiği başarımdan daha iyi bir başarıyı ilgili iş hattıyla (KBM+Ada Boost) elde etmek ancak 1 no'lu düzen (ÜPD1) kullanımı ile mümkün olmuştur. Genel bakışla, KBM'nin farklı sınıflandırıcılarla iş hattında oluşturduğu sinerji sayesinde, birçok geleneksel sınıflandırıcının tek başına olan başarımının iyileştirilmesi yoluyla, KBM'nin 2 no'lu düzeninin (ÜPD2) 1 no'lu düzenine (ÜPD1) göre LRS, KA, GSB ve ROS kullanımında daha avantajlı ve yüksek başarımlı bir iş hattı kurulmasına yol açtığı görülmüştür. Başarım değerlendirmesi yüzdelik oran cinsinden ifade edildiğinde, doğruluk başarıları oranlarının yukarıdaki tablolarda verilen 0 ilâ 1 aralığındaki değerleri 0 ilâ 100 aralığına ilgili değerlerin 100 ile çarpılması yoluyla doğrudan dönüştürülmektedir. Böylece en yüksek doğrulukta bir sınıflandırma deneylerimizde 2 no'lu parametre düzenindeki KBM ve ROS içeren iş hattı ile yüzdelik oran olarak %97,19 doğruluk başarıları ile elde edildiği görülmüştür. Genel olarak başarımlara tablo ve grafiklerden bakıldığında; KBM ve LRS, KBM ve KA, KBM ve GSB, KBM ve Ada Boost, KBM ve ROS içeren farklı iş hatlarıyla ortalama başarımlar açısından %1 ilâ %33 oranında doğruluk başarılarında iyileştirme sağlandığı görülmektedir. Bu değerler sırasıyla, deneydeki herhangi bir iş hattının başarımını gösteren ilgili tablodaki en yüksek ve en düşük doğruluk başarı oranı arasındaki fark alınarak Tablo 6'daki değerler için %1 bulunmuş ve Tablo 4'deki değerler için %33 olarak bulunmuştur. Buna göre, bireysel (tek başına) sınıflandırıcılara göre önerilen iş hattı tasarımıyla elde edilen kombinasyonlarla daha yüksek başarımlı bir sınıflandırma işlemi yapıldığı açıkça ortaya çıkmaktadır.

Sonraki çalışmalarımızda iki bileşenli (modüllü) kombinasyonlar yerine üçlü veya dördü kombinasyonlarla

iş hattı oluşturulması ve farklı üstün parametre düzenlerinin verilen veri kümesine uygun olup olmadığının otomatik biçimde programatik olarak belirlenmesi işlemi denenecektir.

## KAYNAKLAR (REFERENCES)

- [1] D. Ravi, C. Wong, B. Loi, G. Z. Yang, "Deep learning for human activity recognition: A resource efficient implementation on low-power devices", **IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN) 2016**, San Francisco, CA, A.B.D., 71-76, 14-17 Haziran 2016. doi: 10.1109/BSN.2016.7516235.
- [2] A. Geoffrey, E. Hinton, S. Osindero, Y-W. Teh, "A Fast Learning Algorithm for Deep Belief Nets", *Neural Computation*, 18(7), 1527-1554, 2006. doi: 10.1162/neco.2006.18.7.1527.
- [3] N. S. Karakoç, Ş. Karahan, Y. S. Akgül, "Deep learning based estimation of the eye pupil center by using image patch classification", **25th Signal Processing and Communications Applications Conference (SIU) 2017**, Antalya, Türkiye, 1-4, 15-18 Mayıs 2017. doi: 10.1109/SIU.2017.7960457
- [4] M. Zeng, L. T. Nguyen, B. Yu, O. J. Mengshoel, J. Zhu, P. Wu, J. Zhang, "Convolutional Neural Networks for human activity recognition using mobile sensors", **6th International Conference on Mobile Computing, Applications and Services 2014**, Austin, TX, A.B.D., 197-205, 6-7 Kasım 2014. doi: 10.4108/icst.mobica.2014.257786.
- [5] T. Tieleman, "Training Restricted Boltzmann Machines Using Approximations to the Likelihood Gradient", **Proceedings of the 25th international conference on Machine learning (ICML08) 2008**, Helsinki, Finlandiya, 1064-1071, 05-09 Temmuz 2008. doi:10.1145/1390156.1390290.
- [6] Y. Bengio, A. Courville, P. Vincent, "Representation Learning: A Review and New Perspectives", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35(8), 1798-1828, 2013. doi: 10.1109/TPAMI.2013.50.
- [7] Y. Bengio, "Learning Deep Architectures for AI", *Foundations and Trends in Machine Learning*, 2(1), 1-127, 2009. doi: 10.1561/2200000006.
- [8] E. Alpaydın, **Yapay Öğrenme**, Boğaziçi Üniversitesi Yayınevi, 496 sayfa, İstanbul, Türkiye, 2011. ISBN: 978-605-4238-49-1.
- [9] A. Onan, S. Korukoğlu, "Ensemble methods for opinion mining", **23rd Signal Processing and Communications Applications Conference (SIU) 2015**, Malatya, Türkiye, 212-215, 16-19 Mayıs 2015. doi: 10.1109/SIU.2015.7129796.
- [10] Ö. Çokluk, "Lojistik regresyon analizi: kavram ve uygulama", *Educational Sciences: Theory & Practice*, 10(2), 1357-1407, 2010. ISSN: 1303-0485.
- [11] Y. Atakurt, "Lojistik Regresyon Analizi Ve Tıp Alanında Kullanımına İlişkin Bir Uygulama", *Ankara Üniversitesi Tıp Fakültesi Mecmuası*, 52(04), 191-199, 1999. ISSN: 0365-8104.
- [12] C. D. Manning, P. Raghavan, H. Schütze, **Introduction to Information Retrieval**, Draft Online Edition Copy (2009.04.01), Cambridge University Press, New York, NY, A.B.D, 2009. Internet: <http://nlp.stanford.edu/IR-book/pdf/irbookprint.pdf>.(22.12.2017)
- [13] Y. Lecun, L. Bottou, Y. Bengio, P. Haffner, "Gradient-based learning applied to document recognition", **Proceedings of the IEEE 1998**, 86(11), 2278-2324, Kasım 1998. doi: 10.1109/5.726791. Internet: <http://yann.lecun.com/exdb/mnist/>.(22.12.2017)

- [14] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, E. Duchesnay, "Scikit-learn: Machine learning in Python", *Journal of Machine Learning Research (JMLR)*, 12, 2825–2830, Ekim 2011. arXiv:1201.0490.
- [15] L. Buitinck, G. Louppe, M. Blondel, F. Pedregosa, A. Mueller, O. Grisel, V. Niculae, P. Prettenhofer, A. Gramfort, J. Grobler, R. Layton, J. Vanderplas, A. Joly, B. Holt, G. Varoquaux, "API design for machine learning software: experiences from the scikit-learn project", **European Conference on Machine Learning and Principles and Practices of Knowledge Discovery in Databases (ECML PKDD) Workshop (2013): Languages for Data Mining and Machine Learning**, 108-122 arXiv:1309.0238. Internet: <http://scikit-learn.org/>.