

YAPI BİLGİ MODELLEMEDE SEMANTİK ZENGİNLEŞTİRME VE GÜNCELLEŞTİRME İÇİN FARKLI ÖLÇME TEKNİKLERİNİN UYGULANMASI

Koray AKSU¹, Ayşenur KOÇYİĞİT², Aydın Furkan TERZİ³, Hande DEMİREL⁴

¹Araş. Gör., İstanbul Teknik Üniversitesi, Harita Mühendisliği Bölümü, 34469, Maslak, İstanbul, aksuko@itu.edu.tr

²Geomatik Mühendisi, İstanbul Teknik Üniversitesi, Harita Mühendisliği Bölümü, 34469, Maslak, İstanbul, kocyigit19@itu.edu.tr

³Geomatik Mühendisi, İstanbul Teknik Üniversitesi, Harita Mühendisliği Bölümü, 34469, Maslak, İstanbul, terzia18@itu.edu.tr

⁴Prof. Dr., İstanbul Teknik Üniversitesi, Harita Mühendisliği Bölümü, 34469, Maslak, İstanbul, hande.demirel@itu.edu.tr

ÖZET

Yapı Bilgi Modeli (YBM), binanın geometrik yapısını ve semantik bilgilerini içeren üç boyutlu dijital bir temsildir. YBM içerdiği bilgiler sebebiyle çok farklı disiplinler için kullanım alanına sahiptir ve disiplinler arası çalışma için uygun bir çalışma ortamı sağlamaktadır. YBM'nin geniş kullanım olanağı bulmasının başlıca sebebi, YBM'lerin üretiminde farklı kullanıcıların ihtiyacı bulunan detay seviyelerinin tanımlanmasıdır. Detay seviyeleri arasındaki geçiş, binanın zaman içerisinde geometrisinin ve kullanım amacının değişmesi, YBM'nin binayı yeterince temsil edememesine neden olmaktadır. Bu çalışma kapsamında, YBM'nin geometrik ve semantik açıdan zenginleştirilmesi, belirli zaman aralıkları ile modelin güncellenmesi ve detay seviyeleri arasındaki geçiş için bir sistem mimarisi önerilmiştir. Bu araştırma konusunun incelenmesi amacıyla güncel çalışmalar detaylı olarak incelenmiştir. Değerlendirmeler sonucunda farklı veri tiplerinin bütünleştirildiği bir sistem mimarisi önerilmiş olup, tasarlanan mimari ile bina detay seviyesinin istenilen düzeyde ve güncel kalması sağlanacaktır.

Anahtar Sözcükler: Yapı Bilgi Modelleme, Fotogrametri, 3B Nokta Bulutu, Detay Seviyesi, Semantik Bilgi

ABSTRACT

IMPLEMENTATION OF DIFFERENT MEASUREMENT TECHNIQUES FOR SEMANTIC ENRICHMENT AND UPDATE IN BUILDING INFORMATION MODELING

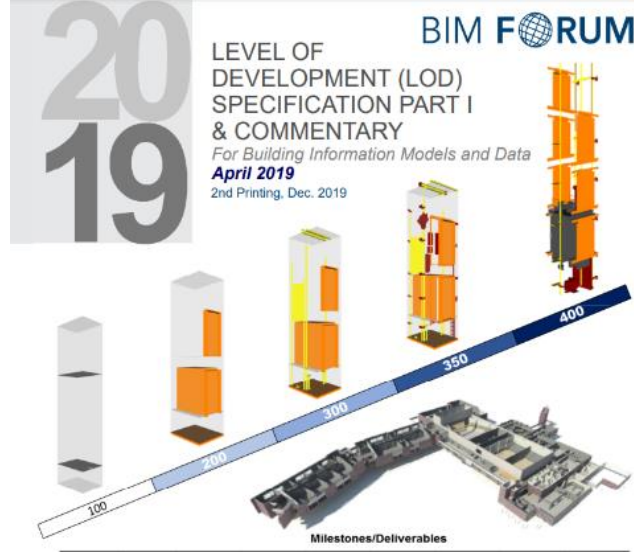
The Building Information Model (BIM) is a three-dimensional digital representation of a building, encompassing its geometric structure and semantic information. BIM is widely utilized across diverse disciplines due to the comprehensive information it offers, fostering an optimal environment for interdisciplinary collaboration. The varying levels of detail required by different users for producing BIMs are a crucial aspect of its widespread use. However, the transition between detail levels, changes in geometry, and the building's evolving purpose over time can sometimes impede BIM's ability to accurately represent the building. This study proposes a system architecture for enriching BIM with geometric and semantic information, updating the model at specific intervals, and managing the transition between detail levels. Existing research in this area has been thoroughly reviewed, and the proposed system architecture integrates various data types, ensuring that the building's level of detail remains at the desired level and stays current.

Keywords: Building Information Modeling, Photogrammetry, 3D Point Cloud, Level of Detail, Semantic Information

1. GİRİŞ

Yapı Bilgi Modelleme (YBM), mimarlık mühendislik ve inşaat (Architecture, Engineering, and Construction-AEC) sektöründe kullanılan üç boyutlu (3B) parametrik bir modellemenin yapıldığı bir sistemdir. YBM, yapıların tasarımı, inşası ve bakımı sürecinde kullanılan verilerin toplanması, yönetilmesi ve paylaşılmasını sağlar. YBM'lerin hangi detayda oluşturulacağını temsil etmek için modele ait ayrıntı düzeyi (Level of Detail-LoD) ve gelişim düzeyi (Level of Development-LoD) gibi kavramlar tanımlanmıştır. Farklı modelleme ortamlarının içerdiği detay seviyelerini temsil eden bu kavramlardan ayrıntı düzeyi, YBM süreçlerinde yapının ve içindeki nesnelere hangi detay seviyesinde tanımlanacağını belirten endüstriyel bir standart olarak kabul edilmiştir (Dinis vd., 2022; Zhang vd., 2022). YBM çalışmalarında halihazırda LoD 100, 200, 300, 350, 400 ve 500 ayrıntı düzeyleri tanımlanmıştır ve LoD seviyesi arttıkça model üzerindeki geometrik ve semantik bilgi düzeyi artmaktadır. LoD 100 modelin grafiksel gösterimini temsil eden kavramsal seviyedir. LoD 200'de model öğeleri boyut, şekil, konum ve dönüklük bilgileri içerir. LoD 300, LoD 200'den boyut, şekil, konum bakımından daha hassas bilgi sağlamakla birlikte nesnelere ait grafik olmayan bilgiler de içermektedir. LoD 400, imalat ve kurulum gibi çok detaylı bilgileri içerirken, LoD 500 ise yapının İş Sonu (As Built) modeli olarak adlandırılır ve tesis işletmesi için gerekli olan detay seviyesini içermektedir (Abualdenien ve Borrmann, 2022). İlgili LoD'ler, YBM oluşturmada kullanılacak ayrıntı seviyesini belirlemede kullanılan genel şema olup, çalışmanın kapsamına göre farklılık gösterebilmekte veya model geliştiricileri tarafından çalışma özelinde LoD 350 gibi farklı ara seviyeler tanımlanabilmektedir. LoD 350 seviyesinde genellikle, LoD 300'de geometrik olarak temsil edilen nesnelere ve sistemlerin birbirleri ile ilişkileri de temsil edilmektedir (Mavreli, 2018). YBM'lere ait

detay seviyeleri uluslararası bir kurum olan BIMForum tarafından yapı elemanı bazında düzenli olarak güncellenmekte olup, 2019 yılına ait örnek detay seviyeleri Şekil 1’de sunulmaktadır.



Şekil 1. YBM detay seviyeleri (BIM Forum, 2019).

YBM’lerin detay seviyeleri ile kullanım alanları arasında doğrudan bağlantı bulunmaktadır. Detay seviyesi arttıkça içerdiği semantik ve geometrik bilgi düzeyi de artacak ve bu sayede dijital ortamda binanın daha yüksek doğrulukla temsil edilmesini sağlanacak ve akıllı bina yönetim sistemleri, dökümantasyon, dijital ikiz gibi kavramlara altlık sağlayacaktır. Ayrıca, YBM’lerin kullanım alanını artıracak diğer bir husus ise güncel kalabilme yeteneğidir. Bu koşullar sağlandığı durumda YBM işlevini sorunsuz olarak yerine getirecektir. Yapım süreci yakın tarihte olan binaların çoğunda YBM üretimi projelendirme aşamasında oluşturulmuştur. Bu nedenle güncel ve yüksek detay seviyesinde sahiptir. Fakat eski binaların büyük çoğunluğunda YBM modeller bulunmamakta ve bulunduğu durumlarda ise güncelliğini korumamaktadır. Bu durumda farklı ölçme teknikleri kullanılarak detay seviyesinin artırılmakta ve değişim analizleri yardımıyla model güncellenmektedir. Bu işlemlerin gerçekleştirilebilmesi için klasik ölçme yöntemleri, fotogrametri ve lazer tarayıcı gibi üç boyutlu veri elde etme yöntemleri kullanılmaktadır. Ayrıca iki boyutlu kat planları, mekanik planlar ve tabular veriler de kullanılabilir. Bu yöntemlerle üretilen veriler yüksek doğrulukta geometrik ve semantik bilgi içermektedir, fakat verilerin yapısı, üretim yöntemi, boyutu, doğruluğu ve üretim standardı farklı olduğu için entegrasyon ve bilgi çıkarımı konusunda eksiklikler bulunmaktadır. Bu alanda yapılan güncel çalışmalar incelendiğinde, tek tip veri kullanılarak yapay zeka destekli şekilde bilgi çıkarımı gerçekleştirilmekte ve YBM üretimi/güncelleştirilmesi yapılmaktadır. Burada nesne çıkarımı için sıklıkla otomatik/yarı otomatik olarak makine öğrenmesi algoritmaları ve derin öğrenme mimarileri kullanılmaktadır (Girshick vd., 2014; Qi vd., 2017; Ding vd., 2019). Farklı veri tiplerinin bir arada kullanımı YBM’nin LoD düzeyinin artırılması ve güncellenmesi aşamasında katkı sağlayacaktır.

Çalışmanın amacı, YBM’lerin detay seviyelerinin (LoD) artırılması ve zamansal değişim analizlerinin gerçekleştirilmesi için sistem mimarisi önerilmesidir. Önerilen sistem mimarisi kullanılarak, LoD100-LoD200 seviyesine sahip bir YBM’nin detay seviyesi LoD350 ara seviyesine çıkarılarak, geometrik ve semantik açıdan daha iyi bir temsiliyet sağlayan üç boyutlu YBM’ler oluşturulacak ve tasarlanan sistem mimarisi ile YBM’nin güncel kalması sağlanacaktır. Çalışmanın özgün yönleri, farklı ölçme teknikleriyle üretilen verilerden yapay zeka desteğiyle (derin öğrenme/makine öğrenmesi) bilgi çıkarımı yapılması ve farklı ölçme teknikleri kullanılarak üretilen veriler uluslararası standartlara göre düzenlenerek etkin bir veri entegrasyonu sağlanmasıdır.

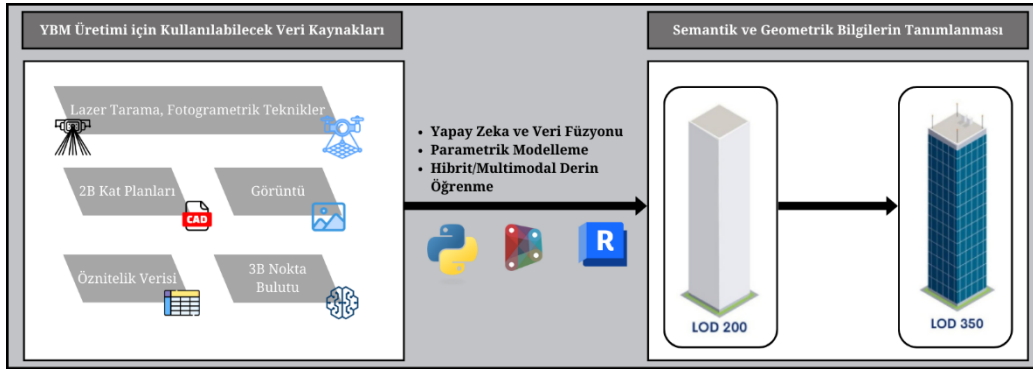
2. LİTERATÜR ARAŞTIRMASI

YBM üretimi ve güncelleştirmesi son yıllarda önemli bir çalışma haline gelmiş ve farklı çalışmalar sürdürülmektedir. Urbietta vd. (2023) tarafından yapılan çalışmada, yapay zeka algoritmaları yardımıyla mimari ve yapısal bina çizimlerinin ayrıştırılarak BIM modellerinin oluşturulması için yeni bir yaklaşım geliştirilmiştir. Bu yeni yaklaşımda Mask R-CNN modeli, mimari ve yapısal çizimleri bilinen dokuz bina verisi ile eğitilmiş ve Endüstri Temel Sınıfları (Industry Foundation Classes – IFC) formatında BIM model üretilmiştir. Yang vd. (2020) tarafından yapılan diğer bir çalışmada ise iki Boyutlu (2B) bilgisayar çizimlerinden (CAD) semantik zenginliğe sahip YBM modellerinin üretilebilmesi için bir yarı otomatik yöntem sunulmuştur. Bu yöntemde ilk olarak binanın temel yapı elemanları olan kirişlerin, döşemelerin ve kolonların geometrik modellerinin oluşturulabilmesi için CAD modellerde sınıflandırılmış

bilgiler kullanılmaktadır. Ardından bu semantik bilgiler uygun şekilde yapılandırılarak karşılık geldikleri modellerde depolanırlar. Son adımda bu yöntem iki örnek çalışma ile doğrulanmaktadır. Wang vd. (2024) YBM modellerinin semantik zenginleştirilmesi için bir çalışma gerçekleştirmişlerdir. Yaptıkları bu çalışmada YBM semantiğini temel model verilerinden ve obje geometrilerinden çıkartarak tahmin edilen sonuçları akıllı uygulamaları desteklemek amacıyla grafik tabanlı bir ortak veri ortamında (CDE) düzenlemeyi hedeflemişlerdir. Mirarchi vd. (2024) tarafından yapılan bir başka çalışmada ise derin Convolutional Neural Networks (ConvNets) ile analiz edilen görüntüler kullanılarak YBM modellerinin semantik zenginleştirilmesi hedeflenmiştir. Bunun yapılabilmesi için grafiksel bilgilerin hesaplanabilir bilgilere dönüştürebilmek için makine öğrenmesi yöntemlerinin kullanılması önerilmektedir. Chen ve Xue (2023) tarafından gerçekleştirilen çalışmada YBM'nin derin özelliklerinin (deep features) kullanılmasıyla otomatik YBM zenginleştirme yöntemi geliştirilmiştir. Geliştirilen bu yöntem üç adımlıdır. İlk adımda YBM modelinin 3B görünümü ve semantik bilgileri otomatik olarak çıkarılmaktadır. Ardından YBM'de görünmeyen detayların tahmin edilebilmesi ve çıkarılması için makine öğrenmesi algoritmaları derin özellikler kullanılarak eğitilmektedir. Son adımda ise DynamoBIM ortamında ilgili detaylar otomatik olarak YBM'e entegre edilmektedir.

3. ÖNERİLEN MODEL

Çalışma kapsamında önerilen sistem mimarisi Şekil 2'de yer almaktadır. İlgili veriler farklı ölçme teknikleri kullanılarak bu verilerden bilgi çıkarımı yapılması ve mevcut YBM'ye entegre edilmesi gerekmektedir. Çalışma kapsamında öncelikle LoD200 detay düzeyine sahip YBM'ye ihtiyaç duyulmaktadır. Oluşturulacak sistem mimarisinin bütüncülük ve uygulanabilirlik açısından uygun olması için çalışma bölgesinde farklı detay seviyelerine, geometrik ve semantik özelliklere sahip nesnelere bulunması gerekmektedir. Sistem mimarisi farklı türde yazılımlar ve verilerin kullanımını gerektirmektedir. Her bir veri farklı bir geometrik ve semantik bilgi içerdiği için verilerin entegrasyonu ve standardizasyonu önemli bir rol oynamaktadır. Temelde altı adet veri kaynağı ve LoD200 düzeyinde YBM kullanılmaktadır. İlgili veriler hakkında detaylı bilgiler ve YBM'ye aktarım süreci ilgili başlıklarda detaylı şekilde açıklanmaktadır.



Şekil 2. Önerilen sistem mimarisi.

3.1 Veri Kaynakları

Önerilen sistem mimarisi farklı veri tiplerinin kullanılarak geometrik ve semantik bilgilerin çıkarımını içermektedir. İlgili verilere ait detaylı bilgiler alt başlıklarda detaylandırılmıştır.

3.1.1 Üç Boyutlu Nokta Bulutu

3B nokta bulutları yüksek doğrulukta geometrik ve semantik bilgi sağlamaktadır. Bu nedenle YBM için oldukça önemli bir veri kaynağıdır. 3B nokta bulutları yersel tekniklerle, mobil sistemlerle ve fotogrametrik tekniklerle üretilebilmektedir. Nokta bulutundan otomatik bilgi çıkarımı konusu yapay zeka alanındaki çalışma konularından birisidir.

Üretilen nokta bulutları farklı makine öğrenmesi ve derin öğrenme modelleri kullanılarak YBM için kullanılacak anlamlı bilginin üretimine destek sağlayabilmektedir (Ding vd., 2019). Bu konuda en yaygın kullanılan derin öğrenme modellerinden biri PointNet mimarisidir. PointNet, CNN tabanlı bir mimariye sahip olup, nesne sınıflandırma, parça segmentasyonu ve semantik segmentasyon gibi farklı bilgi çıkarım yöntemlerini desteklemektedir. Model girdi olarak nokta bulutunun üç boyutlu koordinat değerlerini, RGB renk bilgilerini kullanmaktadır (Qi vd., 2017). Diğer bir derin öğrenme modeli olan RandLA-Net, PointNet'e benzer şekilde nokta bulutundan bilgi çıkarımı amacıyla geliştirilmiştir. Eğitim hızının yüksek olması nedeniyle PointNet modelinden ön plana çıkmaktadır (Hu vd., 2020). VoteNet yöntemi, iç mekanlarda semantik bilgi çıkarımı amacıyla kullanılan diğer bir derin öğrenme modelidir (Qi

vd., 2019). Bu modellerden üretilen tahmin sonuçları kullanılacak farklı makine öğrenmesi algoritmalarının desteğiyle de semantik bilginin yanı sıra geometrik bilgiler de türetilmektedir. Bunun için makine öğrenmesi tabanlı kümeleme algoritmaları kullanılmaktadır (Connected Component Labeling (CCL), Density Based Spatial Clustering of Applications with Noise (DBSCAN), Random Sample Consensus (RANSAC)) (Stefano ve Bulgarelli, 1999; Schubert vd., 2017; Derpanis, 2010). Bu algoritmalar semantik olarak sınıflandırılmış nokta bulutlarını kümeleyerek nesnelere ait geometrik parametrelerin çıkarımına olanak sağlamaktadır. Bu bilgilere örnek olarak pencere genişliği, eşik yüksekliği, duvarın üzdüşümü verilebilir.

Önerilen sistem mimarisi kapsamında bina kolonları, duvarları ve kirişleri gibi yapı elemanları ve binada bulunan masa, sıra, kapı, pencere, yangın ekipmanları gibi nesnelere ait bilgilerin otomatik/yarı-otomatik bir şekilde elde edilebilecektir.

3.1.2 İki Boyutlu Kat Planları

YBM üretiminde sıklıkla kullanılan verilerden bir diğeri ise binaların 2B kat planlarıdır. 2B kat planları bina hakkında geometrik bilgiler, boyutlar, grafik bilgiler, kapı tipleri, duvar tipleri, pencere tipleri, duvar hakkında bilgiler, elektrik tesisatları ve döşeme bilgileri gibi birçok farklı türde yararlı bilgiyi içermektedir. Üretilen YBM'nin semantik anlamda zengin olabilmesi için bu verilere ihtiyaç duyulmaktadır. YBM üretiminde 2B kat planları genel olarak iki farklı veri türünde bulunmaktadır. Bunlardan ilki vektör tabanlı çizimlerdir ve bu çizimler AutoCAD gibi yazılımlar kullanılarak yapılmaktadır. Bir diğeri ise bu çizimlerin taranarak görüntü haline getirilmesi sonucunda oluşturulan verilerdir. Bu verilerden YBM üretiminde yararlı bilgilerin üretilmesi için farklı yöntemler geliştirilmiştir. Örneğin 2B mekanik kat planlarındaki objelerin ve bu objelerin geometrik özelliklerinin çıkarılması için Minimum Circuit Search algoritması kullanılmaktadır (Zhao vd., 2021).

3.1.3 Görüntüler

Kullanılabilecek diğeri bir veri kaynağı ise görüntülerdir. Görüntüler sayesinde fiziksel ortamın durumu gerçeğe uygun bir şekilde sunulabilmektedir. Görüntülerde YBM'lerin oluşturulmasında ve zenginleştirilmesinde ihtiyaç duyulabilecek farklı türden veri bulunmaktadır. Bu verilerin YBM'de kullanılabilmesi için görüntü işleme algoritmaları ve yapay zeka kullanılarak nesne tespiti yapılmaktadır. Nesne tespitinde kullanılan birçok farklı derin öğrenme tabanlı algoritmalar bulunmaktadır. Bunlardan birine örnek olarak CNN tabanlı derin öğrenme modeli olan You Only Look Once (YOLO) modeli verilebilir (Lan vd. 2018; Chen vd., 2020). Nesne tespiti gerçekleştirildikten sonra ise fotogrametrik teknikler kullanılarak nesnelere ait 3B konumları elde edilmekte ve YBM'ye dahil edilebilmektedir.

3.1.4 Öznitelik Verisi

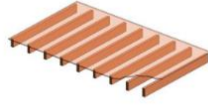


Öznitelik verileri içerdiği çeşitli bilgiler sayesinde YBM oluşturulma sürecince sıklıkla tercih edilmektedir. Bu veriler modele ait konum, materyal, yükseklik ve yanıcılık katsayısı gibi yanıcılık özellikleri gibi bilgiler sağlamaktadır. Ayrıca, bu verilerin kullanımı bilgilerin düzenli bir şekilde saklanabilmesini, farklı modellerle entegre edilebilmesini, farklı disiplinler kolayca paylaşılabilmesini, güncelleme ve aktarım durumunda veri kaybının azaltılmasını sağladığı için sıklıkla tercih edilmektedir. Özellikle geometrik bilgilerle birleştirildiğinde mekansal açıdan daha zengin bir veri kaynağı ortaya çıkmaktadır. Bu nedenle YBM üretiminde kullanımı avantajlar sağlamaktadır.

3.2 Semantik ve Geometrik Bilgilerin Tanımlanması

Sistem mimarisinde belirtilen verilen kullanılarak üretilen semantik ve geometrik bilgilerin mevcut YBM'ye aktarımı sonrasında nesnelere ait noktasal, çizgisel ve düzlemsel olarak mekansal bilgi üretimi sağlanmış olup, YBM'nin istenilen LoD düzeyinde güncel bir şekilde dönüşümü tamamlanmıştır. Ayrıca, parametrik modelleme için gerekli olan bilgiler üretilmiştir. Bu işlem için AutoDesk Revit ortamıyla paralel olarak çalışabilen açık kaynak kodlu DynamoBIM görsel programlama eklentisi kullanılabilir. Ayrıca değişim analizlerinin gözlenmesi amacıyla mevcut YBM'nin katı modelinden nokta bulutu örnekleme yapılarak üretilen nokta bulutlarına çakıştırma yapılarak, değişimler saptanabilir.

Sistem mimarisinin uygulanmasında veri füzyonu açısından bazı kısıtlar ve zorluklar mevcuttur. Veri füzyonu en genel haliyle iyileştirilmiş bilgi elde edilmesi amacıyla birden fazla kaynağın bir araya getirilmesidir ve verilerin daha iyi bir şekilde anlaşılması ve analizlerin etkili bir şekilde yapılmasına olanak sağlamaktadır (Castaneda, 2013). Verilerin entegrasyonunda yaşanan koordinat sistemi ve ölçek problemi, verilerin farklı türde ve farklı standartlarda üretilmesi, verilerin binanın güncel halini yansıtmaması bu zorluklardan bazılarıdır. Veri füzyonu sırasında yaşanan bu zorluklar çalışmanın doğruluğunu ve verimliliğini önemli derecede olumsuz etkilemektedir. Bu zorluklar verinin farklı disiplinler ile paylaşılmasına ve farklı platformlarda kullanılmasına engel olmaktadır. Önerilen sistem mimarisi

ile güncellenen YBM'nin doğruluk analizlerinin gerçekleştirilmesi için LoD 350 düzeyine getirilmiş bir modelde farklı yapı elemanları ve nesnelere incelenerek BIMForum tarafından 2023 yılında yayınlanan LoD düzeylerinin tanımlandığı standart ile karşılaştırılabilir. BIMForum tarafından 2023 yılında yayınlanan LoD düzeylerine örnek olarak Şekil 3'de sunulmaktadır.

100	See B10	
200	Inclusions: <ul style="list-style-type: none">• Element envelope	
300	Inclusions: <ul style="list-style-type: none">• Joist size, depth, slope• Spacing and end elevations• Joist seat depth	
350	Inclusions: <ul style="list-style-type: none">• Actual final joist profile locations with accurate panel points• Joist bridging and lateral braces• Joist seat width• Erection details for installation• Chord and web member section profiles• Non-standard joist seat depths and/or sloping joist seat	

Şekil 3. Farklı LoD düzeyleri (BIMForum, 2023).

4. ÖNERİLER

YBM'lerin detay seviyelerinin artırılması ve zamansal değişim analizlerinin gerçekleştirilmesi için önerilen sistem mimarisi, geliştirilecek platformun farklı disiplinlerin, farklı kullanıcıların, farklı uygulamaların ortak kullanımı ve maliyetlerin azaltılması için gereklidir. Önerilen sistem mimarisi kullanılarak, farklı detay seviyeleri arasında geçiş ve güncelleme mümkün olmaktadır. Önerilen sistem mimarisi, farklı veri kaynakları ile üretilen verilerden yapay zeka desteğiyle (derin öğrenme/makine öğrenmesi) bilgi çıkarımı yapılması ve farklı ölçme teknikleri kullanılarak üretilen veriler uluslararası standartlara göre düzenlenerek etkin bir veri entegrasyonu sağlamaktadır. Tasarlanan sistem mimarisinin farklı bina tiplerinde ve farklı uygulamalar için -örneğin bina yönetimi, güneş enerjisi potansiyelinin belirlenmesi, kapalı alan navigasyonu- denenmesi gerekmektedir.

5. TEŞEKKÜR

Bu çalışma TÜBİTAK ARDEB-1001 programı çerçevesinde 121099 numaralı "Yapı Bilgi Modeli Tabanlı Yangın Tahliye Simülasyonu (YBIMS)" projesi kapsamında desteklenmektedir.

KAYNAKLAR

Abualdenien, J., & Borrmann, A. (2022). Levels of detail, development, definition, and information need: a critical literature review. *Journal of Information Technology in Construction*, 27.

BIMForum, (2019). "Level of Development (LoD) Specification Part 1 & Commentary.

BIMForum, (2023). "Level of Development (LoD) Specification Part 1 & Commentary.

Castanedo, F. (2013). A review of data fusion techniques. *The scientific world journal*, 2013(1), 704504.

Chen, S., & Xue, F. (2023). Automatic BIM detailing using deep features of 3D views. *Automation in Construction*, 148, 104780. <https://doi.org/10.1016/j.autcon.2023.104780>.

Chen, W., Huang, H., Peng, S., Zhou, C., & Zhang, C. (2020). YOLO-face: a real-time face detector. *The Visual Computer*, 37(4), 805–813.

Derpanis, K. G. (2010). Overview of the RANSAC Algorithm. *Image Rochester NY*, 4(1), 2-3.

Di Stefano, L., & Bulgarelli, A. (1999). A simple and efficient connected components labeling algorithm. In *Proceedings 10th international conference on image analysis and processing* (pp. 322-327). IEEE.

Ding, Y., Zheng, X., Xiong, H., & Zhang, Y. (2019). "Semantic Segmentation of Indoor 3d Point Cloud with Slenet", ISPRS-International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 4213, 785-791.

- Dinis, F. M., Poças Martins, J., Guimarães, A. S., & Rangel, B.** (2022). BIM and semantic enrichment methods and applications: A review of recent developments. *Archives of Computational Methods in Engineering*, 29(2), 879-895.
- Girshick, R., Donahue, J., Darrell, T., & Malik, J.** (2014). "Rich feature hierarchies for accurate object detection and semantic segmentation", Proceedings of the IEEE conference on computer vision and pattern recognition, 580-587.
- Hu, Q., Yang, B., Xie, L., Rosa, S., Guo, Y., Wang, Z., ... & Markham, A.** (2020). Randa-net: Efficient semantic segmentation of large-scale point clouds. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition (pp. 11108-11117).
- Lan, W., Dang, J., Wang, Y., & Wang, S.** (2018). Pedestrian detection based on YOLO network model. In 2018 IEEE international conference on mechatronics and automation (ICMA) (pp. 1547-1551). IEEE.
- Mavreli, E.** (2018). "Level of Development vs. Level of Detail for BIM", TUM, Munich.
- Mirarchi, C., Gholamzadehmir, M., Daniotti, B., & Pavan, A.** (2024). Semantic Enrichment of BIM: The role of Machine Learning-Based Image Recognition. *Buildings*, 14(4), 1122. <https://doi.org/10.3390/buildings14041122>.
- Qi, C. R., Litany, O., He, K., & Guibas, L. J.** (2019). Deep hough voting for 3D object detection in point clouds. In proceedings of the IEEE/CVF International Conference on Computer Vision (pp. 9277-9286).
- Qi, C. R., Su, H., Mo, K., & Guibas, L. J.** (2017). "Pointnet: Deep learning on point sets for 3d classification and segmentation", Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 652-660.
- Schubert, E., Sander, J., Ester, M., Kriegel, H. P., & Xu, X.** (2017). DBSCAN revisited, revisited: why and how you should (still) use DBSCAN. *ACM Transactions on Database Systems (TODS)*, 42(3), 1-21.
- Urbieto, M., Urbieto, M., Laborde, T., Villarreal, G., & Rossi, G.** (2023). Generating BIM model from structural and architectural plans using Artificial Intelligence. *Journal of Building Engineering*, 78, 107672. <https://doi.org/10.1016/j.jobe.2023.107672>.
- Wang, Z., Sacks, R., Ouyang, B., Ying, H., & Borrmann, A.** (2024). A framework for generic semantic enrichment of BIM models. *Journal of Computing in Civil Engineering*, 38(1). <https://doi.org/10.1061/jccee5.cpeng-5487>.
- Yang, B., Liu, B., Zhu, D., Zhang, B., Wang, Z., & Lei, K.** (2020). Semiautomatic Structural BIM-Model Generation Methodology using CAD construction drawings. *Journal of Computing in Civil Engineering*, 34(3). [https://doi.org/10.1061/\(asce\)cp.1943-5487.0000885](https://doi.org/10.1061/(asce)cp.1943-5487.0000885).
- Zhang, J., Cheng, J. C., Chen, W., & Chen, K.** (2022). Digital twins for construction sites: Concepts, LoD definition, and applications. *Journal of Management in Engineering*, 38(2), 04021094.
- Zhao, Y., Deng, X., & Lai, H.** (2021). Reconstructing BIM from 2D structural drawings for existing buildings. *Automation in Construction*, 128, 103750. <https://doi.org/10.1016/j.autcon.2021.103750>.