

PAPER DETAILS

TITLE: Mekansal zekanin getirdigi paradigma degisimi

AUTHORS: Caner GÜNEY

PAGES: 128-142

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/775654>

Mekansal zekanın getirdiği paradigma değişimi

Caner Güney^{1*} 

¹Istanbul Teknik Üniversitesi, Maslak Kampüsü, İnşaat Fakültesi, Geomatik Mühendisliği Bölümü, Sarıyer, İstanbul.

Öz: Niceliksel ve niteliksel olarak artan, veri türü olarak çeşitlenen görüntü kaynaklarından anlamlı ve faydalı bilginin yapay öğrenme temelli olarak üretilmesi giderek yaygınlık kazanmaktadır. Mekansal bilgi sistemi uygulamalarında bilinçli karar verebilmek için nesnelere, olgulara ve içinde bulundukları ortama ilişkin bağlamın, ilişkilerin, örüntülerin ve eğilimlerin yapay öğrenme teknikleri ile belirlenmesi mekansal bilgi sistemi projelerinin başarımını ve verimliliğini arttırmaktadır. Bu tür yönelimler mekansal bilişim endüstrisinde mekansal zeka temelli sistemlerin kullanımını yaygınlaştırmaktadır. Gözlem ve ölçme sistemlerinden bulut ortamında çalışan bilgi sistemlerine kadar geniş bir yelpazede mekansal zeka özellikli çözümler geliştirilebilmektedir. Mekansal zeka özellikli sistemlerin etkin ve verimli biçimde kullanılabilmesi için mekansal zeka kavramının ne olduğu, hangi alanlarda kullanılabileceği ve daha yüksek bir katma değer sağlayabilmesi için nasıl bir yol haritasının oluşturulması gerektiği bu çalışma kapsamında irdelenmeye çalışılmıştır.

Anahtar Sözcükler: Mekansal zeka, Yapay zeka, Makine öğrenmesi, Derin öğrenme, Mekansal bilgi sistemi, Mekansal veri altyapısı

Paradigm shift by spatial intelligence

Abstract: It is becoming prevalent to produce meaningful and useful information based on artificial learning from quantitative and qualitatively increasing data sources. In order to make informed decisions in spatial information system applications, determining the context, relations, patterns and trends related to objects, facts and environment by artificial learning techniques increases the performance and efficiency of spatial information system projects. Such trends will accelerate the spread of GeoAI-based systems in the spatial informatics industry. A wide range of spatial intelligence solutions can be developed from observation and measurement systems to cloud computing information systems. In the scope of the study, it has been examined that first what the concept of spatial intelligence means, then in which areas geospatial intelligence can be utilized, and finally, how to create a road map to provide a higher added value from spatial intelligence.

Keywords: Spatial intelligence, Artificial intelligence, Machine learning, Deep learning, Geospatial information system, Spatial data infrastructure

* Sorumlu Yazar/Corresponding Author: Tel: +90 212 285 3825

Gönderim Tarihi/Received: 02.04.2019
Kabul Tarihi/Accepted: 05.07.2019

1. Giriş

Endüstriyel ekonomiden bilgi ekonomisine, bilgi ekonomisinden de girişim ekonomisine geçilmesi ve 21. yüzyılın başında 4. Endüstri Devrimi (2. Bilgi Devrimi)’nin hız kazanmasıyla, yenilikçi düşünce ile fark yaratma ve yüksek katma değerli ürün geliştirme sürdürülebilir kalkınma için üzerinde en çok durulan konulardan biri olmuştur.

Bulut bilişim, büyük veri, nesnelerin interneti, sanal/arttırılmış/karma gerçeklikler, blok zinciri, kripto-paralar, oyun motorları, robotik, otonom sistemler, siber fiziksel sistemler, akıllı etmenler, yapay zeka, siber güvenlik vb. alanlardaki hızlı gelişim ve bunun sonucunda ortaya çıkan ezber/oyun bozan teknolojiler (*disruptive technologies*) (Christensen, 1997; Yu & Hang, 2010) mühendislik, tasarım, tıp, iktisat, hukuk gibi farklı disiplinleri ve bu disiplinlerin çalışma yöntemlerini evirmektedir. Bu oluşan yeni dijital ekosistemde başarılı olabilmek için hem farklı bir düşünceye sahip bir iş modeli kurabilmek hem de bu iş modeli içerisinde sözü edilen ileri teknolojileri etkin kullanıp değer katabilen ürünler/uygulamalar/çözümler geliştirmek gerekmektedir. Bunun gibi bir ekosistemde hemen hemen her sektörde görülmeye başlayan “Akıllı Şey” ve/veya “Akıllı Sistemler” kavramları dijital dönüşümde ve dijital ekonomide önemli yer almakta ve böylelikle problem çözme veya karar verme aşamaları daha akıllı biçimde gerçekleştirilebilmektedir.

İnsanoğlunun sosyal medya üzerinde sürekli konum ve zaman etiketli bilgiler paylaşımı, nesnelerin interneti yaklaşımı ile sensörlerin neredeyse her yerde kullanılmaya başlanmış olması ve sürekli veri üretimi, sensörler ve bilgi sistemleri arasındaki bağlantıların artması “akıllılık” kavramının yaygınlaşmasına neden olmaktadır. 21. yüzyılda akıllı kentler, akıllı ulaşım sistemleri, akıllı binalar, akıllı arabalar vb. her şey giderek daha “akıllı” olmaya başlamış ve akıllı cihazlarla iletişim ve problem çözme daha önemli konuma gelmiştir. “Akıllılık” kavramının yaygınlaşması beraberinde birçok zeka kavramını ortaya çıkarmaktadır. İş dünyasında kullanılan iş zekası, rekabetçi zeka, işlemsel zeka, bilgisayar mühendisliği alanında ortaya çıkan ve veri biliminde de sıklıkla kullanılan yapay zeka, malzeme alanında kullanılan fiziksel zeka bu kavramlara örnek olarak verilebilir. Benzer biçimde mekansal bilgi sektöründe de mekansal bilgiden **mekansal zeka** kavramına geçiş süreci başlamıştır (Güney, 2016).

2. Mekansal Zeka

Yerin merkezinden uzayın derinliklerine ve siber dünyaya kadar her yerde gerçekleşen olguların ve insan faaliyetlerinin mekansal modellenmesinde, analizinde, görselleştirilmesinde, mekansal problemlerin çözümünde ve mekansal karar vermede yapay zeka yöntemlerinin yukarıda ifade edilen ileri teknolojilerle birlikte toplum yararına kullanımı **mekansal zeka** (*spatial intelligence, geospatial intelligence - GeoAI, location intelligence - GeoBI*) olarak tanımlanabilir.

Gerçeklik çok karmaşık bir sistemler sistemi (*a system of systems*) olup tüm olasılıkları klasik programlama dilleri ile kod geliştirerek modellemek olası değildir. Bunun yerine veriden kendi kendine öğrenebilen algoritmaların kullanıldığı yapay zeka yaklaşımına geçilmektedir. Mekansal zekanın rolü de insanların ve sensörlerin birbirlerine bağlı olduğu bir ortamda, gerçek dünya problemlerinin çözümünde, mekansal veri kümelerine dayalı (*data-driven*) bulguları çok daha doğru ve anlamlı hale getirip, anlam çıkarma üzerinden değer yaratan uygulamaları ve çözümleri çok daha etkin ve verimli biçimde geliştirebilmektir.

Mekansal zeka yalnız yapay öğrenme teknikleri kullanılarak örüntü tanıyan, görüntüler ve diğer mekansal veri kümeleri üzerinde sınıflandırma yapan araç olarak algılanmamalı, aynı zamanda veri kümeleri üzerinden öğrendiklerini kullanarak akıl yürütmeler (*reasoning*) ve çıkarımlar (*inference*) da yapabilen bir **paradigma değişimi** olarak algılanmalıdır.

Mekansal verinin yalnızca yerel yönetimlerden, kamu kurum ve kuruluşlarından temin edilmesi yerine mekansal veri kümelerinin; nesnelerin interneti, sosyal medya, kitle kaynaklı veri, üçüncü parti veri, açık veri, akan veri, yapılandırılmamış veri vb. yaklaşımlar üzerinden koordinat, metin, görüntü, video, ses gibi farklı formatlardaki veri kümelerinden türetilmesi ve kamu kurumları tarafından üretilmiş yapılandırılmış veri kümeleri ile birlikte kullanılması sözü edilen paradigma kaymasına örnek olarak gösterilebilir. Diğer tür paradigma değişimlerine örnek olarak; mekansal zeka tarafından bir haritanın tasarımı ve üretilmesi, mekansal zeka tarafından yapılan bir imar planı, mekansal zeka tarafından belirlenen taşınmaz değeri, gezgin sürü robotlarca üretilen topoğrafik haritalar vb. uygulamalar gösterilebilir.

Aşağıda ifade edilen ve benzeri birçok yeni teknolojik kavramın ortaya çıkması, bunların farklı biçimlerde farklı uygulamalarda yer bulması, **mekansal bilişim endüstrisi** için de zihinsel dönüşümün neden gerekli olduğunu ortaya koymakta ve **mekansal zeka ‘devrimi’nin** altyapısını oluşturmaktadır.

- Uydu görüntülerinin artan mekansal, zamansal, radyometrik ve spektral çözünürlüklerde, daha az maliyetle ve kimi zaman ücretsiz olarak web üzerinden daha kolay ulaşılabilir olması,
- İnsanlı veya insansız, sabit ya da döner kanatlı hava araçlarından elde edilen dijital görüntülerin ve nokta bulutlarının daha kolay üretiliyor olması,
- Nokta bulutlarının, görüntülerin ve videoların (video-tabanlı görüntülerin) uzay ve hava ortamlarına ek olarak yerden (*ground-level*) mobil harita üretim araçları, gözlem sistemleri (*surveillance systems*), sokak görünimleri (*Street View*), akıllı telefonlar gibi farklı sensörler ve sistemlerle daha yaygın biçimde üretiliyor olması,
- Görüntü elde etme kaynaklarının çoğalması ve zenginleşmesi, elektromanyetik spektrumun görünür ışık bölgesi dışında radar ve kızıl ötesi gibi diğer alanlarının da kullanılarak multispektral veya hiperspektral görüntülerin üretiliyor olması,
- Sunucu tarafında daha geniş ve ucuz depolama alanlarının bulut üzerinden hizmet olarak sunulması, bulut üzerinden Landsat vb. uydu görüntülerinin servis ediliyor olması,
- Bulut tarafındaki sunucularda ve uç (*edge*) (Hassan, Gillani, Ahmed, Yaqoob & Imran, 2018) taraftaki gömülü sistemlerde hesaplama gücünün artmış olması,
- Google, Amazon (AWS), Azure, IBM gibi global bulut çözümü sunan firmaların platformlarında otomatik ölçeklendirmenin yapılabilir olması, yüksek kapasiteli işlem birimlerinin (CPU), hafıza birimlerinin (RAM), Grafik İşleme Birimlerinin (*Graphics Processing Unit*, GPU) kullanılıyor olması ve tüm bunları servis olarak sunabiliyor olmaları,
- Bulut bilişimin olanakları kullanılmadan özellikle mekansal büyük veriye ilişkin sorgulamaların ve analizlerin gerçekleştirilmesinin çok uzun zaman alıyor olması vb. nedenlerle yapay öğrenme uygulamalarında bulut çalışma ortamlarına ve bu bulut ortamında paralel hesaplama mimarilerine duyulan gereksinimin giderek artması,
- Web üzerinde gelişkin 3 boyutlu (3B) görselleştirme araçlarının kullanılmaya başlanmış olması, 3B kent modellerinin web üzerinden paylaşılmasının yaygınlık kazanıyor olması,
- 3B kent modellerinin “3B/4 boyutlu (4B) veya çok boyutlu kadastro” uygulamaları ile bütünleştirilmeye çalışılıyor

olması,

- Makine öğrenmesi (Blum & Langley, 1997), derin öğrenme (Schmidhuber, 2015) gibi yapay öğrenme algoritmalarının büyük bir hızla gelişmesi ve birçok alanda kullanılıyor olmaları,
- 5. nesil (5G) kablosuz ağ teknolojisi ile internet hızının artacak olması, nesnelerin interneti ve artan internet bağlantı hızının getireceği yeniliklerin diğer sektörlerde olduğu gibi mekansal bilgi sektöründeki geleneksel iş modellerini radikal biçimde değiştirecek olması,
- Mekansal bilişimin büyük veri, nesnelerin interneti, blok zinciri vb. kavramlarla birlikte kullanılarak bir sinerji oluşturmaya başlaması ve mekansal büyük veri (*spatial big data*), nesnelerin coğrafyası (*geography of things*), krypto koordinatlar vb. kavramların uygulamalarda kullanılmaya başlanmış olması.

Bu tür zihinsel dönüşümlerle birlikte ‘mekansal veri bilimi analisti (*geospatial data science analyst*)’, ‘mekansal veri madencisi’, ‘mekansal veri sorumlusu (*spatial data steward*)’, ‘siber güvenlik uzmanı’, ‘mekansal zeka model geliştiricisi’, ‘mekansal zeka uzmanı’ gibi yeni ve farklı uzmanlıkların yakın gelecekte ortaya çıkması olası görülmektedir.

3. Mekansal Zeka Yaklaşımının Katkıları

İçinde bulunulan çağda sensörlerden, cihazlardan, sosyal medyadan ve bilgi sistemlerinden büyük miktarda elde edilen verinin daha fazla değer yaratabilmesi için mekansal olarak daha iyi anlaşılması/yorumlanması beklenmektedir. Bu nedenle geleneksel yaklaşımların dışında bulunan yapay zeka yöntemleri gibi araçlar ve algoritmalar kullanılarak çok daha karmaşık mekansal analizler ve görselleştirmeler gerçekleştirilmeye başlanmıştır. Mekansal analizlerde kullanılan yapay öğrenme modelleri, çok sayıda değişkenin büyük mekansal veri üzerinde analiz edilmesini, geleneksel yöntemlerle gerçekleştirilemeyecek çok boyutlu mekansal analizlerin yapılabilmesini ve yine geleneksel yöntemlerle ortaya çıkarılamayacak sonuçların elde edilebilmesini sağlamaktadır.

Daha önce üretilmiş analog haritalardan, elektromanyetik spektrumun farklı dalga boylarındaki herhangi bir ışımdan oluşacak bir sinyale kadar farklı veri türleri ve yapıları mekansal zeka çözümlerinde kullanılabilir. Mekansal zeka uygulamaları, kapalı alan olarak bir bina içerisinde veya açık alanda bir kent içerisinde ya da gezegenin bütününde veya siber dünyada bir oyunun içinde herhangi bir ortamda farklı ölçeklerde ve çözünürlüklerde geliştirilebilir.

Mekansal Zekanın, mekansal bilişim dünyasında kolaylıkla öne çıktığı üç alan olarak mekansal verinin elde edilmesi ile mekansal verinin analizi ve mekansal verinin görselleştirilmesi gösterilebilir. Mekansal verinin elde edilmesinde mekansal zeka yaklaşımı uydu görüntüsü, insansız hava araçları, lazer tarama gibi algılama teknik ve teknolojileri ile elde edilen veri kümelerinde detay yakalama, nesne çıkarma gibi konularda öne çıkmaktadır. Mekansal bilişim alanında mekansal analizlerin gerçekleştirilmesinde ise Coğrafi/Mekansal Bilgi Sistemleri (CBS) (*Geospatial Information System*, GIS) kullanılmaktadır. CBS uygulamalarında sınıflandırma, kümeleme, tahmin etme ve regresyon yöntemleri uzun yıllardır kullanılmaktadır. Örneğin tahmin işi için konumsal olarak ağırlıklandırılmış regresyon veya enterpolasyon, sınıflandırma işi için Destek Vektör Makinesi (*Support Vector Machine*, SVM) (Cortes & Vapnik, 1995) CBS ortamında yaygın olarak kullanılmaktadır. Mekansal verinin dağılımı, yoğunluğu, yakınlıkların, bağlantılı olma durumlarının analizi vb. mekansal analizler CBS ortamında sıklıkla gerçekleştirilen istatistiksel analizlerdir ve bu tür analizler makine öğrenmesi algoritmalarında kullanılmaya uygun niteliktedir. Bu nedenle mekansal zeka kapsamında mekansal verinin analizinde ve mekansal karar destek süreçlerinde yapay öğrenme yöntemleri CBS uygulamalarında etkin olarak kullanılabilir. Mekansal verinin

görselleştirilmesinde veya harita tasarımında, kavramsallaştırma, sınıflandırma ve optimizasyon gibi süreçler yapay öğrenme yöntemlerinden olan Çekişmeli Üretici Ağlar (*Generative Adversarial Network, GAN*) (Goodfellow vd., 2014) kullanılarak gerçekleştirilebilir.

Mekansal Zeka yaklaşımının mekansal bilgi endüstrisine sağladığı katkılar genel olarak aşağıda ifade edilmeye çalışılmıştır:

- Farklı formatlarda bulunan büyük mekansal-zamansal veriden anlamlı bilginin üretilmesi,
 - Jeodezik ölçüler arasında veya mekansal veri kümeleri arasındaki ilişkilerin kendi kendine kurulması, yığın mekansal veriden anlamlı haritaların üretilmesi,
 - Konum etiketli sosyal medya paylaşımlarından ve/veya konumu bilinen sensörlerden elde edilen gerçek zamanlı veri kümelerinin bulut üzerinde anlamlı mekansal veriye dönüştürülmesi ve bu veri kümelerinin karmaşık gerçek dünya problemlerinin çözümünde kullanılması,
 - Çevrimiçi platformlar üzerinden büyük miktardaki mekansal verinin işlenmesi ve işlenen mekansal bilginin karar verme süreçlerinde gerçek zamanlı ya da gerçek zamana yakın (*near real-time*) kullanımı,
 - Uydu gravimetrisi, uydu altimetrisi, enterferometrik yapay açıklıklı radar (InSAR), sayısal zenit kamera sistemi gibi birbirinden farklı jeodezik ölçme yöntemlerinden elde edilen bilgiler ve yapay öğrenme teknikleri kullanılarak geoit sinyalinin uzun, orta ve kısa dalga boylu kısımlarının belirlenmesi ve ulusal jeodezik veri altyapısında bulunması gereken jeopotansiyel değerlerin doğruluğunun ve mekansal çözünürlüklerinin artırılması,
 - Farklı zamansal ve mekansal çözünürlüklü yüzlerce, binlerce görüntü üzerinde yapay ve doğal nesnelerin insan müdahalesi olmadan tespit edilmesi/bulunması (*detection*), tanımlanması/sınıflandırılması (*recognition/classification*), takip edilmesi (*tracking*), bölütlenmesi (*segmentation*), tanımlanan nesnelerin üzerinde çalışılabilir veri türüne dönüştürülmesi/sayısallaştırılması (*extraction*) ve daha sonra bu veri kümelerinin Mekansal Bilgi Sistemi ortamlarında bilinçli karar vermek (*informed decisions*) için kullanılması,
 - Uzayda, havada veya yerde bulunan bir platformdan elde edilen görüntüde doğal ve/veya yapay bir nesnenin tanımlanarak makine öğrenme algoritmasıyla görüntü üzerindeki benzer nesnelerin tespit edilmesi ve tanımlanması,
 - Uzaydaki, havadaki ve yerdeki taşıyıcı platformlar üzerinde bulunan farklı sensörlerden elde edilen milyonlarca sayıdaki hiperspektral, multispektral ve optik görüntülerin Evrişimli Sinir Ağı (*Convolutional Neural Network, CNN*) (Krizhevsky, Sutskever & Hinton, 2012) ve türevleri gibi derin öğrenme teknikleri (LeCunn, Bengio & Hinton, 2015) yardımıyla arazi örtüsü, arazi kullanımı vb. amaçlı otomatik ya da yarı-otomatik sınıflandırılması ve nesnelerin çıkarımı,
 - Düşük çözünürlüklü uzaktan algılama görüntülerine derin öğrenme teknikleri uygulanarak farklı spektral bant kombinasyonlarında detay tanımlama başarısının artırımının sağlanması,
 - Akıllı telefonlardan gözetleme sistemlerindeki kameralara, insansız hava araçlarından uzaydaki uydulara kadar olan farklı taşıyıcı platformlarda bulunan farklı sensörlerden algılama yöntemiyle elde edilen görüntülerin derin

öğrenme teknikleri ile analizi ve bu analiz sonuçlarından tematik haritaların üretilmesi,

- Özellikle sosyal medya paylaşımlarından, web dokümanlarından ya da insan sesinden Doğal Dil İşleme (*Natural Language Processing*, NLP) (Collobert & Weston, 2008) tekniği ile metinden konum bilgisinin çıkarılması, coğrafi kodlama (*geocoding*) yaklaşımıyla diğer mekansal veri kümeleri ile ilişkilendirilmesi,
- Geleneksel yöntemlere göre daha doğru modelleme yapılarak daha iyi karar verme süreçlerinin oluşturulması, geleneksel yöntemlerle ortaya çıkarılamayacak analiz sonuçlarının elde edilebilmesi,
 - Mekansal verinin içeriğinin anlaşılmasında, büyük mekansal veri içerisinde bulunan değişkenler arasındaki gizli ve derin ilişkilerin ortaya çıkarılmasında, mekansal örüntülerin bulunmasında, eğilimlerin belirlenmesinde ve çok değişkenli tahminlerin (*prediction*) gerçekleştirilmesinde makine öğrenmesi gibi yapay öğrenme algoritmalarının kullanılması,
 - Makine öğrenmesi algoritmaları ile karmaşık mekansal ilişkilerin bulunduğu veri yığnında geleneksel yöntemlerle ortaya çıkarılamayacak örüntülerin bulunması ve bu sayede çok daha doğru karar verme süreçlerinin oluşturulması,
 - Geçmiş zamana ilişkin veri kümeleri üzerinden öğrenerek gelecekte verilen bir tarih ve zamanda kaza, hastalık, kirlilik, trafik sıkışıklığı, suç vb. bir olayın/olgunun tehlikeli düzeye ulaşmadan öngörülebilmesi (*forecasting*),
 - Vektör veya raster formatındaki nüfus, arazi kullanımı gibi internet üzerinden servis edilebilen veri kümelerinin yapay öğrenme algoritmaları kullanılarak grid (*tile*) tabanlı veya idari sınır tabanlı üretilmesi.

4. Mekansal Zeka Yaklaşımının Kullanım Alanları

Bugünlerde özellikle öne çıkan ve disiplinler üstü uygulama alanı olan “akıllı” şehirler ile otonom ve bağlantılı araçlar, mekansal verinin ve mekansal zekanın etkin kullanılabileceği uygulamalar arasındadır.

‘Akıllı’ şehir kavramının hayat bulması için

- Bir şehrin nesnelerin interneti yaklaşımıyla çöp kutularından, aydınlatmalarına kadar yüz milyonlarca sensörlerle donatılması;
- Büyük veri yaklaşımıyla bu sensörlerden elde edilen veri kümelerinin anlamlı biçimde bütünleştirilmesi;
- Yapay öğrenme yaklaşımıyla şehrin sorunlarının çözümüne ilişkin çıkarımların yapılabilmesi;
- Sanal/arttırılmış gerçeklik gibi ileri görselleştirme yaklaşımları kullanılarak şehir hayatı canlandırmalarının ve benzetimlerinin kentlilerle paylaşılabilmesi;
- Blok zinciri yaklaşımı ile evrak işlerinin herkese açık olarak yapılabilmesi;
- 5G gibi geniş bantlı kesintisiz bir iletişim yaklaşımı ile bağlantıların kurulması;
- Tüm bunların Kent Bilgi Sistemleri üzerinden planlanması, izlenmesi ve yönetimi

vb. yaklaşımların şehirlerin yetileri arasında yer alması beklenilmektedir (Güney, 2019).

Derin öğrenme teknikleri ile uzaktan algılama görüntülerinden bir şehirde bulunan binaların, yolların otomatik çıkarımı, makine öğrenmesi teknikleri ile şehrin gelişiminin tahmin edilmesi (*prediction*), orman alanlarının ne kadar azaldığının tespit edilmesi ve bu durumda hava kirliliğinin ne kadar artacağına öngörülmesi (*forecasting*) gibi çalışmalar mekansal zekanın “akıllı” şehirler uygulamalarında nasıl kullanılabileceğine örnek olarak gösterilebilir. Bunun için örneğin CNN algoritmasıyla uydu görüntülerinden yalnız binaların çıkarılmasında arkaplan, bina sınırı ve bina içi olmak üzere üç farklı sınıf oluşturulabilir. Görüntü üzerinde bina olarak tanımlanan pikseller Douglas-Peucker vb. bir algoritma kullanılarak vektör veri yapısında bir poligona dönüştürülebilir. Bu şekilde 2B bina taban alanlarının (*building footprint*) oluşturulması kentlilerin mekansal dağılımlarını belirlemede, şehrin büyüme eğilimini analiz etmede vb. amaçlarla kullanılabilir. Yine hava fotogrametrisi ve 3B kent modelleri için önemli bir konu olan bina çatı hatlarının otomatik belirlenmesi, geometrilerinin, şekillerinin ve eğimlerinin yapay öğrenme yöntemleri ile otomatik üretilmesi fotovoltaiik panellerin bina çatılarına nasıl yerleştirilmesi gerektiğini analiz etmek için kullanılabilir.

“Akıllı” şehir ekosisteminin parçası olan “akıllı” ulaşım sistemleri yollar, trafik işaretleri, sinyalizasyon gibi bileşenlerin yanında bağlantılı ve otonom araçlarla birlikte yeni nesil bir ulaşım kavramını ortaya çıkarmaktadır. Otonom/sürücüsüz araçların başarılı biçimde sürüşlerini gerçekleştirebilmeleri için yazılım, donanım gibi gerekli olan temel bileşenlerden biri de harita ve konum bilgisidir. Geomatik/Harita Mühendisliğinde geleneksel olarak üretilen navigasyon amaçlı yol haritaları sürücüsüz araçların navigasyonlarını otonom biçimde gerçekleştirebilmeleri için yeterli düzeyde değildir. Bu nedenle şerit genişliklerinden kaldırım yüksekliklerine kadar farklı türdeki bilgileri kapsamlı biçimde içeren “*high-precision map* veya *precision map* (HD-map)” (Jiao, 2018) olarak isimlendirilen yeni tür çok yüksek ayrıntı düzeyindeki haritaların üretimine ve bunları hızlı biçimde güncelleyen sistemlere gereksinim duyulmaktadır. Üstelik harita yerine otonom araçlar için özel mekansal zeka uygulamalarının geliştirilmesi, otonom araçların mekansal bilgi destekli karar süreçlerinde daha etkin olmalarını sağlayacaktır (Güney & Çelik, 2017).

Otonom sürüşte karmaşık sürüş ortamlarında güvenli bir yolculuk için sensör füzyonundan elde edilen veri kümeleri üzerine pekiştirmeli öğrenme (*reinforcement learning*) (Kaelbling, Littman & Moore, 1996) ve özellikle derin pekiştirmeli öğrenme (*deep reinforcement learning*, DRL) (Yu, Shi, Huang, Li & Ma, 2017) yaklaşımı uygulanmaktadır. Otonom araçlar yolculuk süresince takip ettikleri güzergahın mekansal modelini görüntü, radar, LiDAR gibi sensörlerden elde edilen veri kümelerini kullanarak oluşturur. Bu mekansal model sonrasında sürüş tekniği ve trafik kuralları ile bütünleştirilir. Sürücüsüz araçlar için sokak düzeyinde (*street-level data*) üç boyutlu ve çok yüksek çözünürlüklü topoğrafik veriye gereksinim bulunmaktadır. Bu tür veri, farklı kurumlarca ve farklı amaca yönelik olarak mobil harita üretim sistemlerince üretilmektedir. Üretilen bu mekansal veri otonom araçların eğitimi için de kullanılabilir.

Otonom araçların navigasyonu için gerekli bir diğer veri türü de coğrafi referanslı trafik işaretleridir. Farklı görüntüleme sistemleri ile üretilen statik ve akan görüntülerden çok fazla sayıdaki trafik işaretinin yüksek doğrulukla tanımlanması gerekmektedir. Trafik işaretleri insanoğlunun işaretleri kolay tanımlayabilmesi için tasarlanmış olması nedeniyle bilgisayarlar tarafından kolayca tanımlanamamaktadır. Hem görüntü işleme hem de makine öğrenme algoritmaları, bu tanımlama sürecini geliştirmek için sürekli olarak iyileştirilmektedir. Bu amaca yönelik girişimlerin bu tür geliştirmeleri yapabilmeleri için üzerinde çalışabilecekleri veri kümelerine ve geliştirdikleri algoritmaların başkaları tarafından geliştirilen algoritmalarla olan başarımlarını karşılaştırmak için kalite testi (*benchmark*) veri kümesine gereksinimleri bulunmaktadır. Girişimler yapay öğrenme algoritmasının eğitimi için gerekli olan veri kümesini kendileri hazırlayabilirler. Ancak üzerinde uzlaşılmış kalite testi veri kümesini başka bir kaynaktan elde etmeleri gerekmektedir. Almanya’da trafik işaretlerinin derin

öğrenmeyle eğitilmesinde kullanılmak üzere bir kalite testi veri kümesi hazırlanmıştır (URL-1).

Literatürde bu tür çalışmalar yeni yeni yaygınlık kazanmaya başlamış olması nedeniyle bütüncül ve ayrıntılı akademik çalışmalara ulaşmak kolay olmamaktadır. Aşağıda iki farklı konu için yapılmış çalışmalar örnek olarak verilmiştir.

Çevresel epidemiyolojinin mekansal zeka ile bütünleştirildiği bir çalışma VoPham, Hart, Laden ve Chiang (2018) tarafından yapılmıştır. Klasik yaklaşımlarla karşılaştırıldığında bu çalışmada mekansal zeka yaklaşımı ile çevresel riskler daha doğru ve yüksek düzeyde çözümlenmiş ve hastalığın yayılması daha iyi düzeyde modellenmiştir. Böylece epidemiyoloji çalışmalarındaki hastalık ve çevresel etkiler arasındaki potansiyel ilişkiler daha iyi anlaşılabilir. Ayrıca, klasik yöntemlerle ortaya çıkarılamayan bazı çevresel etkenler mekansal zeka yaklaşımıyla ortaya çıkarılabilmektedir (VoPham vd., 2018).

ABD'nin Los Angeles şehrindeki hava kirliliği tahmini için sensör tabanlı kirlilik veri kümesi OpenStreetMap ile birlikte kullanılarak arazi kullanımı ile kirlilik konsantrasyonu arasındaki ilişki zamansal olarak belirlenmiş, daha sonra trafik örüntüsü ve insan etkinliği örüntüsü ile bütünleştirilerek hava kirliliği değerinin tehlikeli düzeye ne zaman ulaşacağını tahmini yapılabilmektedir (Lin vd., 2017).

4.1 Örnek Senaryo: İstanbul Trafik Sıkışıklığı Problemi

İstanbul şehri ile özdeşleşen trafik sıkışıklığı sorunsalının çözümüne yönelik olarak geliştirilecek bir bilgisayar programı için trafiğin ve trafik sıkışıklığının ne anlama geldiğini anlatan talimat listesi kodlamak bir diğer ifadeyle kural tabanlı (*rule-based*) bir çözüm geliştirmek yerine, veri güdümlü (*data-driven*) bir yapay öğrenme algoritması geliştirilerek yapay öğrenme modelinin trafik ile ilgili olayları ve örüntüleri öğrenmesi/anlayıp yorumlayabilmesi ve buna göre bilinçli (*informed*) karar süreçlerinin oluşturması tercih edilebilir.

Diğer mekansal problemlerde de olduğu gibi trafik sıkışıklığı sorununun çözümünde statik ve dinamik olmak üzere iki tür girdi veri kümesi gerekmektedir. Statik veri kümesi; yol geometrisi (yolun genişliği ve deveri), yol ağı topolojisi, kavşaklara yakınlık, yol türü, hız sınırları, nüfus yoğunlukları, trafik işaretleri gibi detaylardan (*features*) oluşmaktayken, dinamik veri kümesi; meteorolojik istasyonlardan anlık elde edilen hava koşulları, araç sürücüler, yol kameraları gibi farklı kaynaklardan elde edilen trafik yoğunluğu vb. saat, gün, ay gibi zamansal değişkenlere bağlı detaylardan oluşmaktadır. Dinamik veride tahminin (*prediction*) ne zaman yapıldığına bağlı olarak detaylar farklılık gösterecektir. Geçmişte trafik sıkışıklığının olduğu yol bölümleri gerçek pozitif, trafik sıkışıklığının olmadığı tüm yol bölümleri de gerçek negatif olarak etiketlenebilir. Geçmiş yıllara ait tüm bu ve benzeri veri kümelerindeki detaylar ve trafik sıkışıklığının olup olmadığını gösteren pozitif ve negatif örnekler kullanılarak denetimli makine öğrenmesi modeli oluşturulabilir ve modelin trafik sıkışıklığı kavramını öğrenmesi sağlanabilir. Makine öğrenmesi yaklaşımı olarak XGBoost kütüphanesi (URL-2) ile 'gradient boosting' yöntemi (Mason, Baxter, Bartlett & Frean, 1999) kullanılabilir. 'Gradient boosting' algoritması yalnız tahmin etmede değil, aynı zamanda bu tahminlerin neden gerçekleştiğini açıklamakta da kullanılabilir. Öğrenme süreci birkaç yıllık veri büyüklüğü üzerinden yüzlerce değişken dikkate alınarak tamamlanabilir. Model eğitimi tamamlandıktan sonra eğitim verisi içerisinde olmayan diğer bir veri kümesiyle modelin doğrulaması (*validation*) gerçekleştirilir. Tahminlerin olası yerleri görselleştirilir ve trafik sıkışıklığı verisi ile karşılaştırılır. Böylece modelin ne kadar doğru çalıştığı tespit edilebilir. Yapay öğrenmede genel yaklaşım olarak veri kümelerinin %80-90'ı eğitim için, %10-20'si de doğrulama için ayrılmaktadır. İstenilen doğruluğa ulaşılması durumunda gerçek zaman verisi ile test aşamasına geçilir. Eğitimi tamamlanan model gerçek zamanlı veri kümeleri ile koşturularak hangi zamanlarda hangi nedenlerden (*insight*) dolayı hangi yollarda trafik sıkışıklığının artış göstereceği çok değişkenli olarak tahmin (*multivariate prediction*) edilebilir. Sonuçlar web üzerinden bir harita arayüzü kullanılarak görselleştirilebilir, sıkışıklığa neden olan etmenlerin etki düzeyine göre sıralaması yapılabilir. Bu sonuçlara göre trafik

sıkışıklığı ile ilgili kamu kurum ve kuruluşları bu sıkışıklığın oluşmaması için operasyonel kararlar alabilir. Farklı kullanıcılar için farklı amaçlara yönelik dinamik güzergah planlama gibi mekansal karar verme süreçleri oluşturulabilir. Böylece gelecek zamana ilişkin trafik durumu tahmin edilebilir (*prediction*), yapay öğrenme ile dinamik güzergah planlama yapılabilir, lojistik ve kargo vb. sektörlerde ürün/paket teslim süreci optimize edilebilir.

Trafik sıkışıklığı gibi mekansal problemlerin çözümünde yakınlık, komşuluk, yoğunluk, dağılım gibi mekansal ilişkilerin analizleri önemli rol oynamaktadır. Örneğin hava durumu verisinin yol geometrisi ile ilişkilendirilmesi gerekmekte ve bu durumda Kriging gibi bir enterpolasyon yöntemi kullanılabilir. Diğer taraftan hava durumu verisini başka tür bir iklim modeli ile birlikte kullanıp daha doğru girdi üretilmek istenirse coğrafi ağırlıklı bir regresyon modeli kullanılabilir. Bu nedenle makine öğrenme modelinin birçok farklı coğrafi veri kaynağını ve bu kaynakların birbirleriyle olan ilişkilerini dikkate alması gerekmektedir. Bu durum CBS yaklaşımını gerektirmektedir. Mekansal analizlerin otomatik bir biçimde web üzerinde gerçekleştirilebileceği standart, Açık Mekansal Bilişim Birliği (*Open Geospatial Consortium*, OGC) tarafından tanımlanan “*Web Processing Service (WPS)*”dir (URL-3). Bu mekansal analiz servisin diğer bir katkısı da herhangi bir CBS yazılımına gerek kalmadan mekansal analizlerin yapılabilmesidir. Birçok farklı veri türünü ve yapısını kullanan model sunucu tarafında oluşturulduğu için mekansal analizlerin de sunucu tarafında gerçekleştirilmesi uygun olacaktır. Mikroservis mimarisine dayalı OGC WPS servisinin, Python betimleme dilinin, Pandas ve GeoPandas gibi Python kütüphanelerinin, R istatistik dilinin ve PostgreSQL/PostGIS veritabanının yer aldığı bir sistem mimarisi bu iş için etkin olarak kullanılabilir. Geliştirme sürecinde Python betimlemeleri ve Python kütüphaneleri ‘Jupyter notebbok’ veya ‘Zeppelin notebook’ gibi tarayıcı tabanlı bir defterler üzerinden düzenlenip takip edilebilir. ‘Jupyter/Zepelin notebook’lar; R, Python ve Julia için Docker platformu gibi konteyner (*container*) yani sanallaştırma teknolojisi desteği de sağlamaktadır. Tüm bu ifade edilen teknolojiler Anaconda gibi tümleşik bir Python dağıtımı üzerinden de kullanılabilir.

Benzer yaklaşım hassas tarım, halk sağlığı, salgın hastalıklar, suç vb. diğer uygulama alanları için farklı senaryolar üzerinden oluşturulabilir.


4.2 Mekansal Zekayı Daha Etkin Kullanabilmek İçin Öneriler

Uzayda, havada veya yerde bulunan bir platformdan elde edilen görüntüde doğal ve/veya yapay bir nesnenin tanımlanarak makine öğrenme algoritmasıyla görüntü üzerindeki benzer nesnelerin tespit edilmesinde, kullanılan makine öğrenmesi algoritmasında bazı kuralların daha önceden tanımlanmış olması gerekmektedir. Aranılan nesneyi tanımlayacak ne kadar farklı kural tanımlanabilirse ve eğitim aşamasında kullanılacak ne kadar çok görüntü olursa, makine öğrenme algoritmasının başarımı da o ölçüde artacaktır.

Kentsel ve kırsal alanlarda uydu ve hava görüntülerinden nesne tespit edilmesine ilişkin etiketli veri (bir diğer ifadeyle yapay öğrenmede gerekli olan sınıf bilgisi atanmış veri) kümeleri yok denecek kadar azdır. Oysaki derin öğrenme modelleri kullanarak nesne sınıflandırması yapabilmek için neredeyse milyonlarca sayıda eğitim örneği gerekmektedir. İster makine öğrenmesi ister derin öğrenme olsun denetimli öğrenmede eğitim veri seti geniş bir yelpazede farklı çeşitlilikte ve sayıca ne kadar çoksa, sınıflandırma doğruluğu da o kadar yüksek olacaktır.

Eğer uydu ve/veya hava görüntüleri için yeterli çeşitlilikte ve miktarda eğitim verisi bulunmuyorsa öncelikle eğitim veri kümesinin hazırlanması gerekmektedir. Bunun için masaüstü bir CBS yazılımı kullanılabilir. Örneğin ESRI firmasının ArcGIS yazılımında üretilen etiketli görüntüler raster formatında dışa aktararak Google TensorFlow, Microsoft CNTK, PyTorch gibi yapay öğrenme kütüphanelerinde derin öğrenme uygulamaları için kullanılabilir. Görüntülerden nesnelerin tespitine ilişkin eğitim için ‘*Single Shot MultiBox Detector (SSD)*’ algoritması (Liu vd., 2016) ve benzeri diğer algoritmalar kullanılabilir. SSD algoritması seçilen yapay öğrenme kütüphanesi kullanılarak LeNet (LeCunn, Bottou, Bengio & Haffner,

1998), AlexNet (Krizhevsky vd., 2012), GoogLeNet (Szegedy vd., 2015), ResNet (He, Zhang, Ren & Sun, 2016) gibi bir CNN modeli üzerinden kullanılabilir. Şekil 1 genel olarak yapay zeka yaklaşımında kullanılabilecek algoritmaları, modelleri ve araçları göstermektedir.




Şekil 1: Yapay zeka ekosisteminin genel görünümü

Model başarımını arttırmak için farklı görüntü kaynaklarından elde edilen görüntüler birlikte kullanılabilir. Her ne kadar bilgisayarlı görü alanındaki çalışmalar elektromanyetik spektrumun görünür bölgesindeki RGB bantlarına yoğunlaşsa da spektrumun diğer bantlarını da kullanmak gerekebilir. 7.5 m çözünürlüklü RASAT, siyah-beyaz görüntü çözünürlüğü 2.5 m, renkli görüntü çözünürlüğü 5 m olan Göktürk2, 0.5 m çözünürlüklü Göktürk1, uçaklarla elde edilen 10 cm ve altı yüksek çözünürlüklü görüntüler yanında farklı spektral özellikleri olan 9 spektral ve 2 termal bantlara sahip Landsat, 13 banta sahip Sentinel gibi uydulardan elde edilen görüntüler birlikte kullanılabilir.

Her ne kadar yerden üretilen görüntüler yukarıda ifade edilen uydu ve hava görüntülerinden farklı olsa da kenarlar, gölgeler, eğriler, dokular vb. gibi benzer detaylar tüm görüntülerde ortaklaşmakta ve evrişimli sinir ağları tanımayı düşük seviye detaylardan başlayarak öğrenmektedir. Bu nedenle daha önceden başka veri kümesi ile yapılmış eğitim işleminin aktarımı anlamına gelen “Transfer Learning” yaklaşımıyla daha önceden milyonlarca görüntü ile eğitilmiş bir yapay sinir ağı modeli mekansal uygulamalar için geliştirilen modelde kullanılabilir ve daha sonra az sayıda etiketli uydu/hava görüntüsü ile ince ayar (*fine-tuning*) yapılabilir. Bu tür bir yaklaşım uydu/hava görüntülerine dayalı yeni bir ağ eğitimi sıfırdan yapma gereksinimini ortadan kaldıracak için veri ve hesaplama maliyetlerini düşürecek ve daha kısa zamanda model üretiminin gerçekleşmesini sağlayacaktır.

Hesaplama gücü ile yakından ilgili olan yapay zeka konusunda genel yönelim yapay öğrenme modellerinin, kaynakların otomatik ölçeklendirilebildiği bulut altyapısında eğitilmesi ve kullanılmasıdır. Büyük veri yaklaşımında veri depolama genellikle bulut tarafında çalışan veritabanlarında olduğu için bulut ortamında makine öğrenmesi ve derin öğrenme çalışmaları büyük ivme kazanmış ve birçok farklı uygulama geliştirilmiştir. Ancak, gerçek zamanlı verinin nesnelerin interneti yaklaşımıyla kolay üretilebilir duruma gelmesi, insanoğlunun nesnelerin interneti teknolojilerinden olan beklentilerini

veri üretiminden veri analizine ve daha sonra da eyleme geçmeye doğru yönlendirmiştir. Bu durumda uç tarafta (*edge*) yapay öğrenme modellerinin koşturulması durumu ortaya çıkmıştır. Gömülü sistemlerin performanslarının artmasıyla yapay zeka yaklaşımındaki yeni yönelim yapay öğrenme modellerinin bulut tarafında eğitilmesi ve uç tarafta gerçek zamanlı veri kümeleriyle kullanılmasıdır. Şekil 2 sunucu ve uç taraf arasındaki geri besleme döngüsünü göstermektedir.



Şekil 2: Uçtan-uca çözüm mimarisinin genel görünümü

5. Mekansal Zeka Çalışmaları

5.1 Dünyada Mekansal Zeka Çalışmaları

ABD, Çin, Fransa gibi ülkeler, ekonomik büyümelerini ve ulusal güvenliklerini sağlayabilmek için uluslarını yapay zeka alanında lider yapmaya yönelik hedeflerini açıklamışlardır. Bu ülkeler yapay zeka teknolojilerinin ticarileşmesinde liderlik edebilmek için büyük yatırımlar yapmaktadır. Şubat 2019 tarihinde ABD Başkanı Trump ‘*American AI Initiative*’ başlıklı başkanlık emrini imzalayarak, federal hükümetin kaynaklarının bu alana yönlendirilmesini sağlamış ve ABD’nin yapay zeka alanında lider ülke olması hedefine daha güçlü ve sağlam biçimde ilerlemesine katkı vermiştir (URL-4).

Mekansal Zeka üzerine uluslararası ilk çalıştaylar SIGSPATIAL konferansı etkinliği kapsamında, 2017 ve 2018 yıllarında Mekansal Zeka etkinlikleri (*AI for Geographic Knowledge Discovery*) olarak düzenlenmiştir (URL-5). ABD’de mekansal zekaya ilişkin başka bir akademik etkinlik de Amerika Coğrafyacılar Birliği tarafından 3-7 Nisan 2019 tarihinde düzenlenmiş olan mekansal zeka sempozyumudur (*GeoAI and Deep Learning Symposium: Spatial-Temporal Modeling and Data Mining I*) (URL-6).

OGC 2018 yılı içerisinde Mekansal Zeka çalışma grubu (*GeoAI Domain Working Group*) oluşturmuştur. Çalışma grubunun amacı mekansal uygulamalarda yapay zekanın nasıl kullanılacağını tartışılması ve diğer OGC standartlarının bu uygulamalarla nasıl ilişkilendirilebileceğinin araştırılmasıdır (URL-7).

Mekansal zekaya uyarlanmış platformlara örnek olarak Microsoft Azure ve ESRI'nin birlikte sağladıkları Azure platform üzerinde koştan 'Data Science Virtual Machine/Deep Learning Virtual Machine' ailesinin bir üyesi olan 'GeoAI Data Science Virtual Machine (DSVM)' örnek olarak verilebilir. Bu platform, daha akıllı uygulamalar geliştirmek için bulut altyapısı, coğrafi analitik (*geospatial analytics*) ve görselleştirme yaklaşımlarının birlikte kullanımını sağlamaktadır (URL-8).

5.2 Türkiye'de Mekansal Zeka Çalışmaları

Türkiye'de mekansal zeka çalışmaları henüz başlangıç aşamasındadır. Bu konuda ulusal düzeyde en bilinen etkinlik Mekansal Bilişim İnisyatifi tarafından 28 Şubat 2018 tarihinden itibaren düzenlenmekte olan mekansal zeka buluştaylarıdır. Bu buluştayların düzenlenmesindeki amaç mekansal zeka kavramının farkındalığını sağlamak, mekansal uygulamalar için ileri teknolojilerin nasıl birlikte etkin olarak kullanılabileceğini göstermek, yapay zeka alanında gerçekleşen en son gelişmelerin mekansal zekaya olan yansımalarını tartışabilmek, mekansal zeka için kullanım senaryoları oluşturmak, yenilik ekosisteminde mekansal zeka üzerine çalışan yerli girişimleri ortaya çıkarabilmek ve yakın gelecekte olabilecek potansiyel gelişmeleri tartışabilmek olarak ifade edilmektedir (URL-9).

6. Mekansal Zeka Yönetişimi

Türkiye'de halihazırda gerçekleştirilmeye çalışılan Mekansal Veri Altyapısı (*National Spatial Data Infrastructure - NSDI*, Türkiye Ulusal Coğrafi Bilgi Sistemi - TUCBS) çalışmalarına ek olarak, mekansal zeka altyapıları çalışmalarına da mekansal zeka ekosistemi içerisinde bulunan tüm paydaşlarla birlikte başlanmalıdır. Mekansal zeka uygulamaları için mekansal veri çok önemli olduğundan mekansal veri altyapısı ve mekansal zeka altyapısı çalışmaları bütünleştirilerek birlikte yürütülebilir. Bunun için bütüncül bir **mekansal zeka politikası** oluşturulması gerekmektedir. Bu politika hükümet politikası düzeyine getirilmeli ve Türkiye'nin 2023 vizyonu hedefleri arasına sokulabilmelidir.

Mekansal Zeka politikası yalnız yapay zekanın mekansal veri/bilgi temelli uygulamalarda kullanılması olarak değil, diğer ileri teknolojilerin ekosistemleri ile birlikte yeni bir **mekansal zeka ekosistemi** oluşturmak olarak algılanmalıdır. Bulut bilişim, büyük veri, nesnelerin interneti, sanal/arttırılmış/karma gerçeklikler, blok zinciri, kripto-paralar, robotik vb. ileri teknolojilerin yapay zeka ve akıllı sistemlerle birlikte mekansal zeka ile bütünleştirildiği bir ekosistem, mekansal zeka politikasının merkezini oluşturmalıdır. Bu tür bir anlayış mekansal veri ve bilgiye daha çok ekonomik ve toplumsal değerler kazandırabilecektir. Mekansal zeka ekosistemi içerisinde yalnız belirli bir disiplin ya da kamu kurumları değil; uzman kişilerin, kurumsal firmaların, teknoloji şirketlerinin, girişimcilerin, kaynak sağlayıcıların, akademisyenlerin, öğrencilerin, hukukçuların, iktisatçıların ve diğer disiplinlerin de yer aldığı geniş bir katılımcı grubu düşünülmelidir.

Anlamlı bir mekansal zeka politikası oluşturulduktan sonra sürdürülebilir bir **mekansal zeka stratejisi** ivedilikle belirlenmelidir. Ulusal düzeyde oluşturulacak mekansal strateji planında üzerinde durulması gereken konulardan bazıları aşağıda ifade edilmiştir:

- Mekansal zeka konusunda ilerlemenin sağlanması için mekansal zeka üzerine yapılacak olan bilimsel araştırmaların ve bu konuda çalışan araştırma topluluklarının desteklenmesi, Araştırma ve Geliştirme (Ar-Ge) faaliyetlerinin yapılabilmesi için gerekli fonların oluşturulması,
- Mekansal zeka uygulamalarını geliştirmek için yenileşimin (*innovation*) önündeki engellerin kaldırılması, girişimcilerin desteklenmesi,
- Kamu ve özel sektörün mekansal zeka kavramına ilişkin farkındalığının arttırılması, bu sektörlerin mekansal zeka

kavramını benimsemesine yönelik çalışmaların yapılması ve mekansal zekanın ulusal düzeydeki ekonomik büyüklüğünün belirlenmesi,

- Mekansal zekanın diğer hangi sektörlerle ne ölçüde ara kesit oluşturduğunun, ne kadar zaman içerisinde diğer sektörlerde yaygınlık kazanacağını belirlenmesi ve sektörel senaryo (*use-case*) çalışmalarının yapılması,
- Ulusal düzeyde özellikle kamu kurum ve kuruluşların mekansal zeka konusundaki yeteneklerini geliştirecek çalışmaların yapılması ve bu kurumlarda çalışan ilgili personele mekansal zeka konusunda eğitimler verilerek mekansal zeka konusundaki becerilerinin artırılması, mekansal zeka üzerine kitlesel çevrimiçi açık derslerin (*Massive Online Open Courses*, MOOC) oluşturulması,
- Mekansal zeka konusunda lisansüstü programların açılması ve bu programlar üzerinden yetişmiş insan kaynağı kapasitesinin artırılması,
- Mekansal zeka kavramına ilişkin teknik standartların belirlenmesi, bir yasal çerçevenin oluşturulması ve bu yasal çerçeve kapsamında kamu kurum ve kuruluşların kendi teşkilat yasa ve yönetmeliklerinde gerekli yasal düzenlemeleri yapması,
- Mekansal zeka kavramına ilişkin etik normların belirlenmesi,
- Mekansal zeka kavramının teknolojik, ekonomik, etik, politik, sosyal ve yasal boyutlarının tartışabileceği etkinliklerin düzenlenmesi ve bu boyutlardaki çalışmaların geliştirilebilmesi için çalışma gruplarının oluşturulması,
- Sanayi, akademi, kamu kurum ve kuruluşlarının temsilcilerinin ve ilgi gösteren herkesin katılabileceği ve her yıl düzenlenecek bir mekansal zeka zirvesinin organize edilmesi, politika ve stratejilerin burada tartışılabilmesi,
- Uluslararası ölçekte mekansal zeka ve yapay zeka konusundan çalışan birliklere ve oluşumlara katılım sağlanması ve Türkiye'nin uluslararası alanda bu konularda da temsil edilmesi,
- Mekansal zeka kapsamında kullanılabilecek bir mekansal veri altyapısına doğru evrilmenin gerçekleştirilmesi, etiketlenmiş mekansal veri kümelerinin oluşturulması, açık veri politikasının kamu kurum ve kuruluşlarına yerleşmesi ve kamuya ait veri kümelerinin daha çok toplumla açık veri olarak paylaşımı için gerekli yasal mevzuatın oluşturulması, vb.

Tüm paydaşlarca üzerinde anlaşılan bir stratejik plan belirlendikten sonra bir yol haritası oluşturulmalı ve bu yol haritasının takvimine sadık kalınarak eylem planları uygulamaya geçirilmelidir. Bu hedeflere ulaşmada tüm disiplinler, demokratik meslek kitle örgütleri, üniversiteler, özel sektör, kamu kurum ve kuruluşları eş güdüm ve iş birliği içerisinde çalışmalıdır.

7. Sonuçlar ve Öneriler

Bu çalışmada mekansal bilişim endüstrisinde mekansal zeka kavramına ilişkin bir farkındalığın yaratılması ve sonrasında mekansal zeka ekosisteminin oluşturulmasının ne kadar önemli olduğu vurgulanmaya çalışılmıştır. Yeni açılan üniversiteler ve bölümler nedeniyle artan meslektaş sayıları birçok sektörde istihdam problemine neden olmaktadır. Sözü edilen istihdam probleminin çözüm yöntemlerinden biri de sektörlerin klasik üretimleri dışında yenilikçi üretim alanlarını uygulamaya kazandırabilmeleridir. Mekansal zeka ekosisteminin en önemli bileşeni olan özgirişimlerin (*startup*) mekansal zeka konusuna

ilişkin hangi alanlarda ve konularda iş geliştirme yapabilecekleri bu çalışma kapsamında öne çıkarılmaya çalışılmıştır. Çalışma kapsamında öncelikle öne çıkarılan diğer iki konu da yapay öğrenme modellerinin eğitimi için etiketli veri kümelerinin hazırlanması ve mekansal bilişim endüstrisinde mekansal zeka yeteneğinin artırılmasıdır.

1990'lı yıllarda başlayan ve henüz tamamlanamayan Ulusal Mekansal Veri Altyapısı çalışmalarındaki en büyük eksikliklerden biri o zamandan bugüne mekansal bilgi sistemleri alanında yetişmiş insan gücünün hem nicelik hem de nitelik olarak istenilen düzeye getirilememiş olmasıdır. Mekansal zeka konusunda da aynı hatayı tekrarlamamak için mekansal zeka konusunda farkındalık ve eğitim konularına önem verilmelidir.

Diğer taraftan mekansal bilgi endüstrisi tarafından tamamlanması sabırsızlıkla beklenen Ulusal Mekansal Veri Altyapısı kapsamındaki mekansal veri kümelerinin yapay zeka mimarilerine ne kadar uygun olduğu tartışmaya açıktır. Yapay öğrenme yöntemlerinin uygulanması sırasında gerekli olan ilk bileşen veri olup, öğrenmenin başarımı veri kalitesiyle doğru orantılıdır. Yapay öğrenme modellerinde kullanılacak veri kümelerinin eksiksiz ve güncel olması gerekmektedir.

Yapay zeka konusuna olan yatırımların hızla artması ve yapılan çalışmaların olumlu sonuçlar vermesi sonucunda dünyada yapay zeka konusunda hızlı gelişmeler yaşanmaktadır. Mevcut gelişmeler dikkate alındığında yakın gelecekteki mekansal zeka uygulamalarının bugünün mekansal zeka uygulamalarından çok farklı olacağı açık olarak görülmektedir. Bu nedenle zaman kaybedilmeden çalışma kapsamında değinilen konuların; ulusal düzeyde mekansal bilgi endüstrisinin tüm paydaşlarınca tartışılıp, değerlendirilip analiz edilerek bir eylem planına geçirilmesi gerekmektedir. Eğer böylesi bir yaklaşım ortaya konulmazsa mekansal bilgi endüstrisinin yakın zamandaki ulusal ve uluslararası rekabet gücünün çok azalacağı ve uygulama alanlarında büyük kayıpların oluşacağı değerlendirilmektedir. Cumhurbaşkanlığı Dijital Dönüşüm Ofisi koordinasyonunda 2019 yılı sonunda tamamlanacak olan Türkiye'nin ilk yapay zeka stratejisi belgesinde mekansal zeka konusunun da yer alması için mekansal bilişim endüstrisinin tüm bileşenleri ile birlikte çaba göstermesi gerekmektedir.

Kaynaklar

- Blum, A. L., & Langley, P. (1997). Selection of relevant features and examples in machine learning. *Artificial intelligence*, 97(1-2), 245-271.
- Christensen, C. M. (1997). *The innovator's dilemma: when new technologies cause great firms to fail*. Harvard Business Review Press.
- Collobert, R., & Weston, J. (2008). A unified architecture for natural language processing: Deep neural networks with multitask learning. *Proceedings of the 25th international conference on Machine learning*. 160-167.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative adversarial nets. *Advances in neural information processing systems*. 2672-2680.
- Güney, C. (2016). Yeni Nesil Coğrafi Bilgi Sistemlerinde Yapay Zeka, *XVIII. Akademik Bilişim Konferansı (AB 2016)*. Aydın.
- Güney, C., & Çelik, R. N. (2017). Geomatik Mühendisliğinin Rekabet Gücü ve Endüstri 4.0, *16. Türkiye Harita Bilimsel ve Teknik Kurultayı*, Ankara.
- Güney, C. (2019), Yerel Yönetimlerde Paradigma Değişimi, *Sosyal Demokrat Dergi*, 97-98.
- Hassan, N., Gillani, S., Ahmed, E., Yaqoob, I., & Imran, M. (2018). The role of edge computing in internet of things. *IEEE Communications Magazine*, 56(11), 110-115.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Jiao, J. (2018). Machine Learning Assisted High-Definition Map Creation. *2018 IEEE 42nd Annual Computer Software and Applications Conference (COMPSAC)*, 1, 367-373.
- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of artificial intelligence research*, 4,

237-285.

- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 1097-1105.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2324.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436.
- Lin, Y., Chiang, Y. Y., Pan, F., Stripelis, D., Ambite, J. L., Eckel, S. P., & Habre, R. (2017). Mining public datasets for modeling intra-city PM2.5 concentrations at a fine spatial resolution. *Proceedings of the 25th ACM SIGSPATIAL international conference on advances in geographic information systems*, 25.
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). Ssd: Single shot multibox detector. In *European conference on computer vision*. 21-37. Springer, Cham.
- Mason, L., Baxter, J., Bartlett, P. L., & Frean, M. R. (1999). Boosting algorithms as gradient descent. *Advances in neural information processing systems*. 512-518.
- Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. In *Proceedings of the IEEE conference on computer vision and pattern recognition*. 1-9.
- VoPham, T., Hart, J. E., Laden, F., & Chiang, Y. Y. (2018). Emerging trends in geospatial artificial intelligence (geoAI): potential applications for environmental epidemiology. *Environmental Health*, 17(1), 40.
- Yu, D., & Hang, C. C. (2010). A reflective review of disruptive innovation theory. *International journal of management reviews*, 12(4), 435-452.
- Yu, R., Shi, Z., Huang, C., Li, T., & Ma, Q. (2017). Deep reinforcement learning based optimal trajectory tracking control of autonomous underwater vehicle. In *2017 36th Chinese Control Conference (CCC)*. 4958-4965.
- URL-1: <http://benchmark.ini.rub.de/>, (Erişim Tarihi: 17 Kasım 2018).
- URL-2: <https://xgboost.ai/about>, (Erişim Tarihi: 8 Aralık 2018).
- URL-3: <https://www.opengeospatial.org/standards/wps>, (Erişim Tarihi: 7 Temmuz 2018).
- URL-4: https://www.whitehouse.gov/articles/accelerating-americas-leadership-in-artificial-intelligence/?utm_source=twitter&utm_medium=social&utm_campaign=wh, (Erişim Tarihi: 16 Mart 2019).
- URL-5: <https://udi.ornl.gov/geoai>, (Erişim Tarihi: 4 Eylül 2018).
- URL-6: <https://aag.secure-abstracts.com/AAG%20Annual%20Meeting%202019/sessions-gallery/23171>, (Erişim Tarihi: 23 Mart 2019).
- URL-7: <http://www.opengeospatial.org/pressroom/pressreleases?from=hogzpqvtpaj&page=98>, (Erişim Tarihi: 5 Ocak 2019).
- URL-8: <https://www.esri.com/en-us/landing-page/lp/product/2018/geo-ai>, (Erişim Tarihi: 2 Şubat 2019).
- URL-9: <https://www.meetup.com/Mekansal-Zeka/>, (Erişim Tarihi: 30 Mart 2019).