

Derin Yapay Sinir Ağları Kullanan Dinamik Bulanık Bilişsel Haritalarla Çoklu Görüde Nesne Takibi

Turan Göktuğ ALTUNDOĞAN^{1*}, Mehmet KARAKÖSE²

¹ Bilgisayar Mühendisliği, Mühendislik Fakültesi, Manisa Celal Bayar Üniversitesi, Manisa, Türkiye

² Bilgisayar Mühendisliği, Mühendislik Fakültesi, Fırat Üniversitesi, Elazığ, Türkiye

*¹ turan.altundogan@cbu.edu.tr, ² mkarakose@firat.edu.tr

(Geliş/Received: 19/01/2021;

Kabul/Accepted:22/04/2021)

Öz: Çoklu görüde nesne takibi, birden fazla görüntüleme aygıtının kullanıldığı görüntüleme sistemlerinde tek bir görüntüleme aygıtından elde edilen görüntü kareleri üzerinde tespit edilen nesnelere diğer görüntüleme aygıtlarından gelen görüntü kareleri üzerinde de bulunduğu yerin hesaplanmasına dayalı nesne takip işlemidir. Burada bahsi geçen problemin çözümü için genelde görüntüleme sistemi içerisinde bulunan farklı kamera konum ve oryantasyonların içerisinde kullanıldığı hesaplama metodlarından yararlanılmaktadır. Makine öğrenmesi ve yapay zeka tabanlı yöntemlerin bilgisayarlı görü alanında problemlerin çözme kabiliyetinin artmasıyla beraber ÇGNT işlemini gerçekleştirmek için farklı yapay zeka ve makine öğrenmesi tabanlı yöntemlerden yararlanılabilmektedir. Bu çalışmada ÇGNT için bulanık bilişsel haritalardan yararlanan yeni bir yöntem geliştirilmiştir. Bulanık bilişsel haritalar, ele aldığı gerçek dünya sistem veya problemlerine ait özellikleri konsept olarak kabul eder. Daha sonra bu konseptler arasındaki ilişkileri kullanarak iteratif bir şekilde modelleme veya hesaplama işlemini gerçekleştirir. Günümüzde endüstri, sağlık, enerji, bilgisayar bilimi vs. gibi birçok alanda problemlerin çözümünde BBH'lar kullanılmaktadır. Bulanık bilişsel haritaların literatürde bilgisayar bilimi alanında sağladığı çözüm önerileri için daha dinamik bir yapıya ihtiyaç duyulmuştur. Bu çalışmada çoklu görüde nesne takibi işlemi için geliştirdiğimiz bulanık bilişsel harita yapısında konsept ilişkilerinin dinamik bir şekilde güncellenmesi için derin yapay sinir ağlarından yararlanılmıştır. Deneysel sonuçların analizi farklı başarımlar hesaplama işlemleriyle gerçekleştirilmiştir. ÇGNT odaklı yöntemlerin başarımlarını hesaplamada kullanılan Birleşim Kesişimi (Intersection of Union) yöntemi ile yapılan analizlerde minimum %67,4 maksimum %99,8 ve ortalama %88,2 başarımlar elde edildiği gözlemlenmiştir. Ele alınan problem için hesaplanan kesişim oranı literatür çalışmaları incelendiğinde çok yüksek bir başarıma sahiptir.

Anahtar kelimeler: Çoklu Görüde Nesne Takibi, Dinamik Bulanık Bilişsel Haritalar, Derin Yapay Sinir Ağları, Genetik Algoritma

Multi-View Object Tracking with Dynamic Fuzzy Cognitive Maps Using Deep Neural Networks

Abstract: Multi-view object tracking is an object tracking process based on calculating the location of the detected objects on the image frames obtained from a single imaging device in imaging systems where more than one imaging device is used, also on the image frames from other imaging devices. In order to solve the problem mentioned here, calculation methods in which different camera positions and orientations are generally used in the imaging system are used. With the increase in the ability of machine learning and artificial intelligence-based methods to solve problems in the field of computer vision, different artificial intelligence and machine learning-based methods can be used to perform the MVOT process. In this study, a new method using fuzzy cognitive maps has been developed for MVOT. Fuzzy cognitive maps are graph-based structures that take the features of real world systems or problems they deal with as a concept and perform the modeling or computation process iteratively using the relationships between these concepts. Today industry, health, energy, computer science etc. FCMs are used to solve problems in many areas such as. A more dynamic structure was needed for the proposed methods provided by fuzzy cognitive maps in the field of computer science in the literature. In this study, deep artificial neural networks were used to dynamically update the concept relations in the fuzzy cognitive map structure we developed for multi-view object tracking. The analysis of the experimental results was carried out with different performance calculations. In the analysis performed with the Intersection over Union method, which is used in the performance calculation of the MVOT-focused methods, it was observed that a minimum performance of 67.4%, maximum 99.8% and an average of 88.2% was achieved. When the literature studies are examined, the intersection rate calculated for the problem under consideration has a very high success.

Key words: Multi View Object Tracking, Dynamic Fuzzy Cognitive Maps, Deep Neural Networks, Genetic Algorithm

* Sorumlu yazar: fenbilimleri@firat.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-8677-3105, ² 0000-0002-3276-3788

1. Giriş

Bilgisayarlı görü, görüntüleme aygıtları (kamaralar) vasıtasıyla elde edilen görüntüler üzerinde sinyal-görüntü işleme, görüntü analizi, istatistiksel metotlar, makine öğrenmesi ve yapay zeka yöntemlerinden yararlanılarak ilgili görüntü üzerindeki nesnelere, canlılar vs. üzerinde bilgi elde etmeye odaklanmış bilgisayar bilimi alanıdır. Bilgisayarlı görü teknikleri ile nesne takibi, insana ait farklı biyometrik bilgilerinin elde edilmesi, sınıflandırma, görüntü restorasyonu ve iyileştirilmesi, nesne sayma işlemleri, anomali tespiti ve analizi vs. gibi çeşitli problemlerin çözümü sağlanmaktadır.

Bu çalışmada Bilgisayarlı Görü alanında oldukça sık odaklanılan bir problem olan çoklu görüde nesne takibi (ÇGNT) üzerinde durulmuştur. Farklı görüntüleme aygıtlarından alınan görüntüler üzerindeki nesnelere aynı zamanda kaydedilmiş görüntü kareleri için eşleştirilmesi çoklu görüde nesne takibi olarak adlandırılmaktadır. Burada ele alınan problemin daha iyi anlaşılması için aynı anda birçok kamera ile görüntülenen bir stadyum örneğini ele alalım. Bilindiği üzere futbol müsabakalarında futbolculara ait kat edilen mesafe, oyunun hangi bölgede daha çok yoğunlaştığı, hakem kararlarının analizleriyle alakalı farklı uygulamalar farklı kameralardan elde edilen görüntüler üzerinde uygulanmaktadır.

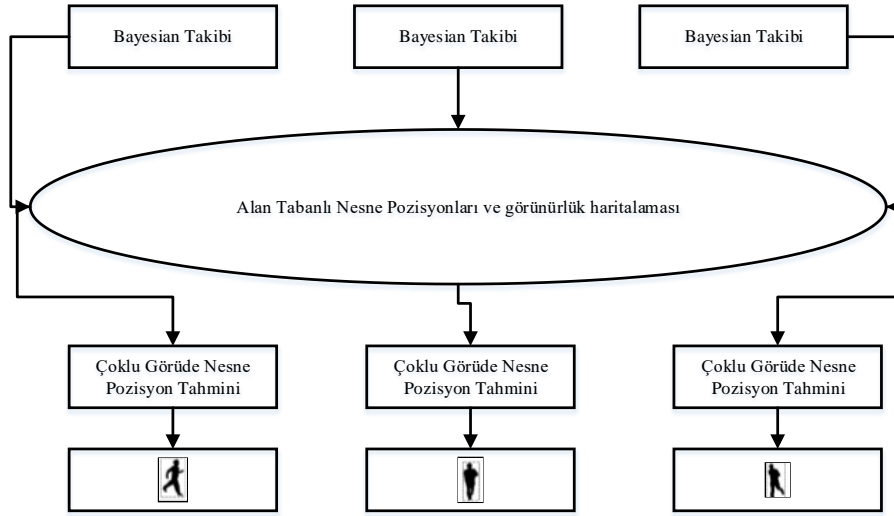
Şimdi aynı anda 8 adet kamerayla görüntülenen bir futbol müsabakası ve burada gerçekleştirdiğimiz bilgisayarlı görme uygulamasının da bu sekiz kamerayla elde edilen görüntüler üzerinde futbol topunun takibi olduğunu var sayalım. Burada futbol topunun tespit ve takip işleminin her görüntü karesi için ayrı ayrı yapılması 8 kat algoritmik maliyeti ifade etmektedir. Oysa ki takip ve tespit işleminin tek bir görüntü karesi üzerinden yapıp tespit edilen nesnenin diğer görüntü kareleri üzerindeki konumlarının hesaplanması daha az algoritmik maliyete sahip bir yöntem olabilir.

ÇGNT üzerine odaklanmış bir çok literatür çalışması bulunmaktadır. Bir çalışmada W. Chen ve arkadaşları çoklu kamera ile kaydedilmiş görüntüler üzerinde nesne takibi işlemini gerçekleştirmişlerdir [1]. Burada yazarlar, çoklu kamera içeren nesne takip uygulamalarında, kullanılan yöntemlerin genellikle kameralardan biri tarafından çekilmiş referans görüntü dizisi üzerindeki nesne takibi ve diğer görüntü dizilerindeki takip işleminin de bu işleme bağımlılığından kaynaklı olumsuzlukları gidermeye odaklanmıştır. Yani araştırmacılar, referans görüntü üzerinde yapılan nesne tespit ve takip işleminin düşük performanslı olması durumunda, çoklu kamerada nesne takibi işlemini iyileştirmek için yeni bir bakış açısı geliştirmişlerdir. Bilgisayar bilimlerinde, eşleşme problemlerini çözmekte oldukça sık kullanılan Macar algoritması tabanlı bir bakış açısı geliştiren araştırmacılar, geliştirdikleri yöntemi mevcut yöntemlerle kıyaslayarak çoklu kamerada takip işlemini daha başarılı bir şekilde gerçekleştirdiklerini ifade etmişlerdir.

Başka bir çalışmada, Parisa J. vd., kalman filtresi tabanlı bir yöntemle çoklu görüde nesne takibi işleminin gerçekleştirilmesine odaklanmıştır [2]. Burada ilk olarak bütün görüntüleme aygıtları ile çekilmiş görüntülere arka plan çıkarımı işlemi uygulanarak görüntü farklarını elde etmişlerdir. Daha sonra hizalama (homografi) kısıtı bulunan çoklu görü sistemleri için her görünümde tespit edilen nesnelere referans görüntüye bağlı bir hiza ile eşleştirilecektir. Daha sonra referans görüde olan görüntü karelerinden, grafik kesimi segmentasyonu ile ikili skalada görüntüler elde edilecektir. Bu şekilde kesişme noktalarının pozisyonunu referans görüntü içerisindeki diğer noktalardan ayırmaktadır. Araştırmacılar bu adımla, görüntüden kaynaklanan eksik algılamaları azaltmayı hedeflemişlerdir. Takip işlemi için de nesnelere ortalama konumlarından yararlanılmıştır. Kalman filtresi ile nesne konumunun herhangi bir zamanda optimum tahmini sağlanmaktadır. Araştırmacılar, deneysel sonuçlarla %94.8'lik bir başarımla çoklu görüde nesne takibi işlemini gerçekleştirdiklerini göstermişlerdir.

Başka bir çalışmada, Yixiao Y. vd., çoklu görüde nesne takibi işlemini farklı bir bakış açısıyla ele almışlardır [3]. Araştırmacılar öncelikle her görü için ayrı ayrı nesne takibi işlemini gerçekleştirip daha sonra buradaki nesnelere farklı görüdeki görüntü karelerindekiyle eşleştirmişlerdir. Bunun için epipolar kısıtlamalardan yararlanan araştırmacılar, her görünüm için bölge kovaryanslarını bularak nesne görünümünün referans bir modelini elde etmişlerdir ve takip edilen nesnelere hem tahmini konumlarını hem de görünüşlerini, farklı görülerde kaydedilmiş görüntü kareleri üzerinde haritalamışlardır. Şekil 1'de literatür çalışmasında önerilen yöntemin blok diyagramına yer verilmiştir.

Başka bir çalışmada, Chen Z. vd., çoklu kamerayla bir ağ sistemi üzerinden nesne tespiti ve takibi işlemlerine odaklanmıştır [4]. Burada ele alınan nesne tipi yayalar ve araçlardır. Nesne tespiti işlemi için arkaplan modellemesi ve çıkarımına dayalı bir yöntem geliştirmişlerdir. Burada, tespit işlemi tek bir kameradan alınmış görüntü üzerinden yapılmakta ve çoklu kamera ağındaki, her nesnenin özellikleri ve yörüngelerinin eşleştirmeleri için kamera oryantasyonuna bağlı bir yöntem kullanılmaktadır. Yapılan çalışma sonucunda, yazarlar bir şehirdeki farklı bölgelerde, tekli ve çoklu görüde takip işlemlerini başarılı bir şekilde yaptıklarını ifade etmektedirler.



Şekil 1. Literatür çalışmasında önerilen yöntemin blok diyagramı [3].

Başka bir çalışmada, Chen Z. vd., çoklu kameralı bir ağ sistemi üzerinden nesne tespiti ve takibi işlemlerine odaklanmıştır[4]. Burada ele alınan nesne tipi yayalar ve araçlardır. Nesne tespiti işlemi için arkaplan modellemesi ve çıkarımına dayalı bir yöntem geliştirmişlerdir. Burada, tespit işlemi tek bir kameradan alınmış görüntü üzerinden yapılmakta ve çoklu kamera ağındaki, her nesnenin özellikleri ve yörüngelerinin eşleştirmeleri için kamera oryantasyonuna bağlı bir yöntem kullanılmaktadır. Yapılan çalışma sonucunda, yazarlar bir şehirdeki farklı bölgelerde, tekli ve çoklu görüde takip işlemlerini başarılı bir şekilde yaptıklarını ifade etmektedirler.

Başka bir çalışmada Li H. vd., gelişmiş derin öğrenme ve dağıtılmış bilgi füzyonunu birleştirerek tıkanma ve yeniden yapılandırma sorunlarını etkili bir şekilde çözebilen, dağıtılmış bir kamera ağı kullanan çok hedefli bir izleme yöntemi önermişlerdir [5]. Bahsi geçen çalışmada hedefler ilk olarak derin öğrenmeye dayalı hızlı bir nesne algılama yöntemi kullanılarak tespit edilir. Daha sonra, güçlü hedef ilişkilendirmesi için Macar algoritmasında derin görsel özellik bilgilerini ve mekansal yörünge bilgilerini birleştirilir. Derin görsel özellik bilgisi, büyük ölçekli bir kişi yeniden tanımlama veri kümesi kullanılarak önceden eğitilmiş bir evrişimli sinir ağından çıkarılır. Çerçevelediği birden çok hedefin uzamsal yörüngeleri, füzyon ve izleme için bilgi ağırlıklı bir fikir birliği filtresi kullanan çok görüntülü bir bilgi füzyon yönteminden türetilmiştir. Ek olarak, çoklu görünüm bilgilerini kullanarak kimlik ataması için verimli bir takip işleme yöntemi de önerilmektedir. Önerilen yöntem herkese açık ve çevrimiçi elde edilmiş veri setleri üzerinde test edilmiştir ve yazarlara göre geliştirilen yöntem oldukça başarılıdır. Literatür çalışmaları incelendiğinde ÇGNT odaklı çalışmalarda makine öğrenmesi ve yapay zeka tabanlı yöntemler sıklıkla kullanılmaktadır. Buna ek olarak ÇGNT odaklı çalışmaların bilhassa akıllı şehir ve akıllı ulaşım teknolojik trendleri için oldukça geniş bir uygulama alanına sahip olduğu görülmektedir. Literatürdeki ÇGNT uygulamalarında kullanılan teknikler incelendiğinde makine öğrenme yöntemlerine ek olarak kamera oryantasyonuna ve nesne takibi işleminin bir eşleştirme (matching) problemi olarak ele alınıp Macar Algoritması (Hungarian Algorithm) gibi bilgisayar bilimlerinde eşleştirme problemlerinin çözümünde sıklıkla kullanılan yöntemlere dayalı çözümlerden yararlandığı görülmektedir. Bize göre ÇGNT işleminin bir eşleştirme problemi olarak kabul edilmesi algoritmik maliyetlere sebep olmaktadır. Çünkü bu probleme eşleştirme bakış açısıyla yaklaşabilmek için bütün görüntü dizilerinde takip edilmesi gereken nesnelerin yeniden tespit edilmesi gerekmektedir.

Literatürde çoklu görüde nesne takibi uygulamalarına odaklanmış çalışmalar Tablo 1'de özetlenmiştir. Literatür çalışmaları incelendiğinde bazı çalışmaların kamera oryantasyonu ve / veya uzay zamansal özellikler kullandığı görülmektedir. Bazı çalışmalarda ise hespsal zeka yöntemlerinden yararlanılmıştır.

Ayrıca önerilen yöntemin daha iyi anlaşılması için ikinci bölümde bulanık bilişsel haritalar ve bulanık bilişsel haritalara odaklanmış çalışmalar detaylı bir şekilde açıklanmıştır. Üçüncü bölümde önerilen yöntem mantıksal adımlara ayrılarak her mantıksal adım detaylı bir şekilde açıklanmıştır. Dördüncü bölümde deneysel sonuçlara yer verilmiştir. Burada hem görüntü kareleri üzerinde takibi gerçekleştirilen nesnelerin sınır kutu pozisyonlarına ve bunların görselleştirilmiş hallerine hem de önerilen yöntemin kullandığı başarımlı hesaplama yöntemleri detaylı bir şekilde açıklanmıştır. Ayrıca BBH inşasının her bir adımına ait sonuçlar da yine bu bölümde detaylı bir şekilde verilmiştir. Beşinci bölümde deneysel sonuçlar yorumlanarak önerilen yöntemin sağladığı problemin çözümünde sağladığı katkı ve avantajlardan bahsedilmiştir.


Tablo 1. Literatürdeki ÇGNT odaklı çalışmalarda kullanılan yöntemler.

Referans Numarası	Kullanılan Yöntem
[1]	Macar algoritması
[2]	Kalman Filtreleri ve graflar.
[3]	Homografi ve epipolar kısıtlamalar.
[4]	Kamera oryantasyonu.
[5]	Derin öğrenme
[6]	Konvolüsyonel Yapay Sinir Ağları ve uzaklık matrisleri.
[7]	Ağaç görselleştirme.
[8]	Bayesian filtreleme
[9]	Uzay-Zamansal Özellikler
[11]	YOLO ile Nesne Tespiti, Zaman ve Yer Özelliklerine Göre Nesne Etiketleme
[12]	Literatür İnceleme Çalışması

2. Bulanık Bilişsel Haritalar

Bulanık bilişsel haritalar, hem insan mantığına hem de buna karşılık gelen insan karar verme sürecine oldukça benzer olduğu düşünülen bir yaklaşımı takiben yumuşak bir hesaplama tekniğini içeren yapıya denilmektedir. Gösterimleri temelde çizge teorisine dayanmaktadır. BBH'lerle ifade edilecek bir sistem veya probleme ait özelliklerin her biri bir konsept olarak kabul edilir.

Bu özellikler arasındaki ilişkiler ise ağırlıklandırılmış komşuluklar ile ifade edilir. Bilişsel harita kavramı ilk olarak 1948 yılında Edward Tollman tarafından ortaya atılmıştır. Bulanık küme kavramı ise 1965 yılında L. A. Zadeh tarafından ortaya atılmıştır. Bulanık bilişsel harita kavramı 1986 yılında Bart Kosko tarafından kullanılmıştır. Şekil 2'de yedi düğümlü bir BBH yapısına yer verilmiştir.



Şekil 2. Yedi düğümlü bir BBH örneği.

BBH'lar $F(C,W)$ ile gösterilir. Burada;

- $C_i \rightarrow$ BBH'ya ait i . düğümü,
- $W_{ij} \rightarrow$ BBH'ya ait i ve j . düğüm arasındaki komşuluk ağırlığını ifade etmektedir.
- $W_{ij} \rightarrow [-1,1]$ aralığındaki değerlere sahip olabilir.

BBH iteratif bir yapıya sahiptir. Her bir iterasyondaki düğüm güncelleme işlemi aşağıdaki gibidir.

$$C_i^t = C_i + \sum_{j=1}^n (C_j W_{ji}) \quad (1)$$

BBH ile bir sistem modellenirken, sisteme ait özellikler konseptlerle, bu konseptler arasındaki ilişkiler ise ağırlıklarla ifade edilir. Sisteme ait konseptler belirlendikten sonra, konseptler arası ilişkiler gözetimsiz öğrenme yöntemleri, uzman görüşleri veya sisteme ait bir veri setinin işlenmesi sonucunda belirlenebilir. Sisteme ait konsept ve konseptler arası ilişkilerin belirlenmesinin ardından iteratif bir yapı olan BBH için kararlı durum kriteri ve aktivasyon fonksiyonu belirlenmelidir.

Bütün bu işlemlerin ardından bir sistemi modelleyen BBH inşası tamamlanmış olur. Daha sonra, alınan başlangıç konsept vektörleri ve önceden belirlenmiş ağırlıklar ile BBH işletimi başlatılır ve modellenen sistem simülasyonu bu şekilde sağlanmış olur. Herhangi bir öğrenme yöntemi ile takviye edilmemiş klasik ve statik

ağırlıklara sahip bulanık bilişsel haritaların, dinamik sistemleri modelleme konusunda bazı eksiklikleri ve başarısızlıkları görülmektedir. Bu durumun sebebi, statik ağırlıklara sahip bulanık bilişsel haritaların aynı konsept değerleri ve işletim zamanında aynı konsept ilişkilerini kullanmasından kaynaklanmaktadır. Literatürde BBH'lar üzerine odaklanmış birçok çalışma bulunmaktadır. Literatürde BBH'lerden yararlanan birçok çözüm önerisi bulunmaktadır.

Bunlardan birinde Gozhyj Aleksandr su kalitesinin modellenmesi için BBH'lerden yararlanmıştır [13]. Yapılan çalışmada öncelikle su kalitesine etki eden özellikler düğüm olarak ifade edilmiştir. Daha sonra düğümlerin ağırlıkları ve komşuluklar belirlenmiştir. BBH oluşturulup sistem karakteristiği analizi gerçekleştirilmiştir. BBH oluşturulduktan sonra, yapay veriler üzerinde yapılan simülasyonlar sonucu su kalitesi analizi gerçekleştirilmiştir.


Başka bir çalışmada Pajares ve arkadaşları, BBH'nin bilgisayar görmesi uygulamalarındaki görevlerine yoğunlaşmışlardır [14]. Yapılan çalışmada ilk önce yola çıkma gayesi bilgisayar görmesi uygulamalarında ele alınan iki boyutlu görüntülerin gerçek hayatta üç boyutlu bir ortam içinden alınmış olmasıdır.

Çalışmaya göre iki boyutlu görüntüde üç boyutlu model elde etmek için gerekli olan ilişkiler korunmaktadır. Bundan ötürü iki boyutlu görüntülerden üç boyutlu model elde etmek mümkündür. Bahsedilen bu ilişkileri bir BBH ile modelleyerek üç boyutlama işlemi gerçekleştirmek mümkündür. Bu kapsamda çalışma, görüntü tanıma, görüntü üç boyutlama ve görüntü değişimi algılama gibi bilgisayarlı görme uygulamalarını BBH tabanlı bir bakış açısıyla gerçekleştirmiştir. Çalışmada ilk olarak görüntü sınıflandırma için BBH tabanlı bir yöntem önerilmiştir. Buradaki sınıflandırma, görüntüdeki her pikselin bir kümeye ait olarak sınıflandırılması sağlayan bir birleşik sınıflandırıcıyı açıklar. Önerilen bu sınıflandırma yöntemi Bayes ağları ve Bulanık kümeleyici tabanlı bir eğitim aşaması ve BBH tabanlı bir karar aşamasından meydana gelmektedir.

Başka bir literatür çalışmasında ise, C. Chen vd., BBH'ler için farklı ağırlık eğitimi metodlarını ve eşik fonksiyonlarını incelemiş ve karşılaştırmışlardır [15]. Yapmış oldukları bu çalışmalardan yararlanarak kendi tabirleriyle esnek bir BBH yapısını sunmuşlardır. Burada verilen esnek BBH yapısı dinamik ağırlık güncelleme yeteneğine sahiptir. BBH'lerin yapay sinir ağı doğası kullanmış oldukları aktivasyon fonksiyonlarından kaynaklanmaktadır. Hesapsal zekâ yöntemlerinde en sık kullanılan aktivasyon fonksiyonlarından biri sigmoid fonksiyondur. Bahsi geçen literatür çalışmasında verilen esnek BBH yapısında da sigmoid aktivasyon fonksiyonu ile daha lineer bir aktivasyon fonksiyonu karşılaştırılmıştır. Aktivasyon fonksiyonları temelde hesapsal zekâ yönteminde kullanılan düğüm değerlerini 0,1 veya -1,1 aralığına ölçeklerler.

Başka bir çalışmada, Yuano M. tarafından BBH'nin nedensel ilişkileri modellerken statik bağlantılar kullanması sorununa odaklanıp dinamik bir BBH (DBBH) modeli önerilmiştir [16]. Daha önce de bahsedildiği gibi BBH'ler bir düğüm vektörü ve ağırlıklar matrisinden meydana gelmektedir.

Burada verilen DBBH yapısında iki düğüm arasındaki ağırlıkların tek bir değeri bulunmamaktadır. Yani ağırlıklar matrisinin her bir elemanı birer vektörle ifade edilebilir. Burada ağırlık vektörlerinden iterasyon esnasında kullanılacak elemanlar düğüm değerlerine veya iterasyon sayısına bağlı olarak seçilebilir. Şekil 1.4'te Yuano'nun verdiği DBBH modeline ait örnek bir yapıya yer verilmiştir.



Şekil 3. Literatür çalışmasında verilen dinamik BBH modeli ve ona ait ağırlık matrisi [16].

Başka bir çalışmada Bhutani K. vd. bulanık çıkarım sistemi (BÇS) ve BBH tabanlı bir sınıflandırma yöntemi vermişlerdir [18]. Yapılan çalışmada, BBH ile beraber kullanılan BÇS bir veri seti üzerinde uygulanmış ve BBH yapısı kaynak ve aralık adı verilen iki düğüm grubunun bipartite eşleştirilmesi ile gerçekleştirilmiştir. Geliştirilen yöntemin veri seti üzerindeki başarıyı %100 olarak belirlenmiştir. Kullanılan veri setinin girişleri;

- Yaş,
- Gözlük reçetesi,
- Astigmatik durum,
- Gözyaşı oranı olarak belirlenmiştir.


Sınıflandırma işleminin gerçekleştirileceği sınıflar ise;

- Yumuşak lensler,
- Sert lensler,
- Lens kullanmamalı.

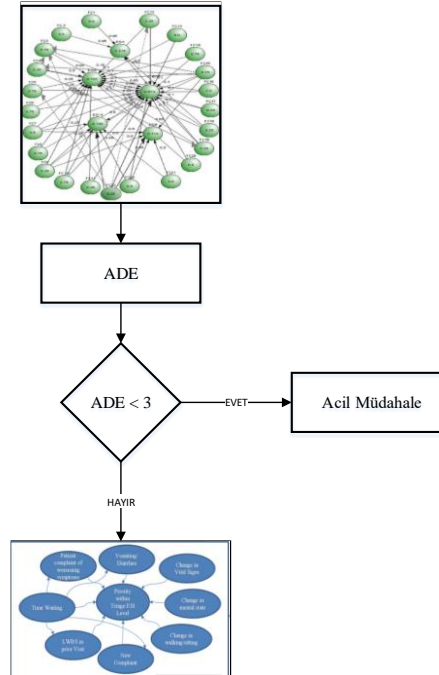
Toplam 24 veriden oluşan veri setinin 14 verisi eğitim için 10'u ise test için kullanılmıştır. Öncelikle veri seti üzerinde üçgen üyelik sınıfları kullanan bir BÇS işlemi uygulanmıştır. Daha sonra Şekil 1.5'te verilen yazarlar tarafından Bulanık İlişkisel Harita olarak adlandırılan (BİH) BBH modeli üzerinde sınıflandırma işlemi gerçekleştirilmiştir.

Başka bir çalışmada Georgopoulos ve Stylios hastanelerin acil servislerinde hastalara müdahale önceliği için kritik durum sınıflandırması işlemini BBH tabanlı bir yöntemle gerçekleştirmişlerdir [19]. Triyaj, hastaların acil servislerde durumunu değerlendirmek ve kategorize etmek için yapılan işlemidir.

Acil servislerin kalabalık oluşu hastaların zamanında uygun tıbbi yardım alma sürecini oldukça zorlaştırmaktadır. Yapılan çalışmada öncelikle bir BBH modeli ile Acil Durum Şiddeti Endeksi (ADE) belirlenmiştir. Bahsi geçen bu ADE 1 ile 5 arasında değer almaktadır. Burada ADE'nin belirlenmesi için 23 özelliğe sahip bir BBH yapısı kullanılmıştır. Bu 23 özellik, hastada görülen semptomlar, hasta yaşı, hayati belirtiler, ağrı şiddeti vs. gibi özelliklerden oluşmaktadır. Yapılan bu BBH tabanlı işlemden sonra elde edilen ADE eğer 1 veya 2 ise hastanın acil bakıma ihtiyacı olduğu belirtilmektedir. Diğer durumlarda ise dinamik öncelik hesaplayan BBH modeli işletilir ve triyaj işlemi bu şekilde gerçekleştirilir. Literatür çalışmasına ait blok diyagramına Şekil 5'de yer verilmiştir.



Şekil 4. Literatür çalışmasında verilen BBH modeli [18].

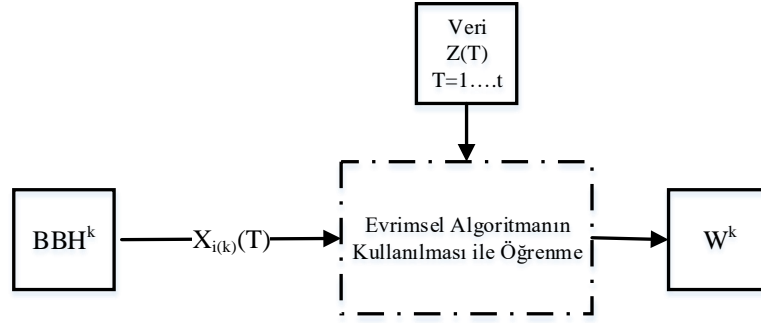


Şekil 5. Literatür çalışmasına ait blok diyagramı [19].

Diğer bir literatür çalışmasında, kompleks BBH'ların evrimsel öğrenme algoritmalarının analizi gerçekleştirilmiştir [20]. Yapılan çalışmada, BBH inşa adımları, ilgili probleme ait konseptlerin belirlenmesi, çıktı olarak değerlendirilecek konseptlerin belirlenmesi ve konsept ilişkilerinin belirlenmesi olarak ifade edilmiştir. Bu noktada literatür çalışmasının hedefi konsept ve konsept ilişkilerinin minimize ederek BBH yapısının çalışabileceği en iyi performansta uygulanmasını sağlayacak BBH inşasını gerçekleştirmektir. Önerilen yöntemin sağladıkları;

- Graf teorisi kriterlerine dayalı temel konseptlerin seçilmesi ve aralarındaki ilişkilerin belirlenmesi,
- Çıktı konseptlere dayalı öğrenme kriterinin belirlenmesi ve öğrenme sürecini analiz edilen probleme bağlanmasıdır.

Geliştirilen yöntemin optimum BBH inşası için gerekli konsept ve konsept ilişkilerini belirlemede uyguladığı adımlara Şekil 6'da yer verilmiştir.



Şekil 6. Literatür çalışmasında verilen yönteme ait blok diyagramı [20].

Literatürdeki çözüm önerileri incelendiğinde BBH tabanlı bir bakış açısı kullanan araştırmacılar aşağıda ifade edilen adımları izlemektedir;

- BBH'ın çözüm üreteceği problem veya modelleyeceği sistem özelliklerinin BBH konseptleri ile bulanıklaştırılarak ifade edilmesi,
- BBH konseptlerinin kullanacağı aktivasyon fonksiyonunun belirlenmesi,
- Belirlenen konseptler arasındaki bilişsel ilişkilerin belirlenmesi için kullanılan yöntemin seçilimi,
- BBH'ın iterasyonlardaki statik veya dinamik işleme sahipliğinin belirlenmesi,
- Dinamik işleme sahip BBH'lar için çevrimiçi ağırlık belirleme veya güncelleme yönteminin seçilmesi,
- BBH durdurma kriterinin belirlenmesi.

Yukarıda verilen literatür çalışmalarında da BBH'ların çok farklı alanlardaki problemlerin çözümlerine odaklandığını görülmektedir. Burada bahsi geçen uygulama alanlarına endüstri, sağlık, enerji, bilgisayar bilimi, ekoloji vs. örnek verilebilir. Burada dikkat edilmesi gereken husus ele alınan probleme ait özelliklerin BBH konseptine dönüşümlerinin sağlanmasıdır. Bununla beraber BBH'ların geliştirilmesinden itibaren araştırmacılar bazı noktalarda statik işletimli yani sistem veya probleme ait bütün fazlarda aynı bilişsel ağırlıkların kullanıldığı BBH işletimlerini yetersiz görerek BBH'lara daha dinamik bir bakış açısı kazandırmaya veya statik işletimli BBH'larda farklı ağırlık belirleme yöntemlerinin geliştirilmesine odaklanmışlardır. BBH'ların statik ağırlık belirleme veya dinamik ağırlık güncelleme işlemleri için gözetimsiz öğrenme teknikleri (Hebbian vs.) , sezgisel optimizasyon teknikleri, bulanık mantık, gözetimli öğrenme teknikleri (Yapay Sinir Ağı vs.) kullanılmıştır. Ayrıca BBH'lar ele aldığı problemlerde bir sınıflandırıcı veya hesaplayıcı rol de üstlenebilmektedirler. Tablo 2'de literatürdeki BBH odaklı çalışmalara ait bazı özelliklere yer verilmiştir.

Tarafımızca yapılan yüksek lisans tezi ve bu tez çalışmasından doğan bazı akademik çalışmalarda konsept ilişkilerinin çevrimiçi güncellendiği derin yapay sinir ağlarını kullanan farklı bir DBBH yapısı önerildi [21-23].

Yine geliştirilen bu DBBH yapısı farklı sanal sayısal senaryolar ve nesne takibi uygulamaları üzerinde test edilmiştir. Burada tez çalışmamız içerisinde ve bu çalışmadan doğan [23] referans numaralı bildirimizde çoklu nesne takibi işlemi için önerilen derin yapay sinir ağlarını kullanan DBBH'tan yararlanılmıştır. Buradaki işlemde DBBH ardışık görüntü kareleri arasındaki nesnelerin eşleştirme skorlarını hesaplayarak bir sınıflandırıcı işlevindeydi. Bununla beraber tez çalışması üzerinde önerilen DBBH bakış açısının doğruluğunu test etmek için kullanılan sanal senaryolara ait sonuçları [22] referans numarası ile verdiğimiz çalışmamızda sunulmuştur. Burada verilen sanal senaryolarda DBBH hesaplayıcı bir rol üstlenmiştir. Bu çalışmada ise yüksek lisans tezi çalışmamızda geliştirilen DBBH yapısı ile çoklu görüde nesne takibi işlemi sunmaya odaklanılmıştır. Çoklu görüde nesne takibi uygulamasının, tekli görüde çoklu nesne takibi uygulamasından temel farkı DBBH'nın sınıflandırıcı değil hesaplayıcı bir rol ile kullanılmasıdır. Yani burada DBBH çoklu görüye sahip bir sistemde

referans bir görüntüleme aygıtına ait görüntü kareleri üzerinden tespit edilen nesne sınır kutularının pozisyonlarını başlangıç konsept vektörü olarak alır ve diğer görüntü kareleri üzerindeki karşılıklarını hesaplar. DBBH inşası ve önerilen yöntemin testi için bir basketbol antrenmanını görüntüleyen iki adet kameradan elde edilmiş görüntü kareleri ve bu kareler üzerinde tespit edilen nesnelerin sınır kutusu bilgilerini barındıran gerçek değer (ground truth) dosyalarından yararlanılmıştır. Önerilen yöntemin performans değerlendirmesi ise birleşim kesişimi (Intersection over Union) yöntemi ile gerçekleştirilmiştir.

Tablo 2. BBH odaklı literatür çalışmalarına genel bakış.

Referans Numarası	Ağırlık Belirleme Yöntemi	Uygulama Alanı
[13]	Uzman Görüşleri	Ekoloji
[14]	Bulanık Üyelik Fonksiyonları	Bilgisayarlı Görme
[15]	Gözetimsiz Öğrenme Yöntemleri	BBH Dinamikleştirme
[16]	Karar Fonksiyonları	BBH Dinamikleştirme
[17]	Büyük Veri Setleri ve Uzman Görüşleri	BBH Tasarımı
[18]	Bulanık Çıkarım Sistemleri	Sınıflandırma
[19]	Uzman Görüşleri	Sağlık
[20]	Evrimsel Algoritmalar	BBH Tasarımı
[21]	Derin Yapay Sınır Ağları, Sezgisel Optimizasyon Yöntemleri	BBH Dinamikleştirme, BBH Tasarımı, Nesne Takip Uygulamaları
[22]	Derin Yapay Sınır Ağları, Sezgisel Optimizasyon Yöntemleri	BBH Dinamikleştirme, BBH Tasarımı
[23]	Derin Yapay Sınır Ağları, Sezgisel Optimizasyon Yöntemleri	Çoklu Nesne Takibi
[24]	Genetik Algoritma	BBH Tasarımı
[25]	Parçacık Sürü Optimizasyonu	BBH Dinamikleştirme

3. Önerilen Yöntem

Çoklu görüde nesne takibi işlemi, aynı alanın birden fazla görüntüleme aygıtı ile kaydedildiği görüntü dizilerinde yapılan nesne takibi işlemidir. Bizim buradaki amacımız iki veya daha fazla kamera ile görüntülenmiş bir alanın üzerinde nesne takibini gerçekleştirirken kameralardan birinin kaydettiği görüntü karelerini referans olarak kabul edip bu görüntü karesi üzerinde tespit edilen nesnelerin kontur pozisyonunu diğer görüntü kareleri üzerinde işaretlemektir. Bu çalışmada da daha önce ifade edildiği ÇGNT işlemi için derin öğrenme kullanan DBBH'lardan yararlanılmaktadır. Daha önce DBBH kullanan çözüm önerilerinde araştırmacıların izlemesi gereken adımlara ve göz önünde bulundurması gereken durumlara yer vermiştik. Önerilen yöntemin detaylı ve anlaşılır bir biçimde açıklanması için bahsi geçen bu DBBH yaklaşım adımlarının her biri ayrı ayrı ele alınacaktır.

A. DBBH Konseptlerinin Belirlenmesi

BBH tabanlı bir çözüm önerisi geliştirilirken öncelikle probleme ait özelliklerin DBBH konsepti olarak ifade edilmesi gerekmektedir. Ele alınan ÇGNT işleminde referans görüntü karesi üzerinde tespit edilen nesne sınır kutularının pozisyonları başlangıç konsept vektörü olarak kabul edilmektedir. DBBH kararlı duruma geldiğinde ise elde edilen çıktı konsept vektörü hedef görüntü karesinde ele alınan nesneye ait sınır kutularının pozisyonlarını ifade etmektedir. Sonuç olarak DBBH konseptleri nesne sınır kutusunu ifade eden referans pozisyonun yatay eksenindeki değeri (X_c), düşey eksenindeki değeri (Y_c), sınır kutusunun düşey uzunluğu ($L1_c$) ve sınır kutusunun yatay uzunluğu ($L2_c$) olarak belirlenmiştir. Problem özelliklerinin bulanıklaştırılma işlemine ait matematiksel gösterimler Denklik 2'deki gibidir. Denkliklerden de anlaşılacağı üzere bulanıklaştırma işlemi için her özellik alabileceği maksimum değere bölünmüştür. Şekil 7'de DBBH konseptlerinin özelliklerini ifade eden bir blok diyagramına yer verilmiştir. DBBH konseptlerinin kullanacağı aktivasyon fonksiyonu Sigmoid olarak belirlenmiştir (6).


$$L1_c = \frac{L1}{\max(L1)} \quad (2)$$

$$L2_c = \frac{L2}{\max(L2)} \quad (3)$$

$$X_c = \frac{X}{\max(X)} \quad (4)$$

$$Y_c = \frac{Y}{\max(Y)} \quad (5)$$

$$\text{sig}(x) = \frac{1}{1+(e)^{-\lambda x}} \quad (6)$$



Şekil 7. DBBH konseptlerini ifade eden diyagram.

B. DBBH İşletimi

Daha önce de bahsedildiği gibi bu çalışmadaki DBBH işletimi derin yapay sinir ağlarından yararlanmaktadır. Bahsi geçen derin yapay sinir ağı ile her iterasyonda DBBH ağırlık matrisi, konseptlerin anlık değerlerine bağlı güncellenecektir. Dolayısıyla derin yapay sinir ağının giriş olarak DBBH konsept vektörünün o anki halini alırken çıkış olarak vektörleştirilmiş DBBH ağırlık değerlerini verecektir. DBBH durdurma kriteri gerçekleştirilene kadar her iterasyonda ağırlık güncelleme işlemi devam edecektir. Şekil 8’de DBBH işletim adımlarına yer verilmiştir. DBBH’ın durdurma kriteri ise DBBH konseptlerinin kararlılığına bağlı bir fonksiyon ile ifade edilmiştir. Burada konsept kararlılığı DBBH konseptlerinin iterasyon sonlarında değişim değerlerinin 0’a yaklaşmasını ifade eder. Kararlılık fonksiyonu ise ardışık iterasyonlardaki ortalama konsept değişim değerinin kararlılık toleransı değerinden (ϵ) küçük olup olmadığını kontrol eder.

C. DBBH İnşası

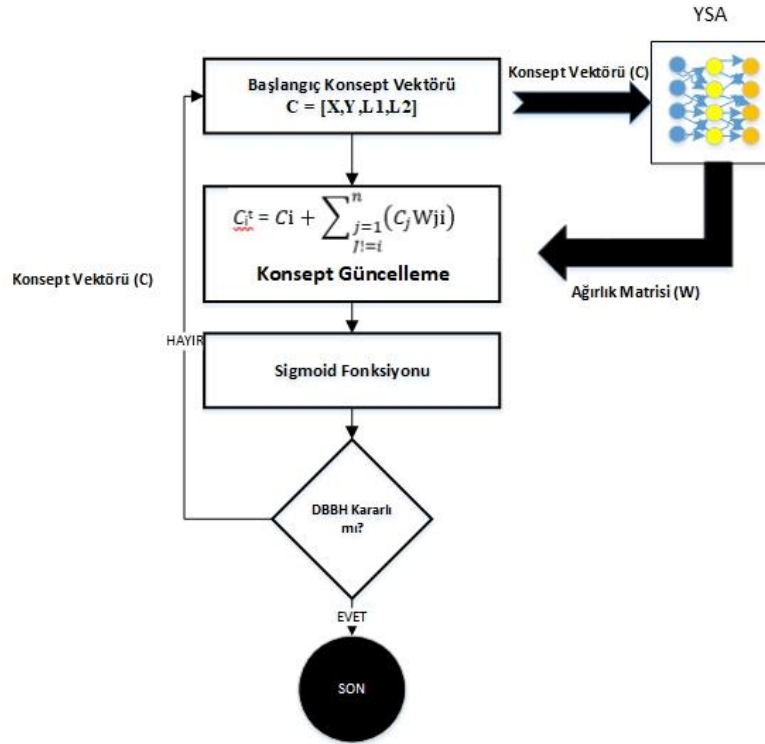
DBBH işletim yönteminin belirlenmesinin ardından istenilen özellikleri gerçekleştirebilecek DBBH’ın inşası için öncelikle ağırlık matrisini güncelleyecek derin yapay sinir ağı modelinin eğitilmesi gerekmektedir. Burada ele alınan derin yapay sinir ağının öncelikle 4 adet giriş ve 16 adet çıkış nöronuna sahip olması gerekmektedir. Burada giriş nöronlarına her iterasyon başında DBBH’ın anlık konsept vektör değerleri verilecek ve 16 elemanlı vektör olarak alınan ağırlık değerleri (4x4)’lük bir matrise çevrilerek DBBH ağırlık matrisi güncellenecektir. Burada derin yapay sinir ağının yapısına bakıldığında YSA eğitimi için içerisinde başlangıç konsept vektörlerine karşılık gelen ağırlık vektörünü bulunduran bir veri seti gerekmektedir. Bu noktada böyle bir veri setine ham bir şekilde ulaşmak mümkün değildir. Çünkü mevcut ÇGNT veri setlerinde ancak tespit edilen nesnelerin sınır kutusu pozisyonlarının tutulduğu gerçek değer (ground truth) dosyaları sunulmaktadır. Yani DBBH konsept bakış açısıyla veri setlerini ele alacak olursak başlangıç konsept değerlerine karşılık gelen kararlı durum konsept değerlerinin bulunduğu veri seti ham olarak sahip olabiliriz. Dolayısıyla yapay sinir ağı eğitimi için bir veri seti dönüşümü işleminin gerçekleştirilmesi gerekir. Buradaki veri seti dönüştürme işlemi için veri setindeki her başlangıç konsept vektöründen DBBH işletimi ile kararlı konsept vektörünün elde edilmesi için gereken bilişsel ağırlıklar genetik algoritma tabanlı bir yöntem ile hesaplanmıştır. Dönüştürülen veri setinin elde edilmesinin ardından farklı eğitim parametrelerinin (gizli katman sayısı, öğrenme oranı, aktivasyon fonksiyonu vs.) kullanıldığı birden fazla YSA eğitimi işlemi gerçekleştirilmiştir ve bu eğitilmiş YSA modellerinden başarıyı en yüksek olan model DBBH işletimi için kullanılmıştır.

D. Genetik Algoritma Tabanlı Veri Seti Dönüşümü

Daha önce de bahsedildiği gibi derin yapay sinir ağının eğitiminde kullanılacak veri setinin başlangıç konsept vektörlerine karşılık gelen ağırlık değerlerinin bulunması gerekmektedir. Burada gerekli olan tipteki veri setinin elde edilmesi için genetik algoritma tabanlı bir veri seti dönüşümü gerçekleştirilmiştir. Bu işlemin

gerçekleştirilmesi için öncelikle kimliklendirilmiş nesne konturlarının her görüntü karesi üzerindeki pozisyonlarını tutan bir veri setine ihtiyaç duyulmaktadır. Böyle bir veri setinden istenilen formattaki veri setini elde etmek için referans görüntü karesine ait kontur pozisyonları bulanıklaştırılarak DBBH'nin başlangıç durum vektörü olarak kabul edilir. Daha sonra, referans görüntüdeki nesne konturlarının diğer görüntü kareleri üzerinde ifade edilmesi için diğer görüntü kareleri üzerindeki kontur pozisyonları bulanıklaştırılarak istenilen konsept vektörü olacak şekilde genetik ağırlık belirleme işlemi gerçekleştirilir.


Burada referans kamera ile kayıt edilmiş görüntü dizileri haricindeki bütün görüntü dizileri için bu işlemin gerçekleştirilmesi ve farklı kameralar ile kaydedilmiş her görüntü dizisi için ayrı bir derin yapay sinir ağı modeli eğitilir. Şekil 9'da ham veri setinden istenilen formatta veri seti elde etmek için gerekli adımların blok diyagramı verilmiştir.



Şekil 8. DBBH İşletim adımları.

Blok diyagramı incelendiğinde nesne sınır kutusu pozisyonlarının veri setinden alınması ve bulanıklaştırma işlemi gerçekleştirilir. Bu adımdan itibaren belirlenmiş popülasyon büyüklüğü ve durdurma kriterine sahip genetik algoritma adımları başlar. Genetik Ağırlık belirleme adımına ait blok diyagramı Şekil 10'daki gibidir. Genetik algoritma içerisindeki her bir kromozom birer DBBH ağırlık matrisidir. Dolayısıyla genler bu ağırlık matrisinin her bir elemanını ifade etmektedir. Genetik Algoritmanın başlangıç popülasyonunun oluşturulması için ağırlık değerleri rastgele bir yaklaşımla oluşturulmaktadır. Başlangıç popülasyonunun belirlenmesinin ardından her kromozomu ifade eden ağırlık matrisleri ve başlangıç konsept vektörü (Cbaşlangıç) ile BBH işletimi gerçekleştirilir. BBH işletiminin gerçekleştirilmesinin ardından elde edilen kararlı konsept vektörü (Ck) ve istenilen konsept vektörü (Cistenen) elemanlarının ortalama sapmaları hesaplanır. Burada elde edilen değerlerin 1'den çıkarılmasıyla her kromozoma ait uygunluk değerleri belirlenir. Bu adımdan sonra kromozomların çaprazlanması ile yeni çocuk kromozomlar elde edilir ve bunların da uygunluk değerleri hesaplanarak çaprazlama işlemi gerçekleştirilir. Genetik ağırlık belirleme işleminin durdurma kriteri en iyi kromozom uygunluk oranının %95'ten büyük olmasıdır. Ayrıca bilindiği üzere BBH işletimi esnasında konseptler sigmoid fonksiyonuna tabi tutulmaktadır. Genetik ağırlık belirleme işlemi sırasında kromozomların yakınsama durumunun farklı sigmoid

lambda (λ) değerlerine göre değiştiği gözlemlenmiştir. Genetik ağırlık belirleme işlemi farklı lambda değerlerinin kullanıldığı BBH yapıları için birden fazla gerçekleştirilmiştir.



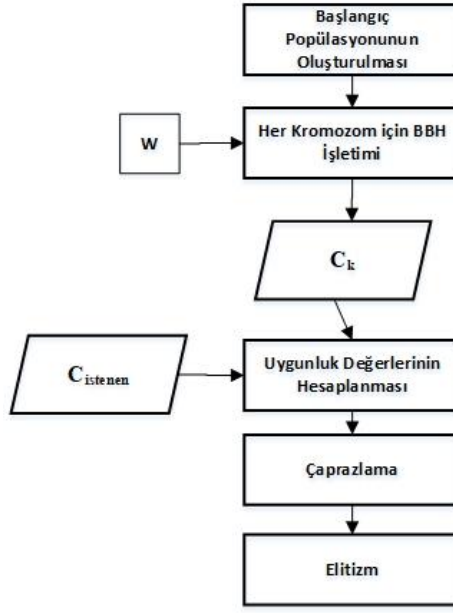
Şekil 9. Ham veri setlerinden istenilen formattaki veri setinin elde edilmesi.

E. Derin Yapay Sinir Ağı Eğitimi

Derin yapay sinir ağları birden fazla gizli katmana sahip yapay sinir ağlarıdır. Önerilen yöntemde istenilen formattaki veri setinin elde edilmesinin ardından farklı yapay sinir ağı eğitim parametrelerine göre birden fazla yapay sinir ağı modeli eğitilmiştir. Bunların içerisinde en yüksek başarıma sahip olan yapay sinir ağı modeli DBBH işletimi esnasında kullanılmıştır. Burada bahsedilen eğitim parametreleri ise katmanlarda kullanılan aktivasyon fonksiyonları, gizli katman sayısı, gizli katmanlara ait nöron sayıları, öğrenme yöntemi, öğrenme oranı, öğrenme iterasyon sayılarıdır. Burada bilişsel ağırlıklar -1 ile 1 değer aralığında olduğu için aktivasyon fonksiyonlarının sınır değerleri oldukça önemlidir. Örneğin hiperbolik tanjant aktivasyon fonksiyonunun sınır değerleri $[-1,1]$ aralığında iken sigmoid fonksiyonunun sınır değerleri $[0,1]$ aralığındadır. Bu kapsamda yapay sinir ağı eğitiminde sigmoid fonksiyonu gibi sınır değeri $[0,1]$ aralığında bulunan bir aktivasyon fonksiyonu kullanılırsa bir normalizasyon (n) ve denormalizasyon fonksiyonu kullanılmalıdır. Burada ağırlık değerlerinin normalizasyonu ve denormalizasyonunu ifade eden matematiksel denklemler 7 ve 8'deki gibidir. Eğitim işleminde öğrenme yöntemi olarak "Adam Optimizer" kullanılmıştır.

$$n(w) = \frac{w+1}{2} \quad (7)$$

$$d(w) = (w \times 2) - 1 \quad (8)$$



Şekil 10. Genetik ağırlık belirleme adımı.

4. Deneysel Sonuçlar

Çoklu görüde nesne takibi işlemi için daha önce de belirtildiği gibi, referans bir görüntüleme aygıtı ile çekilmiş görüntü kareleri üzerinde tekli görüde çoklu nesne takibi işleminin gerçekleştirilmesinden sonra, burada belirlenen kontur pozisyonlarının farklı görüde kaydedilmiş görüntü kareleri üzerinde karşılığının belirlenmesi gerekmektedir. Burada uygulama için kullanılacak DBBH'nin inşası içinde öncelikle ham veri setinden içinde DBBH ağırlıklarının bulunduğu istenilen formattaki veri setinin elde edilmesi için genetik ağırlık belirleme işlemi gerçekleştirilmiştir. Burada kullanılan veri seti bir basketbol antrenmanını farklı görülerden kaydeden iki adet görüntüleme cihazından alınmış görüntülerden oluşmaktadır.

Veri setinin gerçek değer dosyalarında bulunan nesne kontur değerlerinin %10'u ile genetik ağırlık belirleme işlemi gerçekleştirilip, elde edilen istenilen formatta veri seti ile yapay sinir ağı eğitimi gerçekleştirilmiştir. Genetik ağırlık belirleme adımı, optimum değerlere yakınsama için, BBH sigmoid lambda değerinin düzgün bir şekilde seçilmesi gerekmektedir. Şekil 11'de farklı sigmoid lambda değerlerinde işletilmiş genetik algoritmanın yakınsama grafiğine yer verilmiştir.


Şekil 11'de görülmektedir ki verilen problemin çözümünde kullanılacak DBBH sigmoid lambda değeri 2 olarak seçilmelidir. Tablo 3 ve 4'de kullanılan derin yapay sinir ağına ilişkin bilgiler bulunmaktadır. Kullanılan DBBH yapısı, 4 adet bulanıklaştırılmış kontur pozisyonu ve 1 adet yardımcı konseptten oluştuğu için yapay sinir ağına girdi katmanında 4 adet çıktı katmanında ise 25 adet nöron bulunması gerekir.

Tablo 3. Farklı eğitim faktörlerine göre YSA eğitimi başarımı.

Gizli Katman Sayısı	Aktivasyon Fonksiyonu	Öğrenme Oranı	Standart Fark	Eğitim Başarımı
3	Sigmoid	0.1	0.1	0.92
4	Sigmoid	0.001	0.001	0.90
4	Tanh	0.01	0.01	0.91
4	Sigmoid	0.1	0.1	0.92
4	Sigmoid	0.01	0.01	0.90
5	Sigmoid	0.01	0.01	0.91
5	Sigmoid	0.01	0.01	0.91
4	Tanh	0.01	0.01	0.92
4	Sigmoid	0.01	0.01	0.93

Tablo 4. Derin YSA'ya ait gizli katman nöron sayıları ve başarımlara yer verilmiştir.

Gizli Katman	Gizli Katman	Gizli Katman	Gizli Katman	Başarım
1	2	3	4	
8	8	32	32	%92.80
8	32	32	8	%91.12
4	64	64	32	%90.28
16	16	256	512	%92.61
8	16	16	8	%93.77
4	16	16	32	%94.47

**Şekil 11.** Farklı lambda değerlerine bağlı genetik ağırlık belirleme yakınsama grafiği.

Yapay sinir ağı eğitimi de gerçekleştirildikten sonra, referans görüntüdeki, kontur pozisyonları bulanıklaştırılarak, derin öğrenme kullanan DBBH'a sunulmuştur ve DBBH pozisyon tahminini yüksek bir başarımla gerçekleştirmiştir. Tablo 5'de DBBH'ın tahmin ettiği kontur pozisyonları ve gerçek konturlarla olan kesişimlerine bağlı başarımlarına yer verilmiştir. Burada kesişim hesaplama için kullanılan denklik, Denklem 9-12'deki gibidir. Tablo 6'da aynı konturların DBBH'ın referans kabul ettiği görüdeki pozisyonları, Tablo 7'de ise DBBH'ın tahmin ettiği kontur pozisyonlarının referans görüdeki karşılıklarına yer verilmiştir.

$$I_x = |RefX_1 - GX_1| \quad (9)$$

$$I_y = |RefY_1 - GY_1| \quad (10)$$

$$Kesişim Oranı = 100 \times ((RefX \times RefY) - I_s) / (RefX * RefY) \quad (11)$$

Tablo 5. DBBH tarafından tahmin edilen kontur pozisyonları.

Görüntü Karesi	Nesne id	X1	Y1	X2	Y2	Kesişim Oranı
1	0	283	34	319	114	%98,6
1	1	216	47	303	204	%99,4
1	2	246	37	274	116	%78,57
1	3	234	36	259	109	%69,2


Tablo 6. DBBH tarafından tahmin edilen kontur pozisyonlarının gerçek değerleri.

Görüntü Karesi	Nesne id	X1	Y1	X2	Y2
1	0	282	35	310	111
1	1	215	43	313	200
1	2	224	33	258	129
1	3	211	35	241	123

Tablo 7. DBBH tarafından tahmin edilen kontur pozisyonlarının referans görüntüdeki karşılığı.

Görüntü Karesi	Nesne id	X1	Y1	X2	Y2
1	0	155	53	188	39
1	1	1	52	18	119
1	2	80	45	109	126
1	3	110	46	136	125

Şekil 12’de referans görüntü karesi üzerinde işaretlenmiş tek bir nesneye ait sınır kutusuna, ilgili nesnenin DBBH tarafından hesaplanan sınır kutusuna ve hedef görüntüde ilgili nesneye ait gerçek sınır kutusuna yer verilmiştir. Şekil 13’de ise birden fazla nesnenin referans görüntüdeki sınır kutusuna, DBBH tarafından hesaplanmış sınır kutusuna ve hedef görüntüdeki gerçek sınır kutusuna yer verilmiştir.

**Şekil 12.** Hedef görüntüdeki sınır kutusu (a), DBBH’ın elde ettiği sınır kutusu (b) ve referans görüntüdeki sınır kutusu (c).**Şekil 13.** DBBH’ın elde ettiği sınır kutusu (a) ve hedef görüntüdeki sınır kutusu (b).

6. Sonuçlar ve Tartışma

Bu çalışmada çoklu görüde nesne takibi işlemi için bulanık bilişsel haritalara dayalı bir bakış açısı gerçekleştirilmiştir. Çoklu görüde nesne takibi işleminde nesnelerin her görüntü karesi için ayrı ayrı tespit edilmesi yüksek algoritmik maliyete sahip bir bakış açıdır. Bundan ötürü nesnelerin takibi için referans bir görüntüleme aygıtı ile elde edilmiş görüntü kareleri üzerinde tespit edilip diğer görüntü kareleri için bu nesne konumlarının hesaplanması çok daha verimli bir bakış açıdır. Literatürde çoklu görüde nesne takibi uygulamaları için kamera pozisyon bilgilerine dayalı veya hesapsal zeka yöntemlerinden yararlanan bakış açıları kullanılmaktadır. Bulanık bilişsel haritalar (BBH) ise bir probleme ait özellikleri ve bu özellikler arasındaki ilişkileri graflar (çizge) üzerinde ifade eder ve iteratif bir hesaplama işlemi gerçekleştirir. Bulanık bilişsel haritaların sunulan ilk halinde iterasyonlarda konseptler arası ilişkiler sabit kalmaktaydı bu da dinamik problemlerin çözümü için BBH’ların yetersiz kalmasına sebep oluyordu.

Bundan ötürü BBH üzerine çalışan araştırmacılar farklı bakış açılarıyla BBH'ları dinamikleştirmeye odaklandılar. Tarafımızca yapılmış geçmiş çalışmalarda derin yapay sinir ağlarını kullanan dinamik bir BBH yapısı önerilmiştir. BBH ilişkilerinin eğitilmiş derin yapay sinir ağı modelinden elde edildiği bahsi geçen çalışmada inşa edilen DDBH'ların gerçek dünya sistemlerini modelleme başarımının oldukça yüksek olduğu gözlemlenmiştir. Bu çalışmada da ÇGNT işlemi için inşa edilen DBBH yapısı bahsedilen derin yapay sinir ağı tabanlı bir çevrimiçi ağırlık güncelleme kabiliyetine sahiptir. Kullanılan DBBH'nın konseptleri ele alınan nesnelere ait konturların sınır kutusu konumlarının bulanıklaştırılmış halleridir. Başlangıç DBBH konsept değerleri sınır kutularının referans görüntüdeki konum değerlerini ifade ederken, kararlı DBBH konsept değerlerinde hedef görüntü karesindeki nesne sınır kutularının konumlarının hesaplanması hedeflenmiştir. Geliştirilen yöntem, bir basketbol antrenmanının görüntü ve nesne kontur gerçek değerlerini (ground truth) barındıran bir veri seti üzerinde test edilmiştir. Burada veri setinin %70'i eğitim için %30'u ise test işlemleri için kullanılmıştır. DBBH'nın ağırlık güncelleme işlemlerini gerçekleştirecek derin yapay sinir ağının girişi DBBH konsept değerleri çıkışı ise vektörleştirilmiş ağırlık matrisi olması gerekmektedir. Burada derin yapay sinir ağı eğitimi için veri setinin konsept değerlerine karşılık gelen ağırlık matrisini bulunduran bir forma dönüştürülmesi gerekmektedir. Bu işlem genetik algoritma (GA) tabanlı bir bakış açısıyla gerçekleştirilmiştir. GA tabanlı veri seti dönüşümü işlemi %95'in üzerinde bir başarımla gerçekleştirilmiştir. Elde edilen veri seti ve farklı eğitim parametreleri ile birden fazla YSA eğitimi gerçekleştirilerek %94,47'lik test başarımına sahip olan YSA modeli DBBH işletiminde kullanılmıştır. Çalışmada odaklanılan problemin karmaşıklığından ötürü klasik BBH öğrenme yöntemleri DBBH'nın düşük bir başarımla modelleme yapmasına sebep olmaktadır. DBBH inşasında derin yapay sinir ağlarından yararlanmak DBBH'a kompleks sistemleri modelleyebilme yeteneği kazandırmıştır. DBBH işletimi sonucunda elde edilen nesne kontur sınır kutusu konumları birleşim kesişimi (Intersection of Union) adına bir başarımla hesaplama yöntemi ile test edilmiş ve minimum %67,4 maksimum %99,8'lik başarımlar elde edilmiştir. Önerilen yöntemin ortalama birleşim kesişim başarımı ise %88,2'dir. Bununla beraber çalışma içerisinde verilen Şekil 13 ve 14 ile önerilen yöntemin başarımının nitel gözleminin gerçekleştirilmesine imkân verilmiştir. Önerilen yöntem ile ÇGNT işlemi yüksek başarımla ve performans ile gerçekleştirilmiştir.

Kaynaklar

- [1] Chen W, Cao L, Huang K. A novel solution for multi-camera object tracking. 2014 IEEE International Conference on Image Processing (ICIP); 2014; pp. 2329-2333.
- [2] Jahanshahi P, Masoud A, Moghadam E. Multi-view tracking using Kalman filter and graph cut. 2015 AI & Robotics (IRANOPEN);2015; Qazvin. pp. 1-5.
- [3] Yun Y, Gu I, Aghajan H. Maximum-likelihood object tracking from multi-view video by combining homography and epipolar constraints. 2012 Sixth International Conference on Distributed Smart Cameras (ICDSC); 2012; Hong Kong. pp. 1-6.
- [4] Chen Z, Liao W, Xu B, Liu H, Li Q, Li H, Yang D. Object Tracking over a Multiple-Camera Network. 2015 IEEE International Conference on Multimedia Big Data; 2015; Beijing. pp. 276-279.
- [5] He L, Liu G, Tian G, Zhang, J, Ji, Z. Efficient Multi-View Multi-Target Tracking Using a Distributed Camera Network. IEEE Sensors Journal; 2020; vol 20; no 4; pp. 2056-2063.
- [6] Qian Y, Yu L, Liu W, Hauptmann A. ELECTRICITY: An Efficient Multi-camera Vehicle Tracking System for Intelligent City. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW); Seattle; 2020. pp.2511-2519.
- [7] Chou Y S, Wang C Y, Chen M C, Lin S D, Liao H Y M. Dynamic Gallery for Real-Time Multi-Target Multi-Camera Tracking. 2019 16th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS); Taipei, Taiwan; 2019. pp.1-8.
- [8] Ong J, Vo B T, Vo B N, Kim D Y, Nordholm S. A Bayesian Filter for Multi-view 3D Multi-object Tracking with Occlusion Handling. IEEE Transactions on Pattern Analysis and Machine Intelligence. 2020.
- [9] Zhang X, Izquierdo E. Real-Time Multi-Target Multi-Camera Tracking with Spatial-Temporal Information. 2019 IEEE Visual Communications and Image Processing (VCIP); Sydney; Australia; 2019. Pp. 1-4.
- [10] Liu X, Dong Y, Deng Z. Deep Highway Multi-Camera Vehicle Re-ID with Tracking Context. 2020 IEEE 4th Information Technology, Networking, Electronic and Automation Control Conference (ITNEC); 2020; Chingqing; China. pp. 2090-2093.
- [11] Zhou W, Li Z, Gao P. Research on Moving Object Detection and Matching Technology in Multi-Angle Monitoring Video. 2019 IEEE 8th Joint International Information Technology and Artificial Intelligence Conference (ITAIC); 2019; ; Chingqing; China. pp. 741-744.
- [12] Del Rosario J R B, Bandala A A, Dadios E P. Multi-view multi-object tracking in an intelligent transportation system: A literature review. In 2017IEEE 9th International Conference on Humanoid, Nanotechnology, Information Technology, Communication and Control, Environment and Management (HNICEM); 2017; Manila. pp. 1-4.

- [13] Gozhyj A, Kalinina I, Gozhyj V. Fuzzy cognitive analysis and modeling of water quality. In Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications (IDAACS);2017; Bucharest. pp. 289-293.
- [14] Pajares G, Jesús M. Fuzzy cognitive maps for stereovision matching. Pattern Recognition; 2007; 39(11). pp.2101-2114.
- [15] Chen CT, Chiu YT. A study of fuzzy cognitive map model with dynamic adjustment method for the interaction weights, 2016 International Conference on Advanced Materials for Science and Engineering (ICAMSE); 2016; Tainan. Pp.699-702.
- [16] Miao Y. Modelling dynamic causal relationship in fuzzy cognitive maps. 2014 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE); 2014; Beijing. pp.1013-1020.
- [17] Mazzuto G, Ciarapica FE, Stylios C, Georgopoulos VC. Fuzzy Cognitive Maps designing through large dataset and experts' knowledge balancing. 2018 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE); Rio de Janeiro; 2018. pp.1-6.
- [18] Bhutani K, Kumar M. Fuzzy inference system & fuzzy cognitive maps based classification. 2015 International Conference on Advances in Computer Engineering and Applications; 2015. pp.305-309.
- [19] Georgopoulos VC, Stylios CD. Fuzzy cognitive maps for decision making in triage of non-critical elderly patients. 2017 International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS);2018;Okinawa. Pp. 225-228.
- [20] Poczeta K, Kubus L, Yastrebov A. Analysis of an evolutionary algorithm for complex fuzzy cognitive map learning based on graph theory metrics and output concepts. Biosystems;179;2019. Pp.39-47.
- [21] Altundoğan TG. Derin öğrenme kullanan dinamik bulanık bilişsel haritalar ile gerçek zamanlı nesne takibi. Yüksek Lisans Tezi. Fırat Üniversitesi, Elazığ, 2019.
- [22] Altundogan TG, Karakose M. A New Deep Neural Network Based Dynamic Fuzzy Cognitive Map Weight Updating Approach. In 2019 International Artificial Intelligence and Data Processing Symposium (IDAP);2019;Malatya, pp. 1-6.
- [23] Altundogan TG, Karakose M. Multiple Object Tracking with Dynamic Fuzzy Cognitive Maps Using Deep Learning. In 2019 International Artificial Intelligence and Data Processing Symposium (IDAP);2019;Malatya, pp. 1-5.
- [24] Altundogan TG, Karakose M. Genetic Algorithm Based Fuzzy Cognitive Map Concept Relationship Determination and Sigmoid Configuration. In 2020 IEEE International Symposium on Systems Engineering (ISSE);2020; Vienna pp. 1-5.
- [25] Altundoğan, TG, Karaköse M. An Approach for Online Weight Update Using Particle Swarm Optimization in Dynamic Fuzzy Cognitive Maps. In 2018 3rd International Conference on Computer Science and Engineering (UBMK); 2018; Sarajevo (pp. 1-5). IEEE.