

Dempster-Shafer algoritmasının kullanımı ile sınıflandırma algoritmalarının birleştirilmesi

Hüseyin AYGÜN*, Eşref ADALI

İTÜ Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Programı, 34469, Ayazağa, İstanbul

Özet

Sürekli olarak büyümekte olan veri, mevcut istatistiksel yöntemlerin kullanılmasıyla, büyük miktardaki veri içindeki değerli bilginin bulunmasını ve analiz edilmesini imkansız hale getirmektedir. Mevcut analiz araçlarının yetersizliği nedeniyle çok büyük miktardaki veri içindeki değerli fakat saklanmış bilginin bulunup çıkarılması için yeni çözümler bulunmuştur. Bu çözümler veri madenciliği ve veri füzyonudur. Veri madenciliği önceden bilinmeyen, fakat yararlı bilginin büyük miktardaki veri arasından bulunup çıkarılmasıdır. Veri madenciliği, veri içindeki örüntünün keşfedilmesini ve geleceğe ilişkin tahminler yapılmasında kullanılabilecek ilişkilerin çıkarılmasını sağlayan analiz araçlarını kullanır. Veri füzyonu ise farklı sensörlerden gelen bilgilerin birleştirilmesi işlemidir. Veri füzyonu algoritmaları, savunma sektöründe hedef takibi, hedef kimlik tespiti amacıyla istihbarat, keşif ve gözetleme operasyonlarında kullanılmaktadır. Veri madenciliği ve veri füzyonu birbirini tamamlayan prosesler olmasına rağmen, araştırmacılar bu iki alanda birbirinden bağımsız olarak, herhangi bir ilişkiye girmeden çalışmaktadırlar. Sınıflandırmanın etkinliğini artırmak için bu alanlarda kullanılan teknikleri birleştiren çok az sayıda çalışma mevcuttur. Bu çalışmada sınıflandırma sonuçlarını iyileştirmek için yeni bir yöntem önerilmektedir. Söz konusu yöntem Dempster'in Birleştirme Algoritmasını kullanarak, sınıflandırıcıların doğruluğunun da göz önünde bulundurulmasıyla, farklı sınıflandırma algoritmalarından elde edilen sonuçların birleştirilmesinden oluşmaktadır. UCI kütüphanesinden alınan farklı veri takımlarıyla yapılan deneyler sonucunda Dempster'in Birleştirme Algoritmasının kullanımıyla yapılan birleştirme işleminin, birleşimde kullanılan her bir sınıflandırma algoritmasından ve mevcut birleşik algoritmalarından daha doğru sonuçlar verdiği görülmüştür.

Anahtar Kelimeler: Sınıflandırma, Dempster'in birleştirme algoritması, güven derecesi.

*Yazışmaların yapılacağı yazar: Hüseyin AYGÜN. haygun@dho.edu.tr; Tel: (216) 395 26 30.

Bu makale, birinci yazar tarafından İTÜ Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Programı'nda tamamlanmış olan "Combining classification algorithms using Dempster's rule of combination" adlı doktora tezinden hazırlanmıştır. Makale metni 31.10.2005 tarihinde dergiye ulaşmış, 19.01.2006 tarihinde basım kararı alınmıştır. Makale ile ilgili tartışmalar 31.03.2007 tarihine kadar dergiye gönderilmelidir.

Combining classification algorithms using Dempster's rule of combination

Extended abstract

The constantly growing volume of data makes it impossible to analyze and capture the valuable knowledge among large amounts of data using the current statistical methods. Because of the insufficiency of the current analysis tools, new solutions have been found for extracting the valuable but hidden knowledge among huge data. These solutions are data mining and data fusion. Data mining tries to extract implicit, previously unknown, and potentially useful information from large amounts of data. It is a process that uses a variety of data analysis tools to discover patterns and relationships in data that may be used to make valid predictions. Data fusion, on the other hand, is the process of combining information coming from different sensors. Data fusion algorithms are mostly used for target tracking and target identification purposes in intelligence, surveillance and reconnaissance operations in the defense sector. Although data mining and data fusion are two reciprocal processes completing each other, people are generally working on these two areas independently without having any interaction. There are few studies which combine the techniques used in these areas in order to improve the performance of classification. What is missing in most of the studies performed on this issue is uncertainty management. Every classifier has uncertainty to some extent. The second issue regarding the current classification algorithms is the lack of degree of confidence. Degree of confidence is the success that a certain classifier has displayed on similar data sets in the past. A classification algorithm must be able to use degree of confidence in order to give more precise classification results.

Dempster-Shafer's Method, in other words evidence combination rule, has the capability to handle uncertainty. Dempster-Shafer's Method is widely used for combining evidences obtained from different sensory information in the area of data fusion. Dempster-Shafer's Method does not require exact probability values in order to combine evidences. Pieces of information, some being incomplete, obtained from different information sources can be combined using Dempster's Rule of Combination. However, Dempster's Rule of Combination does not include degree of confidence presently.

In our proposed method of combining classification algorithms using Dempster's Rule of Combination, we use degree of confidence during the combination in order to improve the accuracy of the classification. Our proposed combination method using Dempster's Rule of Combination does the following contributions: Employment of degree of confidence during the combination, uncertainty management in combining classifiers and achievement of better classification results. In our proposed method, we first perform classification with different classification algorithms. Assuming the results of the classifiers as beliefs, we calculate mass functions for each classifier. We then combine the mass values in a pairwise fashion using Dempster's Rule of Combination. When there are more than two classifiers to combine, we first combine the first two classifiers and then combine the result of this combination with the third classifier and this process continues until there are no classifiers to combine. We perform different experiments using data sets taken from the UCI machine learning repository. Firstly, we test the success rate of the current classifiers in WEKA using 10 different data sets taken from the UCI machine learning repository. In the experiments we use the default values of the classifiers. We then check the success rate of current hybrid classifiers using the same data sets with the default values. Afterwards we do tests with the proposed method of combining classifiers using Dempster's Rule of Combination employing the same data sets. In the experiments we combine four different classification algorithms selected as representatives for each class of classifiers, in several combinations. In order to be able to make a one-to-one comparison of the proposed method with the current hybrid classification algorithms, we perform experiments with the current hybrid algorithms which has the capability of combining multiple classifiers, using the same data sets. The results of the experiments show that combining classifiers using Dempster's Rule of Combination with the employment of degree of confidence not only performs better than each of the classifiers taking place in the combination but also performs better than the current hybrid classifiers. The results of the experiments also show that the employment of degree of confidence during the combination gives more precise classification results which also decrease uncertainty in the combination.

Keywords: Classification, Dempster's rule of combination, degree of confidence.

Giriş

Sürekli olarak büyümekte olan veri, mevcut istatistiksel yöntemlerin kullanılmasıyla, büyük miktardaki veri içindeki değerli bilginin bulunmasını ve analiz edilmesini imkansız hale getirmektedir. Mevcut analiz araçlarının yetersizliği nedeniyle çok büyük miktardaki veri içindeki değerli fakat saklı bilginin bulunup çıkarılması için yeni çözümler bulunmuştur. Bu çözümler veri madenciliği ve veri füzyonudur.

Veri madenciliği önceden bilinmeyen fakat yararlı bilginin büyük miktardaki veri arasından bulunup çıkarılmasıdır. Veri madenciliği, veri içindeki örüntünün keşfedilmesini ve geleceğe ilişkin tahminler yapılmasında kullanılabilir ilişkilerin çıkarılmasını sağlayan analiz araçlarını kullanır. Örneğin, market analizinde veri madenciliği hedef pazar için aynı özelliklere sahip müşteri gruplarını bulmaya çalışır, müşterilerin zaman içerisindeki satın alma örüntülerini belirler ve ürün satışları arasındaki ilişkileri bulmaya çalışır.

Veri füzyonu ise farklı sensörlerden gelen bilgilerin birleştirilmesi işlemidir. Veri füzyonu algoritmaları, savunma sektöründe hedef tespiti, hedef kimlik tespiti amacıyla istihbarat, keşif ve gözetleme operasyonlarında kullanılmaktadır. White (1987) veri füzyonunun tanımını şu şekilde yapmaktadır: İyileştirilmiş mevki ve kimlik tespiti yapmak, zamanında ve tam durum muhakemesi yapmak amacıyla bir veya birden fazla kaynaktan gelen bilginin ilişkilendirilmesi ve birleştirilmesini içeren bir prosesdir. Proses, iyileştirilmiş sonuçlar elde etmek amacıyla tahmin ve değerlendirmelerinde sürekli olarak düzeltmeler yapar.

Veri madenciliği ve veri füzyonu birbirini tamamlayan prosesler olmasına rağmen (Waltz, 1999), araştırmacılar bu iki alanda birbirinden bağımsız olarak, herhangi bir ilişkiye girmeden çalışmaktadırlar. Performansı artırmak için bu alanlarda kullanılan teknikleri birleştiren çok az sayıda çalışma mevcuttur. Waltz (1999) görüntü verisi, yersel veri, video görüntüleri, istatistiksel veri setleri, anahtar kelimeler içeren tekst verisi içinde gizlenmiş hedeflerin tespiti ve sınıflan-

dırması işlemlerinin iyileştirilmesi için veri madenciliği ve veri füzyonu tekniklerinin birleştirilmesi yollarını araştırmıştır.

Bu çalışmanın ana fikri, sınıflandırma performansının artırılması amacıyla, Dempster'in Birleştirme Algoritmasının kullanılarak farklı sınıflandırma algoritmalarından elde edilen sonuçların birleştirilmesinde, sınıflandırıcıların doğruluğunu da göz önünde bulundurmaktır.

Dempster-Shafer yöntemi

Dempster-Shafer Yöntemi hipotezlere olasılık aralıkları atar. Dempster-Shafer Yönteminin girdileri farklı duyarga raporlarından elde edilen temel olasılık atama fonksiyonlarıdır (bpa). Duyargaların bpa fonksiyonlarını birleştirerek yeni bpa fonksiyonları elde etmek mümkündür. Bpa'lar birleştirildikten sonra hipotezler için olasılık alt ve üst sınırları ([Bel, Pla]) hesaplanır.

Matematiksel olarak ifade edecek olursak, m_1 ve m_2 iki bağımsız duyarga olsun. Θ gözlemlenen durumların kümesi olsun. Bilgi kaynaklarının verdiği bilgiler, Θ 'nın kuvvet kümesi 2^Θ üzerinde tanımlıdır. 2^Θ 'nın herbir elemanına $[0,1]$ aralığında bir sayı karşı getirilsin. Öyle ki, bu sayıların toplamı 1 olmalıdır. Bu işlemin matematiksel ifadesi aşağıdaki şekildedir (Shafer, 1976):

$$m : 2^\Theta \rightarrow [0,1] \quad (1)$$

$$m(\phi) = 0 \quad (2)$$

$$\sum_{A \in \Theta} m(A) = 1 \quad (3)$$

m : bpa fonksiyonu veya olasılık kütle fonksiyonu. Dempster'in Birleştirme Kuralı:

$$m(A) = \frac{\sum_{B \cap C = A} m_1(B) \cdot m_2(C)}{1 - \sum_{B \cap C = \phi} m_1(B) \cdot m_2(C)} \quad (4)$$

m_1 ve m_2 'nin sıfırdan büyük değerlerine *odak elemanları* denir. Kural şu şekilde yorum-

lanabilir: İki bilgi kaynağının zıtlaştığı yani $B \cap C = \emptyset$ olduğu durumlarda, bu bilgiyi destekleyen TOA değerlerinin çarpımı $B \cap C \neq \emptyset$ olanlara dağıtılır.

Bel (Güven), Pla (Olurluk), $A \subset \Theta$ olmak üzere;

$$Bel(A) = \sum_{B \subset A} m(B) \quad (5)$$

$$Pla(A) = \sum_{A \cap B \neq \emptyset} m(B) \quad (6)$$

Bel ve Pla fonksiyonları arasındaki ilişki;

$$Bel(A) \leq Pla(A) \quad (7)$$

Dempster'in Birleştirme Kuralı temel olasılık atama fonksiyonlarını birleştirir ve birleştirilen bilgiyi temsil eden yeni bir olasılık atama fonksiyonu oluşturur.

Dempster'in Birleştirme Kuralı ile temel olasılık atama fonksiyonları birleştirildiğinde (4. denklem), Θ 'nın tüm alt kümeleri için benzerlik vektörleri kullanılarak olasılık kütle fonksiyonları hesaplanır. Daha sonra her bir alt küme için alt ve üst olasılık değerleri hesaplanır. Karar verme işlemi için her bir durumun *bel* değerleri birbiri ile karşılaştırılır. En büyük *bel* değerine sahip durum karar olarak seçilir.

Değerler aynı veya birbirine çok yakınsa hesaplanan *pla* değerleri karşılaştırılır ve en büyük *pla* değerine sahip durum karar olarak seçilir. Bu noktada önemli bir husus, *bel* ve *pla* değerleri arasındaki fark olarak ifade edilen belirsizlik konusudur. Belirsizliğin tanımını, U ile ifade edildiği kabul edilerek, şu şekilde yapılabilir:

$$U = |bel - pla| \quad (8)$$

Buradan belirsizliğin *bel* ve *pla* arasındaki fark ile doğrudan orantılı olduğu anlaşılabilir. Fark küçüldükçe belirsizlik azalır ve fark büyüdükçe belirsizlik artar. Belirsizlik, verilen karardan ne kadar emin olduğumuzun bir göstergesidir.

Sınıflandırma algoritmaları ve önceki çalışmalar

Sınıflandırma işlemi, önceden sınıflandırılmış örneklerin kullanılmasıyla bir model oluşturularak bir veri seti üzerinde sınıflandırma yapılmasını sağlar. Regresyon, karar ağacı, Bayes Sınıflandırması, En Yakın Komşu, Yapay Sinir Ağları gibi pek çok sınıflandırma yaklaşımları mevcuttur. Sınıflandırma yönteminin kullanıldığı alanlar müşteri ayrımı, kredi analizi, finansal marketlerde trend sınıflandırması ve iş modellemesi, tıbbi teşhis ve tedavi gibi alanlardır. Risk seviyeleri (sınıf) verildiğinde, geçmişteki müşterilerin bilgilerine dayanılarak risk modeli üretilebilir ve yeni bir müşteri önceden belirlenmiş bir risk seviyesine atanabilir.

Sınıflandırma algoritmalarının birbirlerine karşı üstünlükleri ve eksiklikleri vardır. Farklı veri setleri üzerinde farklı performans gösterirler. Bazen bir örneği yanlış sınıflandırabilirler veya hiç sınıflandıramayabilirler.

Sınıflandırma sonuçlarının iyileştirilmesi için farklı sınıflandırıcıların sonuçları birleştirilebilir. Wachowicz ve Carvalho (2000)'nin çalışmalarında çevre bilgi sistemi otomasyonu amacıyla veri füzyonu ve veri madenciliği teknikleri birleştirilmektedir. Sınıf seviyesi füzyon/madencilikten elde edilen bilgi karar ağacı sınıflandırma işleminin girdisi olarak kullanılmaktadır. Wachowicz ve Carvalho (2000)'nin çalışması, üretilen bilginin ormanla kaplı alanların haritalarının çıkarılması amacıyla nasıl kullanılabilirceğini göstermektedir.

Mahajani ve Aslandogan (2003)'in çalışmasında Dempster-Shafer teorisi tıp verisinin birleştirilmesi amacıyla kullanılmıştır. K-Komşu (kNN), Naive Bayes ve Karar Ağacı algoritmaları Dempster'in Birleştirme algoritması ile birleştirilmiştir. Sınıflandırıcı sonuçlarının birleştirilmesinden elde edilen iyileştirme %0.1 ile %1.1 arasındadır.

Wu ve diğerleri (2002) "Ağırlıklı Dempster-Shafer kanıt birleştirme kuralı" kullanmışlardır. Onların yaklaşımında birleştirme sırasında duyarların ağırlıkları kullanılmıştır.

Basak ve diğerleri (2004)'nin çalışmasında Dempster-Shafer çatısı altında çelişen bilgilerin ağırlıklı birleştirilmesi incelenmiş ve değiştirilen kuralın bazı özellikleri verilmiştir.

Önerilen yöntem

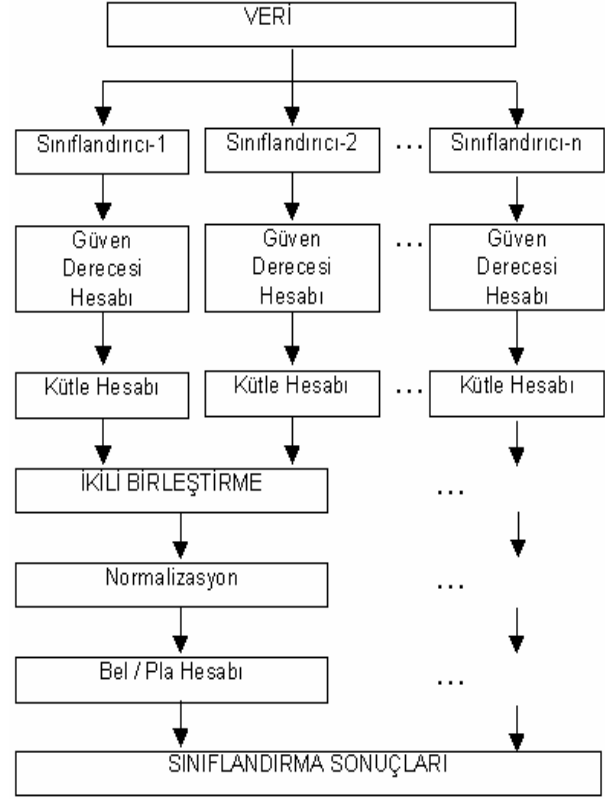
Bu çalışmada farklı sınıflandırma algoritmalarından elde edilen sonuçların, Dempster'in Birleştirme Algoritması ile birleştirilmesinde, sınıflandırıcıların doğruluğunu da göz önünde bulundurulmuş bir yöntem önerilmektedir.

Güven derecesi ya da güven faktörü bir sınıflandırma algoritmasının benzer veri takımı üzerinde geçmişte gösterdiği başarı oranıdır. Sınıflandırıcıların güven faktörünü dikkate alarak sınıflandırıcılardan elde edilen *bel* değerlerini kullanarak yeni *bel* değerleri elde edebiliriz. Matematiksel olarak ifade etmek gerekirse; \mathcal{L} 'nin benzerlik vektörü olduğunu, C 'nin güven faktörü olduğunu kabul edersek yeni benzerlik vektörü $\mathcal{L}_{\text{yeni}}$ şu şekilde olur:

$$\mathcal{L}_{\text{yeni}} [a_{1,j}] = \mathcal{L}[a_{1,j}] * C \quad (9)$$

Önerilen yöntemde, önce farklı sınıflandırma algoritmaları ile sınıflandırma yapılır. Daha sonra her bir sınıflandırıcının güven derecesi hesaplanır. Ardından her bir sınıflandırıcı için *bel* değerlerinden olasılık kütle fonksiyonları hesaplanır. Olasılık kütle değerleri çiftler çiftler Dempster'in Birleştirme Kuralı ile birleştirilir. Sonunda yeni *bel* ve *pla* değerleri hesaplanır. Önerilen yöntemin akış diyagramı Şekil 1'de verilmiştir.

Bu çalışmada deneylerde UCI kütüphanesinde yer alan veri setlerinden 10 tanesi kullanılmıştır. Seçilen dört sınıflandırma algoritması (Naïve Bayes, IB1, J48, OneR) önerilen yöntemle çeşitli kombinasyonlarda birleştirilerek veri takımları üzerinde deneyler yapılmıştır. Yapılan deneyler sonucunda Dempster'in Birleştirme Algoritması kullanılarak yapılan birleştirme yönteminin, kullanılan veri setleri üzerinde mevcut basit ve bileşik algoritmalarından daha başarılı sonuçlar verdiği görülmüştür.



Şekil 1. Sınıflandırıcıların Dempster Birleştirme Kuralı ile birleştirilmesi

Deneyler

Deneylerde UCI kütüphanesinden (Witten ve Frank, 2000; Murphy ve Alia 1994) alınan veri setleri kullanılarak sınıflandırma işlemi yapılmıştır. Deneylerde kullanılan veri setleri Tablo 1'de verilmiştir.

Tablo 1. Deneylerde kullanılan veri

Veri	Kayıt Sayı- Nitelik	
	sı	Sayısı
Otomobil	205	26
Göğüs kanseri-Wisconsin	699	11
Göğüs kanseri-Cleveland	303	14
Göğüs kanseri-Hungary	294	14
Hepatit	155	20
Göz ağ tabakası	150	5
İş görüşmesi	57	17
Soya fasulyesi	683	36
Tiroid	215	6
Şarap	178	14

Deneylede WEKA sınıflandırma metotları (Witten ve Frank, 2000) kullanılmıştır. WEKA sınıflandırıcılarının kullandığımız veri setleri üzerindeki başarısı Tablo 2’de yer almaktadır. Tabloda görüldüğü gibi Naïve Bayes en iyi ortalama başarıya sahip algoritmadır ve en iyi başarıyı göğüs kanseri verisi üzerinde göstermektedir. IB1 en iyi başarıyı tiroid verisi üzerinde, j48 iris verisi üzerinde ve OneR da aynı şekilde iris verisi üzerinde göstermiştir.

Tablo 2. WEKA Sınıflandırıcılarının UCI veri setlerindeki başarısı

Veri	Naïve			
	Bayes	IB1	J48	OneR
Otomobil	79.51	94.15	89.75	83.41
Göğüs kanseri-Wis.	97.42	95.00	94.85	92.70
Göğüs kanseri -Cle.	56.43	54.45	52.47	52.47
Göğüs kanseri-Hun.	85.35	59.18	78.57	78.91
Hepatit	70.32	66.45	58.70	61.93
Göz ağ tabakası	96.00	95.33	96.00	94.00
İş görüşmesi	89.47	82.45	73.68	75.43
Soya fasulyesi	92.97	89.89	91.50	39.97
Tiroid	96.74	97.20	92.09	91.16
Şarap	96.62	94.94	93.82	76.40
Ortalama	86.08	82.90	82.14	74.63

WEKA’da mevcut bileşik sınıflandırma algoritmalarının bazılarının UCI veri takımları üzerindeki ortalama başarıları Tablo 3’te yer almaktadır. Deneylede, birden fazla sınıflandırma algoritmasını birleştirme yeteneğine sahip bu bileşik algoritmaların seçilmesinin sebebi, önerdiğimiz Dempster-Shafer birleştirme yöntemiyle birebir karşılaştırma yapabileme olanağını sağlamasıdır.

Tablo 3. WEKA bileşik sınıflandırıcılarının UCI veri setlerindeki ortalama başarısı

	Naïve		Naïve		IB1	IB1	J48
	Bayes	Naïve	Bayes	IB1			
	+	Bayes	+	+	+	+	
	IB1	+ J48	OneR	J48	OneR	OneR	
Derecelend.	89.73	91.39	90.17	88.38	87.58	89.05	
Çoklu Şema	89.86	91.04	90.02	89.57	89.57	87.91	
Yığınlama	90.33	91.61	89.78	83.14	78.38	87.66	
Oylama	89.54	91.39	77.90	89.60	84.96	81.86	

Dempster’in Birleştirme Algoritması kullanılarak dört farklı sınıflandırma algoritmalarından elde edilen kanıtlar altı farklı şekilde birleştirilmiştir. Birleştirme sonuçlarının WEKA’da mevcut bileşik sınıflandırma algoritmaları ile karşılaştırması Tablo 4’te yer almaktadır.

Tablo 4. Önerilen yöntemin WEKA bileşik sınıflandırıcıları ile karşılaştırılması

	Naïve		Naïve		Naïve	
	Bayes	Bayes	Bayes	IB1	IB1	J48
	+	+	+	+	+	+
	IB1	J48	OneR	J48	OneR	OneR
Dempster Bir. K.	95.73	94.13	92.30	93.20	92.44	89.21
Derecelendirme	89.73	91.39	90.17	88.38	87.58	89.05
Çoklu Şema	89.86	91.04	90.02	89.57	89.57	87.91
Yığınlama	90.33	91.61	89.78	83.14	78.38	87.66
Oylama	89.54	91.39	77.90	89.60	84.96	81.86

Tablo 4’te görüldüğü gibi Dempster’in Birleştirme Algoritmasının kullanılmasıyla sınıflandırıcı sonuçlarının birleştirilmesinden oluşan yöntem, verilen veri takımları üzerinde, ortalama olarak, WEKA’da mevcut bileşik algoritmalarından daha başarılıdır.

Sonuçlar

Bu çalışmada farklı sınıflandırma algoritmalarından elde edilen sonuçların, Dempster’in Birleştirme Algoritması ile birleştirilmesinde, sınıflandırıcıların doğruluğunu da göz önünde bulundurulmuş bir yöntem önerilmektedir. Dört temel sınıflandırma algoritması farklı kombinasyonlarda birleştirilerek on farklı veri takımı üzerinde deneyler yapılmıştır. Yapılan deneyler, önerilen yöntemin, ortalama olarak mevcut basit ve bileşik sınıflandırma algoritmalarından %5-15 arasında daha iyi sonuçlar verdiğini göstermektedir.

Kaynaklar

- Basak J., Goyal Z. ve Kothari R., (2004). A modified Dempster’s rule of combination for weighted sources of evidence, IBM Research Report, IBM Research Division, IBM India Research Lab, New Delhi.
- Mahajani, G. A. ve Aslandogan Y. A., (2003). Evidence Combination in medical data mining,

- Technical Report CSE-2003-23, Department of Computer Science and Engineering, University of Texas at Arlington.
- Shafer, G., (1976). *A Mathematical Theory of Evidence*, Princeton University Press, New Jersey.
- Wachowicz M. ve Carvalho L.,M.,T., (2000). Data fusion and mining for the automation of a space-time reasoning process, 22nd EARSel Symposium, Prague.
- Waltz E., (1999). Information understanding: Integrating data fusion and data mining processes, in workshop along with IEEE 1999 International Symposium on Circuits and Systems, Monterey, CA.
- White, Jr., F.E., (1987). Data fusion lexicon, joint directors of laboratories, Technical Panel for C3, Data Fusion Sub-Panel, Naval Ocean Systems Center, San Diego.
- Witten I.,H. ve Frank E., (2000). *Data Mining: Practical machine learning tools with Java implementations*, Morgan Kaufmann, San Francisco.
- Wu H., Siegel M., Stiefelhagen R. ve Yang J., (2002). Sensor fusion using Dempster-Shafer Theory, IEEE Instrumentation and Measurement Technology Conference, Anchorage, AK, USA.
-
- Murphy, P. M. ve Alia, D. W., (1994). UCI repository of machine learning databases (machine-readable data repository – <http://www.ics.uci.edu/~mlearn/MLRepos.html>). University of California.-Irvine, Department of Information and Computer Science.