



TOBB ETÜ
Ekonomi ve Teknoloji Üniversitesi

TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ

Bilgisayar / Yapay Zekâ Mühendisliği

BİL 495 — YAP 495

Project Specifications Report

Proje Spesifikasyon Raporu

Sistemin ne yapacağı: kapsam, kısıtlar, etik sorumluluklar, gereksinim listesi

Proje Adı	Giyilebilir Cihaz Verileriyle Kişiselleştirilmiş Sağlık Asistanı
Takım Üyeleri	Gülsüm Yıldırım Nurefşan Olfaz Remzi Mert Tehneldere Bektaş Batuhan Kestek
Danışman	—
Akademik Dönem	2026 Yaz
Teslim Tarihi	28.06.2026

İçindekiler

İçindekiler	3
1. Giriş.....	4
1.1 Amaç	4
1.2 Hedef Kullanıcı	4
1.3 Başarı Kriterleri.....	4
2. Tanım	5
2.1 Ana Fonksiyonlar	5
2.2 Kapsam Dışı (Out-of-Scope)	5
3. Kısıtlar	6
3.1 Ekonomik / Finansal Kısıtlar	6
3.2 Hukuki Kısıtlar.....	6
3.3 Etik Kısıtlar	6
3.4 Sağlık / Güvenlik Kısıtları	6
3.5 Sürdürülebilirlik ve Teknolojik Kısıtlar.....	6
3.6 Uygulanmayan Kategoriler	7
4. Profesyonel ve Etik Konular	7
4.1 Kamu Yararı ve Zarar Vermeme	7
4.2 Mahremiyet ve Veri Koruma (KVKK / GDPR)	7
4.3 Dürüstlük, Şeffaflık ve Sınırların Beyanı	7
4.4 Üçüncü Taraf Lisansları ve Veri Seti Kullanımı	7
5. Gereksinimler	7
5.1 Fonksiyonel Gereksinimler	8
5.2 Non-Fonksiyonel Gereksinimler.....	8
6. Kaynaklar	9
Tools & Methodology.....	9

1. Giriş

Bu rapor, “Giyilebilir Cihaz Verileriyle Kişiselleştirilmiş Sağlık Asistanı” projesinin spesifikasyonunu tanımlar. Amaç, geliştirilecek sistemin ne olduğunu; kapsamını, kısıtlarını, etik ve profesyonel sorumluluklarını ve ilk gereksinim listesini ortaya koymaktır. Bu aşamada henüz ayrıntılı analiz ya da tasarım yapılmamakta; projenin sınırları ile karşılanması beklenen gereksinimlerin çerçevesi çizilmektedir. Ayrıntılı analiz modeli Analiz Raporu’nda, kısıtların detaylı işlenişi ise PKE-Plan dokümanında ele alınacaktır.

1.1 Amaç

Proje, kullanıcının halihazırda sahip olduğu giyilebilir cihazdan (Apple Watch, Samsung Galaxy Watch veya eşdeğeri) toplanan fizyolojik verileri kişiye özel bir temel çizgi (baseline) üzerinden yorumlayan bir mobil sağlık farkındalık asistanı geliştirmeyi amaçlar. Mevcut ticari uygulamaların çoğu, fizyolojik değerlendirmeyi popülasyon ortalamalarından türetilmiş genel eşiklere dayandırır; oysa kişiselleştirilmiş yaklaşımların genel modellere kıyasla belirgin biçimde daha yüksek doğruluk sağladığı gösterilmiştir (Li vd., 2024); oysa dinlenik nabız ve kalp atış hızı değişkenliği (HRV) gibi göstergeler bireyler arasında geniş bir aralıkta değişir. Sistem, her kullanıcının kendi geçmiş verisinden öğrenilen normal aralığı referans alarak anlamlı sapmaları tespit eder (Nkurikiyeyezu vd., 2019); makine öğrenmesi ve istatistiksel yöntemlerin sayısal çıktılarını bir büyük dil modeli (LLM) aracılığıyla sade ve eyleme geçirilebilir bir dile çevirir. Sistem bir tıbbi teşhis aracı değil, klinik ortam gerektirmeyen bir karar-destek ve farkındalık asistanıdır.

1.2 Hedef Kullanıcı

Birincil hedef kullanıcı; Apple Watch, Samsung Galaxy Watch veya eşdeğer bir giyilebilir cihaza sahip, sağlığını proaktif biçimde takip etmek isteyen 18-50 yaş aralığındaki, genel olarak sağlıklı bireylerdir. İkincil kullanıcı kitlesi ise kronik stres yaşayan bireyler, düzenli egzersiz yapanlar ve fizyolojik döngülerini daha iyi anlamak isteyen kadın kullanıcılarıdır. Sistem, klinik düzeyde tanı bekleyen hastalar veya kesin tıbbi ölçüm ihtiyacı olan kullanıcılar için tasarlanmamıştır.

1.3 Başarı Kriterleri

Projenin başarısı, aşağıdaki ölçülebilir kriterlerle değerlendirilecektir. Bu hedefler ilgili literatürdeki benzer çalışmaların raporladığı performans aralıkları esas alınarak belirlenmiş olup ilk deney sonuçları doğrultusunda revize edilebilir:

Başarı Kriteri	Hedef Değer
Stres sınıflandırma başarısı (WESAD, ikili, kişi-bazlı bölme)	$\geq$ %80 doğruluk ve makro-F1
Aktivite sınıflandırma doğruluğu (kişi-bazlı bölme)	$\geq$ %80 doğruluk
Anomali tespiti: sağlıklı günlerde yanlış pozitif oranı	$\leq$ %10
Anomali tespiti: hastalık bildirilen günlerde sinyal yükselmesi	$\geq$ %60 örtüşme

Uçtan uca gecikme (veri çekimi → ekranda gösterim)	≤ 5 saniye
LLM çıktısı güvenliği: teşhis içermeyen, normalleştirici yanıt oranı	$\geq \%90$ uygun çıktı

Tablo 1. Ölçülebilir başarı kriterleri.

2. Tanım

Giyilebilir cihazların kullanımı son yıllarda hızla yaygınlaşmış, akıllı saat kullanıcı sayısı dünya genelinde yüz milyonları aşmıştır (DemandSage, 2026). Sistem, kullanıcının halihazırda sahip olduğu bu giyilebilir cihazlardan iOS'ta HealthKit (Apple Inc., t.y.), Android'de Health Connect (Google, t.y.) arayüzü üzerinden okunan fizyolojik sinyalleri işleyen bir mobil uygulamadır. Tüm modeller yalnızca bir kez, halka açık veri setleri üzerinde çevrimdışı eğitilir; kullanıcının kişisel verisi modeli yeniden eğitmek için asla kullanılmaz, yalnızca çıkarım anında kişiselleştirme amacıyla işlenir. Sistem dört analitik bileşen ile bunları tamamlayan bir LLM yorumlama katmanından oluşur ve sonuçları kullanıcıya sade bir dille sunar.

2.1 Ana Fonksiyonlar

Sistemin sağlayacağı temel işlevler şunlardır:

- Veri erişimi ve kişisel temel çizgi: Kullanıcının izniyle çekirdek sinyalleri (kalp atış hızı, dinlenik nabız, HRV, uyku, adım, mesafe, aktif kalori) okur ve her kullanıcı için 28 günlük kayan pencereye dayalı kişisel bir temel çizgi oluşturur.
- Stres sınıflandırma: Fizyolojik özniteliklerden, tablo verisinde güçlü performans gösteren XGBoost (Chen ve Guestrin, 2016) tabanlı denetimli bir model ile anlık stres durumunu tahmin eder.
- Anomali ve hastalık-olabilirlik tespiti: Kullanıcının kişisel baseline'ından çok-günlük sapmaları istatistiksel yöntemlerle (z-skor; ileride RHR-Diff ve HROS-AD) tespit eder ve olağandışı fizyolojik yükü erken uyarı olarak işaretler; bu yöntemler belirti-öncesi enfeksiyon tespitinde doğrulanmıştır (Mishra vd., 2020). Sistem hiçbir zaman belirli bir hastalığı isimlendirmez.
- Aktivite tanıma: Random Forest tabanlı bir model ile aktivite türünü ve yoğunluğunu (yatma, oturma, yürüme, koşma) sınıflandırır; anomali uyarılarına bağlam katar.
- Uyku skoru: Uyku verimliliği, toplam uyku süresi, uyanma sayısı ve (varsa) uyku evre oranlarından kural-tabanlı, açık formüllü bir 0-100 uyku skoru hesaplar.
- Bağlamsal regl döngüsü desteği (opsiyonel): Kullanıcının açık onayıyla regl döngüsü faz bilgisini değerlendirir; HRV ve dinlenik nabızın döngü fazlarına göre sistematik dalgalandığı bilindiğinden (Lin vd., 2026) bu bağlam yanlış alarmları azaltır ve LLM yorumuna katkı sağlar.
- LLM yorumlama ve görselleştirme: Tüm bileşenlerin sayısal çıktılarını tek bir sade paragrafta birleştirir; içgörü, uyarı ve gerektiğinde uzmana yönlendirme sunar, sonuçları grafiklerle görselleştirir.

2.2 Kapsam Dışı (Out-of-Scope)

Aşağıdaki işlevler bu projenin kapsamı dışındadır:

- ☐ Belirli bir hastalığın (grip, COVID-19 vb.) isimlendirilmesi veya teşhis edilmesi; sistem bir tıbbi teşhis aracı değildir.
- ☐ EDA (elektrodermal aktivite) tabanlı stres ölçümü; Apple Watch'ta donanım yoktur ve HealthKit/Health Connect'te standart tip değildir.
- ☐ Ham ECG/EMG analizi, aritmi/kalp hastalığı tespiti, kan basıncı ve kan şekeri gibi tıbbi ölçümler.
- ☐ Klinik düzeyde uyku bozukluğu (uykusuzluk, uyku apnesi) teşhisi.
- ☐ Kendi giyilebilir donanımının üretimi; sistem marka-bağımsız olarak mevcut cihazlardan veri okur.
- ☐ Çoklu platform desteği; MVP tek platformda (iOS veya Android) çalışır.
- ☐ Kullanıcı verisiyle modelin yeniden eğitilmesi; eğitim yalnızca halka açık veri setleriyle çevrimdışı yapılır.
- ☐ Ham sinyal üzerinde LSTM, autoencoder gibi gelişmiş derin öğrenme yöntemleri; zaman elverirse değerlendirilecek ileri aşama hedefleridir.

3. Kısıtlar

Bu bölüm, projeye uygulanabilir kısıt kategorilerini özet düzeyinde ele alır; her kategorinin ayrıntılı versiyonu, doğrulama yöntemleriyle birlikte PKE-Plan dokümanında işlenecektir. İlgili olmayan kategoriler için neden uygulanmadığı açıkça belirtilmiştir.

3.1 Ekonomik / Finansal Kısıtlar

Proje, dört kişilik bir öğrenci ekibi tarafından, ek bütçe olmaksızın geliştirilmektedir. Bu nedenle yalnızca açık erişimli veri setleri (WESAD: Schmidt vd., 2018; LifeSnaps: Yfantidou vd., 2022) ve ücretsiz/öğrenci katmanı geliştirme araçları kullanılacaktır. LLM yorumlama katmanı için ticari bir API kullanılması, çağrı başına maliyet doğurur; bu maliyet, API'ye yalnızca anonim sayısal çıktıların gönderilmesi ve çağrı sıklığının günlük özetle sınırlandırılmasıyla asgaride tutulacaktır. İleri aşamada cihaz üzerinde çalışan küçük dil modeli (SLM) değerlendirilerek API bağımlılığı ve maliyeti tümüyle ortadan kaldırılabılır.

3.2 Hukuki Kısıtlar

Sistem, sağlık ve biyometrik veri işlediğinden 6698 sayılı Kişisel Verilerin Korunması Kanunu (KVKK) ve Avrupa Birliği Genel Veri Koruma Tüzüğü (GDPR) kapsamındaki özel nitelikli kişisel veri yükümlülüklerine tabidir. Her veri türü için kullanıcıdan ayrı ve açık rıza alınması, verinin yerel cihazda tutulması, üçüncü taraf LLM API'sine yalnızca tek başına kimliklendirmeye yetmeyen anonim sayısal çıktıların iletilmesi zorunludur. Apple App Store ve Google Play'in sağlık verisi politikaları ile HealthKit/Health Connect kullanım koşulları da bağlayıcı kısıtlardır.

3.3 Etik Kısıtlar

Sistem, kullanıcıların sağlık algısını doğrudan etkileyebileceğinden, çıktıların gereksiz kaygıya yol açmaması temel bir etik kısıttır. Sistem teşhis koymamalı, kesin tıbbi iddialarda bulunmamalı ve normalleştirici bir dil kullanılmalıdır. Üreme sağlığı verisi gibi son derece hassas bilgilere yalnızca açık onayla erişilmeli; modelin dar demografili veri setlerinden (örneğin WESAD’ın 15 katılımcısı) kaynaklanan yanlılığı şeffaf biçimde raporlanmalıdır.

3.4 Sağlık / Güvenlik Kısıtları

Sistem bir tıbbi cihaz değildir ve klinik karar yerine geçmez. Bu nedenle her çıktının, gerektiğinde kullanıcıyı bir sağlık uzmanına yönlendiren bir sorumluluk reddi (disclaimer) ile birlikte sunulması güvenlik açısından zorunludur. Yanlış-negatif (gerçek bir sapmanın kaçırılması) ve yanlış-pozitif (gereksiz alarm) dengesi gözetilmeli; sistem yalnızca tek bir okuma üzerine değil, birkaç gün süren kalıcı sapma üzerine uyarı vermelidir.

3.5 Sürdürülebilirlik ve Teknolojik Kısıtlar

Modeller yalnızca bir kez çevrimdışı eğitildiğinden sürekli yeniden eğitimin getireceği hesaplama maliyeti ve enerji tüketimi ortadan kalkar; çıkarım, mobil cihazda hafif modellerle yapılır. Teknolojik açıdan sistem, HealthKit ve Health Connect’in sağladığı veri türleri ve örnekleme sıklığıyla sınırlıdır; örneğin HealthKit’te HRV çoğunlukla yalnızca “Breathe/Mindfulness” egzersizleri sırasında ölçülür, bu da baseline kurulumunu kısıtlar.

3.6 Uygulanmayan Kategoriler

Çevresel kısıtlar: Uygulanmıyor — proje fiziksel donanım üretmeyen, yalnızca yazılımdan oluşan bir mobil uygulamadır; üretim atığı, malzeme veya saha kurulumu içermez. Tek dolaylı çevresel etki, bulut/LLM çağrılarının enerji tüketimidir ve bu da çağrı sıklığının sınırlandırılmasıyla azaltılmaktadır.

Sosyal / Kültürel kısıtlar: Sınırlı düzeyde uygulanıyor — sistem belirli bir kültüre özgü içerik üretmez; ancak LLM çıktılarının dilinin kapsayıcı olması ve kadın sağlığına ilişkin verilerin (regl döngüsü) ayrımcı olmayan, normalleştirici bir dille ele alınması gözetilecektir.

4. Profesyonel ve Etik Konular

Bu bölüm, ACM/IEEE Yazılım Mühendisliği Etik İlkeleri çerçevesinde projeye özgü profesyonel ve etik sorumlulukları ele alır.

4.1 Kamu Yararı ve Zarar Vermeme

ACM/IEEE etik ilkelerinin “kamu yararını gözetme” maddesi gereğince sistem, kullanıcıya zarar vermekten kaçınmalıdır. Sağlık alanında en belirgin zarar riski, yanlış güvenceyle gerçek bir sorunun gözden kaçması veya gereksiz alarmla kaygı yaratılmasıdır. Bu nedenle sistem teşhis koymaz, “gribiniz var” gibi kesin ifadeler kullanmaz; bunun yerine “dinlenme nabzınız son birkaç gündür kişisel ortalamanızın üzerinde, belirtiler sürerse bir uzmana danışın” gibi temkinli ve yönlendirici bir dil kullanır.

4.2 Mahremiyet ve Veri Koruma (KVKK / GDPR)

Proje, KVKK ve GDPR kapsamında özel nitelikli kişisel veri olarak sınıflandırılan sağlık ve biyometrik veriler işlemektedir. Bu yükümlülükleri karşılamak için şu profesyonel önlemler alınır: her veri türü için

ayrı ve açık rıza; veri minimizasyonu (yalnızca gerekli sinyallerin okunması); kişisel verinin yerel cihazda tutulması ve model eğitiminde kullanılmaması; üçüncü taraf LLM API’sine ham fizyolojik veri yerine yalnızca anonim sayısal çıktıların iletilmesi. Regl döngüsü fazı gibi hassas bağlamsal bilgiler yalnızca açık onayla ve yalnızca sayısal faz kodu (0–3) olarak aktarılır. Kullanıcı, verdiği izinleri her an geri çekebilir; sistem eksik veriye dayanıklı tasarlanır.

4.3 Dürüstlük, Şeffaflık ve Sınırların Beyanı

Etik ilkelerin “dürüstlük” ve “mesleki yetkinlik” maddeleri gereğince, sistemin sınırları kullanıcıya açıkça beyan edilir. Kullanılan algoritmalar (kişisel baseline, z-skor, RHR-Diff, HROS-AD, kural-tabanlı uyku skoru) şeffaftır; bu, ticari ürünlerin kapalı algoritmalarına karşı projenin temel farklılaşma noktasıdır. Modelin dar demografili veri setlerinden kaynaklanan yanlılığı ve LifeSnaps stres etiketinin Fitbit’in kapalı algoritmasından türetilmiş olması gibi sınırlamalar raporlarda açıkça belirtilir.

4.4 Üçüncü Taraf Lisansları ve Veri Seti Kullanımı

Projede kullanılan veri setleri ve kütüphaneler, lisans koşullarına uygun biçimde kullanılacaktır. WESAD, LifeSnaps ve halka açık Apple Watch/Fitbit aktivite veri seti yalnızca araştırma/akademik kullanım koşullarıyla; XGBoost, scikit-learn ve benzeri açık kaynak kütüphaneler ise kendi açık kaynak lisanslarıyla kullanılır. Tüm veri setlerine ve dış kaynaklara raporlarda usulüne uygun atıf yapılır; kullanılan LLM API’sinin hizmet koşullarına uyulur.

5. Gereksinimler

Bu bölüm, sistemin ilk gereksinim listesini sunar. Gereksinimler fonksiyonel (FR) ve non-fonksiyonel (NFR) olarak numaralandırılmıştır; bu liste Analiz Raporu’nda detaylandırılarak kabul kriterleriyle genişletilecektir.

5.1 Fonksiyonel Gereksinimler

ID	Fonksiyonel Gereksinim
FR1	Sistem, kullanıcının açık izniyle HealthKit (iOS) veya Health Connect (Android) üzerinden çekirdek fizyolojik sinyalleri (kalp atış hızı, dinlenik nabız, HRV, uyku, adım, mesafe, aktif kalori) okuyabilmelidir.
FR2	Sistem, her kullanıcı için 28 günlük kayan pencereye dayalı kişisel bir temel çizgi (baseline) oluşturmali ve veri biriktikçe güncellemelidir.
FR3	Sistem, fizyolojik özniteliklerden XGBoost tabanlı bir model ile anlık stres durumunu sınıflandırmalıdır.
FR4	Sistem, kullanıcının baseline’ından çok-günlük sapmaları istatistiksel yöntemlerle tespit edip olağandışı fizyolojik yükü erken uyarı olarak işaretlemeli, ancak belirli bir hastalık adı vermemelidir.
FR5	Sistem, Random Forest tabanlı bir model ile aktivite türünü ve yoğunluğunu sınıflandırmalı ve bu bağlamı anomali değerlendirmesine katmalıdır.
FR6	Sistem, kural-tabanlı açık bir formülle 0-100 aralığında bir uyku skoru hesaplamalıdır.
FR7	Sistem, kullanıcı açıkça izin verdiyse regl döngüsü faz bilgisini bağlamsal sinyal olarak değerlendirerek yanlış alarmları azaltmalıdır.

FR8	Sistem, tüm bileşenlerin sayısal çıktılarını bir LLM aracılığıyla tek bir sade, teşhis içermeyen paragrafa dönüştürmelidir.
FR9	Sistem, fizyolojik verileri ve analiz sonuçlarını grafiklerle görselleştirmeli ve trendleri kullanıcıya sunmalıdır.
FR10	Sistem, kullanıcının her veri türü için izni ayrı ayrı vermesine ve dilediği an geri çekmesine olanak tanımalı; eksik veriyle azaltılmış modda çalışmaya devam edebilmelidir.
FR11	Sistem, çıktıların yanında, gerektiğinde kullanıcıyı bir uzmana yönlendiren bir sorumluluk reddi (disclaimer) göstermelidir.

Tablo 2. Fonksiyonel gereksinimler.

5.2 Non-Fonksiyonel Gereksinimler

ID	Kategori	Non-Fonksiyonel Gereksinim
NFR1	Performans	Veri çekiminden sonucun ekranda gösterilmesine kadar uçtan uca gecikme ≤ 5 saniye olmalıdır.
NFR2	Doğruluk	Stres ve aktivite sınıflandırma modelleri, kişi-bazlı bölme ile $\geq \%80$ doğruluk sağlamalıdır.
NFR3	Güvenilirlik	Anomali tespiti, sağlıklı günlerde $\leq \%10$ yanlış pozitif oranıyla çalışmalıdır.
NFR4	Güvenlik / Mahremiyet	Ham fizyolojik veri hiçbir zaman üçüncü taraf LLM API'sine gönderilmemeli; API'ye yalnızca anonim sayısal çıktılar iletilmelidir.
NFR5	Kullanılabilirlik	LLM çıktıların $\geq \%90$ 'ı teşhis içermeyen, normalleştirici ve anlaşılır bir dilde olmalıdır.
NFR6	Taşınabilirlik	Çekirdek analitik bileşenler, HealthKit ve Health Connect veri modelleriyle uyumlu, cihaz-bağımsız çalışmalıdır.
NFR7	Sağlamlık (Dayanıklılık)	Sistem, herhangi bir bağlamsal sinyal (SpO2, regl fazı, HRV) eksik olduğunda çökmeden, azaltılmış modda çalışmaya devam etmelidir.

Tablo 3. Non-fonksiyonel gereksinimler (ölçülebilir hedeflerle).

6. Kaynaklar

Apple Inc. (t.y.). HealthKit. Apple Developer Documentation. <https://developer.apple.com/documentation/healthkit>

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785–794. <https://doi.org/10.1145/2939672.2939785>

DemandSage. (2026). Smartwatch statistics: Global users & market share. <https://www.demandsage.com/smartwatch-statistics/>

Google. (t.y.). Health Connect. Android Developers. <https://developer.android.com/health-and-fitness/guides/health-connect>

- Li, X., Dunn, J., Salins, D., Zhou, G., Zhou, W., Schüssler-Fiorenza Rose, S. M., & Sonecha, R. (2024). A comparison of personalized and generalized approaches to emotion recognition using consumer wearable devices. *JMIR AI*, 3, e52171. <https://doi.org/10.2196/52171>
- Lin, J., Li, T., Kalani, K., Malak, P., Tran, M., & Dolatabadi, E. (2026). mcPHASES: A dataset of physiological, hormonal, and self-reported events and symptoms for menstrual health tracking with wearables. *Scientific Data*, 13, 305. <https://doi.org/10.1038/s41597-026-06805-3>
- Mishra, T., Wang, M., Metwally, A. A., Bogu, G. K., Brooks, A. W., Bahmani, A., ... Snyder, M. P. (2020). Pre-symptomatic detection of COVID-19 from smartwatch data. *Nature Biomedical Engineering*, 4, 1208–1220. <https://doi.org/10.1038/s41551-020-00640-6>
- Nkurikiyeyezu, K., Yokokubo, A., & Lopez, G. (2019). The effect of person-specific biometrics in improving generic stress predictive models. *arXiv*. <https://arxiv.org/abs/1910.01770>
- Schmidt, P., Reiss, A., Dürichen, R., Marberger, C., & Van Laerhoven, K. (2018). Introducing WESAD, a multimodal dataset for wearable stress and affect detection. *Proceedings of the 20th ACM International Conference on Multimodal Interaction*, 400–408. <https://doi.org/10.1145/3242969.3242985>
- Yfantidou, S., Karagianni, C., Efstathiou, S., Vakali, A., Palotti, J., Giakatos, D. P., ... Girdzijauskas, Š. (2022). LifeSnaps, a 4-month multi-modal dataset capturing unobtrusive snapshots of our lives in the wild. *Scientific Data*, 9, 663. <https://doi.org/10.1038/s41597-022-01764-x>

Tools & Methodology

Bu raporun taslak hazırlığında, metin akışının düzenlenmesi ve biçimlendirme amacıyla yapay zekâ destekli bir dil modelinden yararlanılmış; üretilen tüm içerik ekip tarafından gözden geçirilmiş, projeye özgü bilgilerle düzenlenmiş ve doğrulanmıştır. İçeriğin doğruluğundan ekip sorumludur.