

Video Olay Tanıma Sistemleri için bir Veri Üretim Yazılımının Gerçekleştirilmesi

Karani Kardeş

Havelsan A.Ş., Komuta Kontrol ve Savunma Teknolojileri Direktörlüğü, 06510, Çankaya,
Ankara - Türkiye.
kkardas@havelsan.com.tr

Özet. Video sistemlerinin kurulum ve kullanım maliyetlerinin azalması ve bu sistemlerin açık alanlardaki güvenliğe katkısı nedenleri ile kişi tespit-takip yapabilen ve aktörler arası gerçekleşen olayları tanımaya çalışan gözetim video sistemleri yazılımları gün geçtikçe yaygınlaşan aktif bir çalışma konusudur. Makine öğrenmesi yöntemleri kullanılan bu çalışmalarda öğrenilen yöntemlerin ve modellerin başarısının ölçümü için test verilerine olan ihtiyaç büyüktür. Gerek öğrenme sürecinde gerek de test aşamasında kullanılacak veri kümelerinin büyüklüğü geliştirilen tanıma sisteminin başarısını önemli ölçüde etkiler. Özellikle arka plan çıkarımı ve nesne takibi gibi alt seviye işlemleri yapmadan, bu alt seviye üzerine geliştirilen video olay tanıma yazılımlarının testlerinde perspektif problemlerinden bağımsız, kamera kalibrasyonu gibi ayarlar ile uğraşmadan hızlı bir şekilde test veri ihtiyacının karşılanması önemlidir. Bu çalışma, video olay tanıma sistemleri için test verilerinin oluşturulması için geliştirilmiş bir yazılımı sunar. Bu bağlamda, çalışmada sahne tasarımı, aktör ve olay tanımlarının kullanıcı tarafından tanımlanabileceği bir Test Verisi Üretim Yazılımı tanıtılmaktadır. Geliştirilen bu yazılım ile üretilen test verilerinin gerçek bir olay tanıma sisteminde başarılı bir şekilde kullanımı gösterilmiştir.

Anahtar Kelimeler: Test Verisi Üretimi, Gözetim Videoları, Olay Tanıma.

Development of a Data Generation Software for Video Event Recognition Systems

Abstract. Surveillance video systems software, which is able to detect and track people and recognize the events that occur between actors, is an active topic due to the decrease in the installation and usage costs of video systems and the contribution of these systems to public security. There is a great need for test data for evaluating the success of the methods and models learned in these studies using machine learning methods. The size of the datasets that can be used both in the learning process and in the test phase significantly impacts the success of the developed event recognition system. In particular, it is important to quickly meet the test data needs without camera calibration or

perspective problems in the testing of video event recognition software in which there is no low level operations such as background subtraction and object tracking. This work presents test data generation software for video event recognition systems. In this respect, we present a Test Data Generation Software in which scene design, actor and event definitions can be defined by the user. Successful use of generated test data by the developed software in a real event recognition system is demonstrated in the paper.

Keywords: Test Data Generation, Surveillance Videos, Event Recognition.

1 Giriş

Video kamera sistemlerinin kurulum ve kullanım maliyetlerinin azalması, açık alan güvenlik alanında gözetim kamera sistemlerinin kullanımını yaygınlaştırmıştır. Olası bir olay durumunda sistemler tarafından kaydedilen videoların insanlar tarafından izlenerek çıkarımların yapılması uzun zaman ve emek gerektirir. Otomasyonu arttırarak bu dezavantajları azaltma amacıyla videolarda takip ve olay çıkarım kabiliyetlerine sahip olay tanıma yazılımları, üzerinde çalışılan önemli bir konudur. Bu yazılımlar sayesinde günümüz video analiz sistemleri, basit görüntü kaydı yapan sistemlerden öteye geçerek insan kaynağı ihtiyacını ve olaylara müdahale süresini azaltır. Böylece bu sistemlerin açık alanlardaki güvenliğe katkısı artar.

Videolarda olay tanıma yazılımları, videoların otomatik olarak incelenmesi ve gerçekleşmiş olayların bulunmasını sağlar. Videolarda olay tanıma, üzerinde çalışılan önemli konulardan biridir [1]. Videolarda bulunmaya çalışılan olaylar “Koşma”, “Durma” ve “Yürüme” gibi tek aktörün meydana getirdiği aktiviteler olabileceği gibi “Toplanma”, “Birlikte Yürüme”, “Kovalama” ve “Kavga” gibi birden fazla aktörün birlikte meydana getirdiği daha karmaşık olaylar olabilir.

Olay tanıma işlemi amaca ulaşmak için belli adımlardan oluşmaktadır. Başarılı olay tanıma işlemleri makine öğrenmesi yöntemlerini içerir ve genel olarak seçilen olay model yöntemine göre olay modelleri, öğrenme verileri yardımı ile öğrenilerek modellenir. Daha sonra modelin kalitesini ölçme adına öğrenme işleminde kullanılmamış başka test verileri ile modellerin kalitesi test edilir. Gerek öğrenme ve gerek de test aşamasında kullanılmak üzere test verilerinin önemi kullanılan makine öğrenmesinin başarısında büyük rol oynar. Test verilerinin büyüklüğü geliştirilen tanıma sisteminin başarısını önemli ölçüde etkiler.

Olay tanıma işlemi genel olarak alt seviye işlemler ve üst seviye işlemlerden oluşur. Alt seviye işlemler arka plan çıkarımı, nesne tanıma ve takip gibi piksel tabanlı işlemlerdir. Üst seviye işlemler ise alt seviyeden çıkarımı yapılmış aktör ve onların takip ettiği yol bilgilerinin anlamlandırılması ile ortaya çıkan olay modelleri kullanılarak karmaşık ilişkilerin ve olayların çıkarımından oluşur. Özellikle alt seviye işlemleri yapmayan ve üst seviye işlemlere yoğunlaşan çalışmalarda aktörler ile nesnelere belirlenmiş ve hareket takipleri yapılarak elde edilmiş aktörlerin hareket bilgilerinden oluşan test verilerini bulup kullanmak önemlidir. Günümüzde video çekimi ile uğraşmadan hatta video çekimi sonrası arka plan çıkarımı, nesne tanıma ve takip gibi alt seviye problemleri ile uğraşmadan perspektif problemlerinden bağımsız üretilmiş video verisi bulmak hayli zordur. Üstelik video çekimi yapmak ve bahsedilen alt seviye işlemler yaparak üst seviye için test verisi oluşturmak maliyetli,

zahmetli ve hataya yatkın bir süreçtir. Bu nedenlerle üst seviye algoritmalarının hızlı bir şekilde testlerinin yapılabilmesi için hazır veriseti bulmak ve oluşturmak olay tanıma sistemleri için önemlidir.

Bu çalışmada yukarıda önemi ve kullanım amacı bahsedilen test verilerinin üretimini gerçekleştirme amaçlı, gözetim videoları için sahne tasarımı, aktör ve olay tanımlarının kullanıcı tarafından tanımlanabileceği esnek bir sentetik veri üretimi yazılımı geliştirilmiştir. Çalışma kapsamında, oluşturulan sentetik verilerin gerçek bir uygulamada kullanımı gösterilmiştir. Böylece test verisinin kısıtlı olduğu zamanlarda, kullanıcıların gerçekleştirdikleri olay tanıma yazılımlarının testini yapabilmek için ihtiyaç duyacakları test verileri etkili bir şekilde sağlanmış olur.

Bildiri şu şekilde organize edilmiştir: ikinci bölümde literatür taraması sonuçları sunulmuş ve bu konudaki yer alan diğer çalışmalar hakkında bilgiler verilmiştir. Üçüncü bölümde geliştirilen yazılım detaylı bir şekilde sunulmuştur. Dördüncü bölümde geliştirilen yazılımı kullanarak yapılan deneyler anlatılmıştır. Son bölümde uygulamanın artı ve eksi yönleri tartışılmış, sonuçlar ve gelecek çalışmalar değerlendirilmiştir.

2 İlgili Çalışmalar

Literatür incelendiğinde olay tanımanın yapay zeka ve görüntü işleme alanlarında son yıllarda aktif olan bir konu olduğu görülür. Bu bağlamda, olay tanıma konusunda farklı makine öğrenmesi yöntemini kullanan birçok çalışma vardır. Örneğin [2] çalışmasında kural tabanlı yöntemler kullanılmıştır. [3], [4] ve [5] çalışmalarında Sinir Ağları, Bayes Ağları, Saklı Markov Modelleri, Sonlu Durum Makineleri gibi olasılık içeren modeller kullanılmıştır. [6] çalışmasında ise Karar Ağaçları yöntemi olay tanıma metodu olarak kullanılmıştır. Konu Modelleri ve Kelime Çantası yaklaşımları da [7] ve [8] gibi çalışmalarda zamanı dikkate almayan yöntemler olarak olay tanıma işlemlerinde kullanılmıştır. Bazı çalışmalarda ise anlamsal modeller kullanılmıştır. Örneğin [9] çalışmasında Petri Net, [10] ve [11] çalışmalarında ise mantık tabanlı yaklaşımlar ve [12] çalışmasında Kısıt Tatmini yöntemi kullanılmıştır. [13] ve [14] çalışmalarında ise son zamanlarda performans yönünden etkinliği ile ön plana çıkan Derin Öğrenme yöntemi kullanılmıştır. Hem olasılık tabanlı oluşu hem de anlamsal modeller sunması nedenleri ile Markov Mantık Ağları yöntemi [15] ve [16] çalışmalarında kullanılan önemli bir makine öğrenmesi yöntemidir.

Yukarıda bahsedilen olay tanıma için kullanılan makine öğrenmesi yöntemlerinin her birinin farklı avantaj ve dezavantajları vardır. Ancak tüm makine öğrenmesi yöntemlerinde olan ortak özellik öğrenme ve test verilerine olan büyük ihtiyaçtır. Özellikle alt seviye işlemleri yapmadan üst seviye işlemlere yoğunlaşan olay tanıma çalışmalarında aktörler ve nesnelere belirlenmiş ve hareket takipleri yapılarak elde edilmiş aktörlerin hareket bilgilerinden oluşan test verilerini bulmak önemlidir. Literatürde bu bağlamda gözetim videoları için geliştirilmiş ve çıkarımları yapılarak XML formatında işaretlenmiş veri setlerinden en önemlileri CAVIAR [17] ve BEHAVE [18] Verisetleridir. Bu verisetleri XML formatında olduğu için alt seviye yeteneklerine sahip olmayan uygulamalar için çok önemlidir. Bu verisetlerinde her bir video kullanıcı yardımı ile işaretlenmiş, videonun ilgili bölümlerindeki aktörler etiketlenmiş ve aktörlerin birbirleri arasındaki olaylar belirtilmiştir. Şekil 1 CAVIAR

Veriseti'nden örnek bir XML verisini göstermektedir. Şekil 1'den de görüldüğü gibi bu veriseti aktörlerin piksel olarak pozisyon, genişlik ve boy bilgilerini her bir video çerçevesi (frame) için tutar. Ek olarak aktörün yapmış olduğu ve aktörler arası gerçekleştirilmiş olan olaylar yer alır.

```
</groupplist/>
</frame>
<frame number="284">
  <objectlist>
    <object id="1">
      <orientation>160</orientation>
      <box yc="173" xc="89" w="41" h="23"/>
      <appearance>visible</appearance>
      <hypothesislist>
        <hypothesis id="1" prev="1.0" evaluation="1.0">
          <movement evaluation="1.0">walking</movement>
          <role evaluation="1.0">walker</role>
          <context evaluation="1.0">walking</context>
          <situation evaluation="1.0">moving</situation>
        </hypothesis>
      </hypothesislist>
    </object>
    <object id="2">
      <orientation>130</orientation>
      <box yc="70" xc="188" w="48" h="40"/>
      <appearance>visible</appearance>
      <hypothesislist>
        <hypothesis id="1" prev="1.0" evaluation="1.0">
          <movement evaluation="1.0">walking</movement>
          <role evaluation="1.0">walker</role>
          <context evaluation="1.0">walking</context>
          <situation evaluation="1.0">moving</situation>
        </hypothesis>
      </hypothesislist>
    </object>
  </objectlist>
</frame>
<frame number="285">
```

Şekil 1. CAVIAR Video Veriseti'nden Örnek Bir XML Verisi

CAVIAR ve BEHAVE Verisetleri gözetim videolarında olay tanıma çalışmalarında literatürde oldukça yaygın kullanılmıştır. Örneğin [5], [6], [10], [11] ve [19] çalışmalarında CAVIAR Veriseti, [20], [21], [22], [23] ve [24] çalışmalarında ise BEHAVE Veriseti kullanılmıştır. [16] gibi bazı çalışmalarda ise her iki veriseti de kullanılmıştır.

CAVIAR Video Veriseti 28 adet elle işaretlenmiş açık alanda çekilmiş videodan oluşur. Bu verisetinde “Koşma”, “Durma”, “Yürüme”, ve “Ani Hareket” olmak üzere dört tip temel aktivite ve “Kavga”, “Bırakılan Nesne” ve “Toplanma” olmak üzere üç tip de olay tanımlıdır. CAVIAR Verisetinde, işaretlenmiş video çerçeve sayısı “Koşma” için 406, “Durma” için 2934, “Yürüme” için 14134 ve “Ani Hareket” için 1872'dir. Veri sayısındaki bu heterojenlik, CAVIAR Veriseti'nin başarılı kullanımını zorlaştırmakta öğrenme algoritmasının olayları başka olaylarla karıştırmasına sebep olmaktadır. Ayrıca CAVIAR Veriseti'nde, tanımlı olay sayısı oldukça azdır. Örneğin “Toplanma” olayı için 6, “Kavga” olayı için 3 ve “Bırakılan Nesne” için 4'tane olay verisi vardır. Veri sayılarının bu şekildeki az oluşu da, bu veri setinin başarılı kullanımını zorlaştıran diğer bir önemli faktördür. CAVIAR Video Verisi'nden örnek bir görüntü Şekil 2'de gösterilmiştir.



Şekil 2. CAVIAR Video Veriseti'nden Örnek Bir Görüntü

BEHAVE Veriseti toplam olarak 76800 video çerçevesinden oluşur. Videoların çözünürlüğü ise 640x480 pikseldir. Bu verisetinde “Birleşme”, “Yaklaşma”, “Birlikte Yürüme”, “Ayrılma”, “İzleme”, “Kovalama”, “Kavga”, “Birlikte Koşma” ve “Tanışma” olayları tanımlıdır. Ancak bu verisetinde de olay sayıları CAVIAR verisetinde olduğu gibi homojen değildir. Bazı olay tipleri için çok fazla veri varken bazıları için çok az veri vardır. Örneğin “Birleşme”, “Yaklaşma”, “Birlikte Yürüme” ve “Ayrılma” olaylar için sırasıyla 35, 25, 43 ve 23 olay verisi varken, “İzleme” ve “Tanışma” olayları için sadece birer olay verisi tanımlanmıştır. BEHAVE Veriseti'nden alınan örnek görüntüler Şekil 3’de gösterilmiştir.



Şekil 3. BEHAVE Video Veriseti'nden Örnek Görüntüler

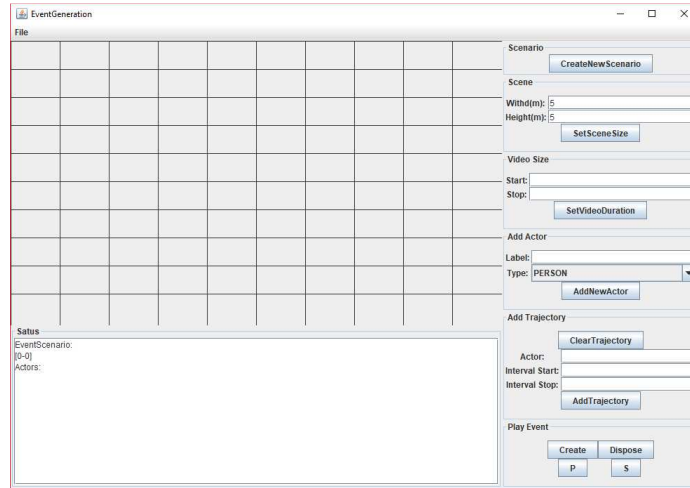
Mevcut çalışmalar genel olarak değerlendirildiğinde yukarıda da bahsedildiği gibi özellikle üst seviye olay tanıma çalışmaları için geliştirilmiş olan CAVIAR ve BEHAVE Verisetleri ön plana çıkmaktadır. Ancak bu verisetlerinin bazı eksiklikleri vardır. Öne çıkan en büyük problem bu verisetleri hazırlanırken kullanılan kamera parametrelerine göre oluşan perspektif problemidir. Kameralar tam tepeden bakacak şekilde olmadığı için bu problem ortaya çıkar. Özellikle CAVIAR Veriseti'nde kullanılan bombeli kamera nedeni ile oluşan perspektif problemi büyüktür. Bu verisetlerinde düzgün çalışmalar yapılabilmesi için kalibrasyon işlemleri gereklidir. Her ne kadar bu verisetleri kısmi kalibrasyon parametreleri sağlasa da verilerin düzeltilmesi zordur ve düzeltme işlemi sonrası bile elde edilen veriler tam tepeden bakan görüntülerden elde edilen veriler kadar başarılı olamaz. Bu verisetlerinde

dikkate alınan önemli bir diğer problem ise verisetlerinde tanımlı olan olayların sayılarının arasında büyük farklar olmasıdır. Verisetleri arasındaki büyük farklar çıkarılan olayların birbirleri ile karıştırılmasına sebep olur. Son olarak dikkate alınabilecek diğer bir problem de veriseti sayısının bazı olay tipleri için çok az ve farklı senaryoları içermeleri nedenleri ile tutarsız oluşudur. Örneğin [19] çalışmasında CAVIAR Veriseti'ndeki "Toplanma" verisi için bu durum dile getirilmiştir.

Yukarıda bahsedilen problemler bütünüyle dikkate alındığında ve yeni olay videolarının çekimi ile olay çıkarımı işlemlerinin zaman alıcı ve maliyetli oluşu göz önüne alındığında sentetik veri üretme yazılımına olan ihtiyacın büyük olduğu görülür. Bu bildiride önerilen çalışma ile literatürdeki bu eksikliğin giderilmesi hedeflenmiş, tam tepeden bakan istenen sayıda olay verilerinin alt seviye işlemlere gerek kalmadan üretilebilmesi sağlanmıştır.

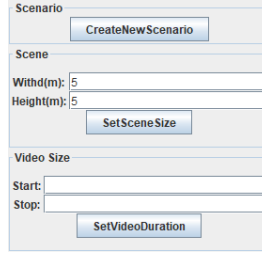
3 Test Verisi Üretim Yazılımı

Test Verisi Üretimi Yazılımı farklı olay tipleri için test verisi hazırlanmasını sağlayan bir uygulama aracıdır. Bu uygulama ile esnek bir şekilde sahne modellenebilir ve olay senaryoları hazırlanabilir. $50\text{ cm} * 50\text{ cm}$ boyutlarındaki ızgaralardan oluşan değişik büyüklükteki sahneler oluşturulabilir. Izgara büyüklüğünün $50\text{ cm} * 50\text{ cm}$ olarak sabit seçilmesinin sebebi bu büyüklüğün yaklaşık olarak bir aktörün etki alanını kapsamasıdır. Oluşturulan senaryolar tam tepeden bakış şeklinde oluşturulduğundan perspektif problemlerinden bağımsızdır ve kalibrasyona ihtiyaç duyulmaz. İnsan, araba ve nesne gibi farklı aktör tipleri tanımlanabilir. Nesnelere, çanta gibi özellikle gözetim videolarındaki olaylarda yer alabilecek muhtemel aktörlerdendir. Senaryo oluşturulurken her bir aktör için hareket bilgileri zaman aralıkları verilerek girilebilir. Hareket bilgileri sahne ızgaraları işaretlenerek belirtilebilir. Oluşturulan senaryolar izleme ve kontrol amacıyla bir akan video gibi oynatılabilir. Şekil 4'te Test Verisi Üretimi Yazılımı'nın ana kullanıcı ekranı gösterilmiştir.



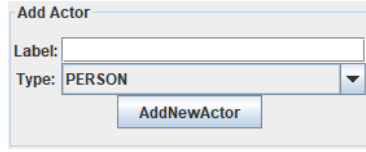
Şekil 4. Test Verisi Üretim Yazılımı'nın Ana Kullanıcı Ekranı Görüntüsü

Sahne yapısı ve video uzunluğu bilgileri ana ekranın sağ üstünde yer alan “Scene” ve “Video Size” kullanıcı bileşenlerinden tanımlanabilir (Şekil 5). Sahne yapısı metre cinsinden girilir böylece 50 cm’lik ızgaralardan oluşan sahne tasarlanır. Video süresi de başlangıç ve bitiş saniyeleri olarak girilir.

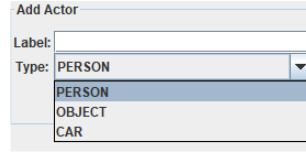


Şekil 5. Sahne ve Video Bilgilerinin Girilmesi

Senaryoda yer alacak aktörler tipleri ile birlikte “Add Actor” isimli aktör ekleme kullanıcı bileşeni ile eklenebilir (Şekil 6). Sistemde şu an için geçerli aktör tipleri İnsan, Nesne ve Araba tipleridir (Şekil 7).

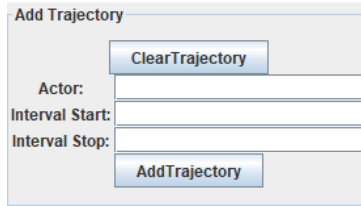


Şekil 6. Aktör Ekleme Bileşeni




Şekil 7. Tanımlı Aktör Tipleri

Şekil 8’de gösterilen “Add Trajectory” isimli kullanıcı bileşeni ve ana ekranın solunda bulunan ızgaralar kullanılarak aktör hareketi tanımlanabilir. Her bir aktör hareketi için hareket şekli zaman aralığı ile birlikte verilerek ve ızgaralar üzerinde işaretlenerek tanımlama yapılabilir. Zaman aralığı “Add Trajectory” isimli kullanıcı bileşeninden belirlenir.



Şekil 8. Aktör Hareketi Tanımlama Kullanıcı Arayüzü Bileşeni

Oluşturulan senaryolar ekranın sağ alt kısmında bulunan “Play Event” isimli kullanıcı bileşeni kullanılarak oynatılabilir (Şekil 9). Bu bileşen ile “senaryo oynatma oluşturma”, “oynatılan senaryoyu kapatma”, “senaryo oynatımını başlatma” ve “oynayan senaryoyu durdurma” işlemleri yapılabilir.




Şekil 9. Senaryo Oynatma Kullanıcı Arayüzü Bileşeni

Oluşturulan senaryolar hakkındaki tüm detaylı bilgiler ana ekranın alt kısmında bulunan ve Şekil 10’da gösterilen bilgi ekranında ayrıntılı olarak listelenir.




Şekil 10. Bilgi Ekranı Kullanıcı Arayüzü Bileşeni

Ana ekran menüsünden “dosyadan senaryo açma” ve “dosyaya senaryo kaydetme” işlemleri ile oluşturulan senaryoların kayıt işlemleri Şekil 11’de gösterildiği gibi yapılabilir.



Şekil 11. Senaryo Açma/Kaydetme

Oluşturulmuş ve oynatılan örnek bir senaryo Şekil 12’de gösterilmiştir.



Şekil 12. Örnek Bir Senaryo Gösterimi

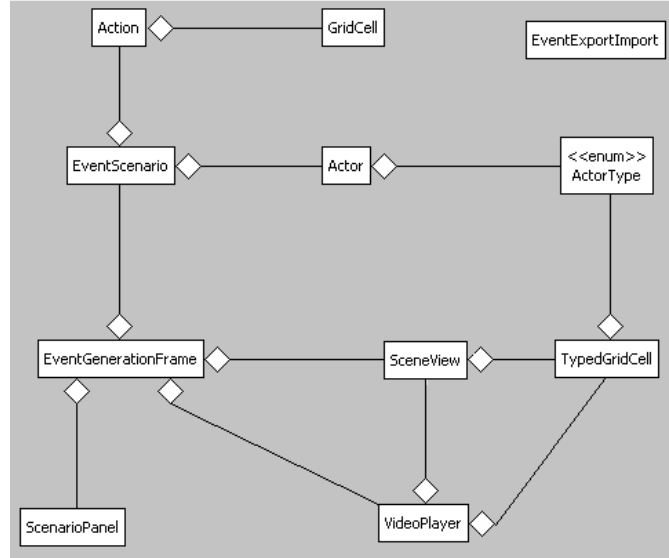
Bu araç ile bazı aktivite ve olaylar için oluşturulan örnek senaryolar Tablo 1’de gösterilmiştir.

Tablo 1. Oluşturulan Örnek Senaryolar

Durma	Yürüme	Karşılaşma	Bırakılan Nesne
VideoInterval:1-8 SceneTag:15-15 Actors:1 1-PERSON Int:1-1-8-17-26-17-26	VideoInterval:1-10 SceneTag:15-15 Actors:1 2-PERSON Int:2-1-10-9-19-15-19	Video Interval: 1-15 Scene: 5-5 Actors: 2 0-PERSON 1-PERSON Int: 0-1-5-0-5-4-5 Int: 0-5-10-4-5-4-5 Int: 0-10-15-4-5-0-5 Int: 1-2-5-9-5-5-5 Int: 1-5-10-5-5-5-5 Int: 1-10-15-5-5-9-5	VideoInterval:1-20 SceneTag:10-10 Actors:2 0-PERSON 1-OBJECT Int:0-1-20-0-7-19-7 Int:1-1-12-0-6-11-6 Int:1-12-20-11-6-11-6

Tablo 1’den görüldüğü gibi oluşturulan senaryolar ile ilgili video uzunluğu, sahne büyüklük bilgileri, aktörler hakkındaki bilgiler ve her bir aktörün o video içindeki belli zaman aralıklarında yapmış oldukları hareket, pozisyon bilgileri ile birlikte tutulur.

Test Verisi Üretim Yazılımı *Java* programlama dili kullanılarak geliştirilmiştir. Uygulamanın sınıf modeli ise Şekil 13’te gösterilmiştir.



Şekil 13. Uygulamanın Sınıf Diyagramı

Action sınıfı oluşturulmuş aktivite için kullanılan veri yapısıdır. Zaman aralıkları ve hareket güzergahındaki ızgara bilgilerini tutar. Izgara hücrelerinin konum bilgilerini ve sırasını tutan veri yapısı *GridCell* sınıfıdır. *EventScenario* sınıfı

oluşturulan senaryoları modelleyen veri yapısıdır. Bu sınıf, aktör bilgilerini ve aktörlerin meydana getirdiği aktivite bilgilerini tutar. Sistemin bir diğer önemli sınıfı olan *Actor* sınıfı isim ve tip gibi aktör bilgilerini tutar. *ActorType* sınıfı sistemde tanımlı aktör tiplerini yansıtan sınıftır. “Araba”, “Nesne” ve “İnsan” şu an için sistemde tanımlı mevcut tiplerdir.

Kullanıcı arayüzü bileşenlerini içeren ve ana ekranı yansıtan arayüz bileşen sınıfı *EventGenerationFrame* sınıfıdır. *ScenarioPanel* sınıfı kullanıcı tarafından senaryo bilgilerinin girilebildiği ve ana ekranın sol tarafını oluşturan kullanıcı bileşenidir. Tasarlanmış sahnenin hücre sayıları gibi bilgilerini tutan sahneyi modellemek için geliştirilmiş veri yapısı ise *SceneView* sınıfıdır. *TypedGridCell* sınıfı aktörlerin hareketi içinde yer alan ve işaretlenmiş ızgara bilgilerini yansıtan sınıftır. *VideoPlayer* sınıfı oluşturulmuş senaryoyu zamana göre sahne üzerinde görsel olarak oynatmakla sorumlu sınıftır. Son olarak *EventExportImport* sınıfı ise oluşturulan senaryoları dosyaya yazan veya oluşturulmuş senaryoları inceleme/değiştirme amaçlı açılmasını sağlayan sınıftır.

4 Deneyler

Geliştirilen Test Verisi Üretim Yazılımı, SVAS (Surveillance Video Analysis System) [16] çalışmasında farklı olay senaryoları için daha fazla test verisi ile güvenilirlik analizi amacıyla kullanılmıştır. SVAS, gözetim videoları için geliştirilmiş aktivite ve olay tanıma yeteneklerine sahip birçok makine öğrenmesi tekniğini farklı fazlarda kullanan bir analiz sistemidir. Bu analiz sisteminde CAVIAR ve BEHAVE Verisetleri kullanılmış, ancak yukarıdaki bölümlerde belirtilen bazı problemlerden bağımsız, maliyetsiz, hızlı bir şekilde test veri ihtiyacının karşılanması amacıyla Test Verisi Üretim Yazılımı ile SVAS kapsamında 135 tane video verisi üretilerek ve SVAS'ın sentetik veri ihtiyacı karşılanarak olay tanıma kabiliyeti test edilmiştir. Bu deney kapsamında hem “Koşma”, “Durma” ve “Yürüme” aktiviteleri için hem de “Kovalama”, “İzleme”, “Bırakılan Nesne”, “Toplanma”, “Birlikte Yürüme” ve “Birlikte Koşma” olayları için test verileri üretilmiştir. Üretilen test verilerinin bazı bölümleri rastgele silinerek SVAS'ın gürültü sebebi ile oluşabilecek eksik verilere duyarlılığı da test edilmiştir. Elde edilen sonuçlar Tablo 2'de gösterilmiştir.

Tablo 2. SVAS Çalışmasındaki Sentetik Veri Testi Sonuçları

Öğrenme Verisi Başına Silinen Değer (saniye)	Olay Bulma Sayısı	Olay Bulma Yüzdesi
Silinen Değer Yok	135	100 %
0.5 saniye	112	82.9 %
1 saniye	98	72.6 %
2 saniye	67	49.6 %
3saniye	0	0 %

Tablo 2’de gösterildiği gibi SVAS, Test Verisi Üretim Yazılımı ile üretilen verileri kullanarak başarılı öğrenme ve tanıma işlemlerini yapabilmiş ve sentetik olarak

üretmiş olayların tamamını bulabilmiştir. Sentetik olarak üretilen video verilerinin uzunluğu maksimum beş saniye olarak üretildiği için video verisindeki gürültülere bağlı veri kayıplarını simüle etme amacıyla silinen saniyelerin etkisi büyüktür. Yine de test videolarının uzunlukları dikkate alındığında SVAS sistemi için silinen verilere karşı duyarlılığı %10 ile %20 arasında olduğu söylenebilir.

5 Sonuçlar ve Değerlendirme

Bu çalışmada, video olay tanıma sistemleri için test verilerinin oluşturulması amacıyla geliştirilmiş bir Test Verisi Üretim Yazılımı sunulmuştur. Literatürdeki video verileri için oluşturulmuş açık verisetleri hakkında detaylı bilgiler verilmiş, sunulan yazılım ile üretilen veriler arasındaki farka değinilmiştir. Ayrıca, geliştirilen bu yazılım ile üretilen test verilerinin SVAS isimli gerçek bir olay tanıma sisteminde başarılı bir şekilde kullanımı gösterilmiştir. Önerilen yazılım ile özellikle üst seviye olay tanıma uygulamalarının kullandıkları makine öğrenmesi yöntemlerinin test verisi ihtiyacı giderilebilir. Esnek yapısı sayesinde kullanıcılar, sahne tasarımı, aktör ve olay tanımlarını perspektif problemlerinden bağımsız ve kalibrasyon ayarlamaları ile uğraşmadan kolay bir şekilde yaparak istenilen tipte video test verileri ve istenilen karmaşıklıkta olay senaryoları üretilebilirler.

Gelecek çalışma olarak, önerilen yazılımın hareketli ve çoklu kameralardan elde edilen verileri simüle edecek şekilde geliştirilmesi hedeflenmektedir. Ayrıca sisteme gözetim videolarındaki ihtiyaç duyulabilecek başka aktivite tiplerinin de eklenmesi planlanmaktadır. Yazılım şu an için aktör hareketlerini en az bir saniyelik aktiviteler olarak tanımlayabildiğinden “Kavga” olayı gibi aktörlerin ani hareketlerini içeren olaylar için tanımlama yapamamaktadır. Bu tip olayların da tanımlanmasının yapılabilmesi için yazılımın hızlı meydana gelen aktiviteleri de modelleyebilecek hale getirilmesi planlanmaktadır. Bu bağlamda özellikle gözetim videoları için önemli olan aktörlerin ani hareketlerini yansıtan modellerin yazılıma kazandırılması hedeflenmektedir.

Kaynakça

1. Lavee, G., Rivlin, E., Rudzksy, M.: Understanding video events: A survey of methods for automatic interpretation of semantic occurrences in video. *Man, and Cybernetics, Part C: Applications and Reviews, IEEE Transactions*, vol 39 (5), pp. 489–504. (2009).
2. Antoniou, G.: Rule-Based Activity Recognition in Ambient Intelligence. *Rule-Based Reasoning, Programming, and Applications*, p. 1. (2011).
3. Lv, F., Song, X., Wu, B., Singh, V. K., Nevatia, R.: Left-Luggage Detection using Bayesian Inference. In *Proceedings 9th IEEE International Workshop Perform. Eval. Tracking Surveillance*, pp. 83-90. (2006).
4. Oliver, N., Horvitz, E.: A comparison of HMMs and dynamic bayesian Networks for recognizing office activities. *International conference on user modeling*, Vol. 3538:199-209. (2005).
5. Perez, O., Piccardi, M., Garcia, J., Molina, J. M.: Comparison of Classifiers for Human Activity Recognition. In *International Work-Conference on the Interplay Between Natural and Artificial Computation*: pp. 192-201. (2007).
6. Simon, C., Meessen, J., De Vleeschouwer C.: Visual event recognition using decision

- trees. *Multimedia Tools Applications*, 50(1), pp. 95-121. (2010).
7. Baxter, R., Robertson, N. M., Lane, D.: Real-time event recognition from video via a “bag-of-activities”. In *Proceedings of the UAI Bayesian Modelling Applications Workshop*. (2011).
 8. Wallach, H. M.: Topic modeling: beyond bag-of-words. In *Proceedings of the 23rd International Conference on Machine learning*, pp. 977-984. (2006).
 9. Ghanem, N., DeMenthon, D., Doermann, D., Davis, L., Representation and recognition of events in surveillance video using Petri nets. *IEEE CVPR*, pp. 104–112, (2004).
 10. Skarlatidis, A., Artikis, A., Filippou, J., Paliouras, G.: A probabilistic logic programming event calculus. *Theory and Practice of Logic Programming*, 15(2), pp. 213-224. (2015).
 11. Artikis, A., Sergot, M., Paliouras, G.: A Logic Programming Approach to Activity Recognition. In *Proceedings of ACM International Workshop on Events in Multimedia*, pp. 3-8. (2010).
 12. Reddy, S., Gal, Y., Shieber, S.: *Recognition of Users Activities Using Constraint Satisfaction*. Springer, vol. 5535: 415-421. (2009).
 13. Jhuo, I., Lee, D.T.: Video Event Detection via Multi-modality Deep Learning. *22nd Int. Conf. on Pattern Recognition*, pp. 666-671. (2014).
 14. Scariaa, E., Tb, A. A., Isaacc, E.: Suspicious Activity Detection in Surveillance Video using Discriminative Deep Belief Network. *International Journal of Control Theory and Applications*, 9(43), pp. 261-267. (2016).
 15. Helouai, R., Niepert, M., Stuckenschmidt, H.: Recognizing Interleaved and Concurrent Activities: A Statistical-Relational Approach. In *Proceedings of the 9th Annual IEEE International Conference on Pervasive Computing and Communication*, pp. 1-9. (2011).
 16. Kardas, K., Cicekli, N.K.: SVAS: Surveillance Video Analysis System. *Expert Systems with Applications*, 89, 343-361. (2017).
 17. Yang, B., Nevatia, R.: Multi-Target Tracking by Online Learning of Non-linear Motion Patterns and Robust Appearance Models. In *Proceedings of IEEE Computer Vision and Pattern Recognition (CVPR)*, pp. 1918-1925. (2012), <http://homepages.inf.ed.ac.uk/rbf/CAVIARDATA1/>, Son Erişim 2018/06/03.
 18. Blunsden, S. J., Fisher, R. B.: The BEHAVE video dataset: ground truthed video for multi-person behavior classification. *Annals of the BMVA*, Vol(4), 1-12. (2010), <http://groups.inf.ed.ac.uk/vision/BEHAVEDATA/INTERACTIONS>, Son Erişim 2018/06/03.
 19. Patino, L., Ferryman J.: Meeting detection in video through semantic analysis. In *Proceedings of 12th IEEE International Conference on Advanced Video and Signal Based Surveillance (AVSS)*, pp. 1-6. (2015).
 20. Al-Raziqi, A., Denzler, J.: Unsupervised Framework for Interactions Modeling between Multiple Objects. In *Proceedings of the 11th Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications (VISIGRAPP 2016) - Volume 4: VISAPP*, pp. 509-516. (2016).
 21. Elhamod, M., Levine, M. D.: Automated Real-Time Detection of Potentially Suspicious Behavior in Public Transport Areas. *IEEE Transactions on Intelligent Transportation Systems*, pp. 688-699. (2013).
 22. Muench, D., Becker, S., Hubner, W., Arens, M.: Towards a Real-Time Situational Awareness System for Surveillance Applications in Unconstrained Environments. *7th Security Research Conference, Future Security*, pp. 517-521. (2012).
 23. Yin, Y., Yang, G., Xu, J., Man, H.: Small Group Human Activity Recognition. In *2012 19th IEEE International Conference on Image Processing (ICIP)*, pp. 2709-2712. (2012).
 24. Zhang, C., Yang, X., Lin, W., Zhu J.: Recognizing Human Group Behaviors with Multi-Group Causalities. In *2012 IEEE/WIC/ACM International Conferences on Web Intelligence and Intelligent Agent Technology (WI-IAT): Vol. 3*, pp. 44-48. (2012).