

Çalışan Yıpranması Tahmin Etmek için Hiper Parametresi Ayarlanmış Makine Öğrenme Algoritmalarının Kullanılması

Volkan Bayırbağ^{1*}, Halit Bakır²

¹Savunma Teknolojileri / Institute of Graduate Studies, Sivas Bilim ve Teknoloji Üniversitesi, Türkiye

²Bilgisayar Mühendisliği / Faculty of Engineering and Natural Sciences, Sivas Bilim ve Teknoloji Üniversitesi, Türkiye

*(vlknbyrbg@gmail.com) Başlıca yazarın mail adresi

Özet – Çalışanların çalışma ortamları, saatlerin düzensizliği, aşırı iş yükü gibi nedenler çalışanların yıpranmasına ve performansına etki etmektedir. Bu çalışmada, çalışan yıpranması verileri doğru bir şekilde işlenerek firmalar için doğru bir sonuç üretmesi için yapay zeka ve makine öğrenmesi kullanılması önerilmiştir. IBM veri seti üzerinde yapılan SMOTE işlemleri ve ardından elde edilen doğruluk değerleri iyileştirmek için hiper parametre tuning işlemleri uygulanmıştır. Sonuçlar incelendiğinde, Hiper parametre tuning işlemleri yapılmadan önce en yüksek doğruluk değeri veren algoritma LGBM Classifier olarak tespit edilmiştir. Daha sonra hiper parametre tuning işlemleri uygulanmış ve SVC makine öğrenmesi yönteminin %95.72 doğruluk oranına çıktığı tespit edilmiş ve literatürde SVC algoritması ile elde edilen en yüksek doğruluk puanı olarak tespit edilmiştir. Değerlendirme sonucunda SVC yönteminin IBM dataseti için en uygun algoritma olduğu önerilmiştir.

Anahtar Kelimeler – Makine Öğrenmesi, Yapay Zeka, Çalışan Yıpranması, SVC, Xgbclassifier

I. GİRİŞ

İş yaşam dengesi günümüz iş dünyasında önemli bir konu olarak ele alınmaktadır. Çünkü çalışanların yaşamında ve davranışlarında önemli sonuçlara neden olmaktadır. Çalışanların çalışma ortamları, saatlerin düzensizliği, aşırı iş yükü gibi nedenler çalışanların yıpranmasına ve performansına etki etmektedir[1]. Çalışan yıpranması, çalışan kaybı olarak tanımlanabilir. Çalışan yıpranmasını gönüllü ve istemsiz yıpranma şeklinde iki farklı şekilde düşünebiliriz. İsteksiz yıpranma görevlerinden feshetmeleri ile ortaya çıkar düşük performans gibi etkenler buna sebep olabilir. Gönüllü yıpranma ise kendi istekleri ile şirketten ayrılmak olarak düşünülebilir. Bunun birkaç sebeplerinden bazıları başka şirketlerden gelen daha iyi teklifler ya da erken emeklilikler gibi[2]. Çalışanların yıpranması doğru orantılı olarak müşteri memnuniyeti de etkilemektedir. Bu

ilişki sebebi ile firmalar “hizmet - kar zinciri” artırmak için çalışanların iş memnuniyetlerinin çok önemli olduğunun farkına varmış ve bunu artırmak için inceleme ihtiyacını doğurmuştur[3]. Böyle bir inceleme ihtiyacı doğrultusunda insan kaynakları tarafından çalışanların memnuniyetleri ve işten ayrılma sebepleri gibi verilerin doğru bir şekilde alınması üzerine çalışmalar yapılmıştır[4]. Bu verilerin doğru bir şekilde işlenip firmalar için doğru bir sonuç üretmesi için yapay zeka ve makine öğrenmesi kullanılması daha etkili ve doğru sonuçlar almamıza yardımcı olacaktır [5]. Çalışan yıpranması ve performansı konusunda literatür taraması yapılarak yapay zeka ve makine öğrenmesi kullanan farklı çalışmalar incelenmiştir.

II. MATERYAL VE YÖNTEM

Fallucchi ve arkadaşları yıpranma paylarını incelendiğinde çalışan kategorisi işçi olanların insan

kaynakları ve satış departmanına göre %54 daha fazla yıprandıkları ve iş bıraktıkları görülmektedir. Ayrıca yaş kategorisine bakıldığında (18-23 yaş grubundaki) çalışanların ayrılma olasılıklarının daha fazla olduğu görülmüştür. Modelleme sürecinde Karar ağacı yöntemi, Bayes yöntemi, Lojistik regresyona ve SVM'ye dayalı olanlar gibi çeşitli tahmin yöntemleri kullanılmıştır. Mevcut çalışmada en iyi sonuçları üreten algoritma Bayes yöntemidir. En iyi recall rate oranı (0.54) olarak hesaplanmıştır. Çalışanların yıpranması ve performansı incelenmek istendiğinde Bayes yönteminin kullanılmasının daha iyi olacağını savunmuşlardır[6].

Adduayj ve arkadaşları ise modelleme sürecinde Random Forest, Cubic SVM, Gaussian SVM ve KNN (K=3) yöntemleri kullanmışlardır. Bu yöntemler 0.91 ile 0.93 arasında yüksek F1 skorları almıştır. En iyi yöntemin Random Forest olduğunu savunmuş ve makine öğrenmesi kullanılırken bu yöntemin daha doğru sonuçlar üreteceğini savunmuşlardır[2].

Jain ve arkadaşları IBM Analytics tarafından alınan verilerin çok karmaşık olduğu ve gereksiz sütunların olduğu savunulmuştur. Bu karmaşıklık sebebi ile tahmin etmek zor olduğundan XGBoost tabanlı bir makine öğrenmesini tercih etmişlerdir. Bu yöntem hem daha hızlı hemde daha yüksek doğruluk sağladığı için tercih edilmesi önerilmiştir. Bu model %90 oranında bir doğruluk seviyesine ulaşmıştır. Bu nedenlerden dolayı XGBoost tekniğini önermişlerdir[7].

Qutub ve arkadaşları 6 farklı öğrenim modeli uygulanmıştır. Bunlar Karar Ağacı modeli, Random Forest, Adabost, Logistic Regression, Decision Tree modelleridir. Bu modeller arasında Logistic Regression ve Decision Tree modellerini %86.39 doğruluk oranlarına ulaşmıştır. Bu veri setinde bu iki modelin kullanılmasının daha iyi olacağını savunmuşlardır[8].

Zangeneh ve arkadaşları ilk başta boyut küçültme işlemi kullanmışlardır. Boyut küçültme işlemi yapıldıktan sonra Logistic Regression tekniği

kullanılarak %81 doğruluk puanı elde edilmiştir. Bu veri seti için Logistic Regression tekniğinin daha başarılı bir teknik olduğunu savunmuşlardır[9].

Bhartiya ve arkadaşları Naive Bayes, Random Forest, Decision Tree, Support Vector Machine ve K-En Yakın Komşu, makine öğrenmesi algoritmaları kullanmışlardır. Çalışmada elde edilen sonuçlara göre Random Forest %83'lük bir doğruluk puanı elde etmiştir [10].

Raza ve arkadaşları ETC, SVM, LR ve DTC yöntemleri kullanmışlardır.. Uygulanan makine öğrenmesi tekniklerinde SVM algoritması ile %87, LR algoritması ile %72 ve DTC algoritması ile %83 doğruluk puanı elde edilmiştir. Çalışmada elde edilen en iyi sonuçları, ETC ile elde edilmiş olup %93 ulaşmıştır. En yüksek doğruluk puanı olan ETC bu veri seti için önerilmiştir. EDA uygulamaları yapılarak daha doğru sonuçlar alınabileceğini söylemişlerdir[11].

Bu çalışmada çalışan yıpranması tahmini iyileştirmek için kullanılan makine öğrenmesi algoritması üzerine hiper parametre tuning işlemi uygulanmıştır.


Kullanılan veri seti

Bu çalışmada 1470 satır 35 sütundan oluşan 'Kaggle' veritabanından alınan IBM Analytics verileri üzerinde analiz yapılmıştır. Bu çalışmada python programlama dili kullanılarak makine öğrenmesi yöntemleri işe veri seti üzerinde çalışma yapılacaktır. Veri setinden örnek değerler Şekil 1'de verilmiştir.

Age	Attrition	BusinessTravel	DailyRate	Department	DistanceFromHome	Education	EducationField	EmployeeCount	EmployeeNumber
41	1	Travel_Rarely	1102	Sales	1	2	Life Sciences	1	1
49	0	Travel_Frequently	279	Research & Development	8	1	Life Sciences	1	2
37	1	Travel_Rarely	1373	Research & Development	2	2	Other	1	4
33	0	Travel_Frequently	1392	Research & Development	3	4	Life Sciences	1	5
27	0	Travel_Rarely	591	Research & Development	2	1	Medical	1	7
32	0	Travel_Frequently	1005	Research & Development	2	2	Life Sciences	1	8
59	0	Travel_Rarely	1324	Research & Development	3	3	Medical	1	10
30	0	Travel_Rarely	1350	Research & Development	24	1	Life Sciences	1	11
38	0	Travel_Frequently	216	Research & Development	23	3	Life Sciences	1	12
36	0	Travel_Rarely	1299	Research & Development	27	3	Medical	1	13


Şekil 1. Veri setinden örnek değerler

Şekil 2'de görüldüğü gibi Attrition özniteliği içerisinde 1(Yes) – 0(No) değerlerini kullanarak sınıflandırabiliriz. Çalışmada belirtilen 35 özniteliği kullanarak makine öğrenmesi modelleri ile doğru sınıflamalar yapabiliriz.



Şekil 2. Sınıflama yapılacak özniteliğin değerleri

Şekil 2’de görüldüğü gibi veri setimizde 1233 yıpranmış bireyler 237 yıpranmamış bireyler bulunmaktadır. Çalışmada belirtilen 35 özniteliği makine öğrenmesi modellerine giriş olarak verilmesi ile sınıflandırma işlemi gerçekleştirilerek kişilerin yıpranmış olup olmadığı hakkında karar verilecektir. Makine öğrenmesi algoritmalarına geçmeden önce veri seti üzerinde ve temizleme ve aykırı noktalar temizleme gibi bir takım ön işleme faz gerçekleştirilmiştir. Ardından veri seti üzerinde dengesizlik olduğu görünmektedir. Bu dengesizliğin giderilmesi için veri seti üzerinde SMOTE algoritması uygulanmıştır. Bu ön işlem faz uygulandıktan sonra 1185 yıpranmış birey 1185 yıpranmamış bireyler olarak veri seti güncellenmiştir. Veri seti üzerinde SMOTE algoritmasının kullanılma sebebi daha sağlıklı bir şekilde eğitilen makine öğrenmesi algoritmaları elde etmektir. Sınıflandırma yapılacak verilerin yeni dağılımları Şekil 3’de verilmiştir.



Şekil 3. Sınıflama yapılacak yeni öznitelik değerleri

A. Random Forest

Rassal Orman (Random forest), hem sınıflandırma hemde tahminleme problemlerinde uygulanabilir olmasından dolayı çok popüler bir makine öğrenmesi algoritmasıdır. Random forest algoritması veri seti içerisinde rassal olarak karar ağaçları oluşturur ve bu karar ağaçları arasında tahminleme yapar. Sınıflama problemlerinde bu karar ağaçlarını eğiterek tahminleme değerleri alır ve en çok oy alan karar ağacını sınıflandırır. Random forest algoritması karar ağaçlarını eğitirken aynı zamanda hangi özniteliğin daha faydalı olduğuna karar verebilir.

B. XGB Classifier

XGBClassifier (Extreme Gradient Boosting) algoritması Gradient Boosting algoritmasının optimize edilmesi ile elde edilmiş bir algoritmadır. Bu algoritmasının en büyük özelliklerinden biri ezberlemenin önüne geçmektir ve karar ağacı altyapısı kullanan en hızlı algoritma olmasıdır. Algoritmanın çalışma prensibi Gradient boosting algoritmasına çok benzemektedir. Algoritma 0.5 lik bir ilk tahmin ile çalışmaya başlar ve daha sonra hatalı tahminleri gözlemlemeye başlar. Hatalı tahminler üzerine bir karar ağacı oluşturur ve hataları öğrenerek doğru tahmini bulmak için devam eder. Kurulan karar ağacı üzerindeki her bir dal için benzerlik skoru hesaplar.

$$\text{Similarity Score} = \frac{\text{Sum of Residuals, Squared}}{\text{Number of Residuals} + \lambda}$$

Şekil 4. XGB Classifier Formülü

Benzerlik skoru hesaplandıktan sonra her bir olasılık için karar ağacı oluşturulur amaç daha iyi bir tahmin yapılıp yapılamayacağıdır. Bu şekilde olasılıklar değerlendirilerek tahminler düzeltilir. Bu sayede hem daha doğru kararlar alır hemde diğer sınıflandırma algoritmalarına göre daha hızlı çalışır.

C. KNN

K-en yakın komşu algoritması, gözlemlerin birbirine olan benzerliklerine göre tahminde bulunan gözetimli bir makine öğrenmesi modelidir.

K-en yakın komşu algoritması tahminde bulunmak istediğimiz gözlem birimine en yakın K adet gözlem tespit eder ve K adet gözlemden bağımlı değişkenleri üzerinden tahminde bulunur. Örnek olarak iki değer alınır ve uzaklık hesabı yapılarak K adet gözlem oluşturulur en sık gözlenen değer tahmin edilerek bulunur.

D. SVC

Destek VEktör Makineleri (SVM) genellikle sınıflandırma problemlerinde kullanılır. Veri setinde bulunan sınıflama yapacağımız öznitelik değerlerinin bir düzlemde nokta olarak düşünülmektedir. Bu düzlemde noktaları ayırmak için bir doğru çizer. Bu doğru iki sınıf içinde maksimum uzaklıkta olmasını amaçlar. Bu doğrular arasında uzaklık (margin) ne kadar genişse sınıflar o kadar iyi ayrıştırılır.

$$\hat{y} = \begin{cases} 0 & \text{if } \mathbf{w}^T \cdot \mathbf{x} + b < 0, \\ 1 & \text{if } \mathbf{w}^T \cdot \mathbf{x} + b \geq 0 \end{cases}$$

Şekil 5. SVC Formülü

Formüle bakacak olursak w ; ağırlık vektörü, x ; girdi vektörü, b ; sapma değerleri. Formüle göre değerler hesaplanır ve 0'dan küçük veya büyük olarak sınıflara dağıtılır. Çok karmaşık bir çalışma prensibine sahiptir ama küçük ve orta ölçekteki veri setleri için uygun bir algoritmadır.

E. LGBM

Son yıllarda veri boyutlarının ve çeşitliliğinin artması ile algoritmalara verilen önem artmıştır. LGBM algoritması gradient algoritmasının bir alternatifi olarak çıkmıştır hem daha yüksek doğruluk hemde daha yüksek bir hız sunmaktadır. Diğer boosting algoritmalarına göre daha yüksek işlem hızı, daha büyük veriler ile çalışabilmesi, daha az ram kullanımı, paralel öğrenme ve daha yüksek tahmin oranı sunmaktadır. LGBM algoritması histogram tabanlı çalışan bir algoritmadır. LGBM algoritması model yaprak stratejisi ile daha az hata oranına sahiptir. Bu algoritma yaprak odaklı strateji

kullandığı için büyük verilerde kullanılması tavsiye edilir.

F. Extra Trees

Random Forest algoritmasına çok benzer olarak çalışmaktadır farklı olarak karar ağaçlarının oluşturma biçiminde farklılık gösterir. Çalışma biçimi sınıflandırma sonucunun çıktısını alarak çoklu korelasyonu kaldırılmış karar ağacı sonuçlarını toplayan bir topluluk öğrenme tekniğidir.

Extra Trees algoritmasındaki her karar ağacı orjinal eğitim örneğinden oluşur. Daha sonra her test düğümü için her ağaca matematiksel işlemler uygulanır. En iyi özelliği seçmek için rastgele bir k özellik örneği sağlanır. Rastgele öznitelik örneği sayesinde birden çok karar ağacı oluşur. Orman inşası sırasında her özellik için ağaç bölünerek devam eder. Özellik seçimini gerçekleştirmek için her özellik, her bir özelliğin Gini Önem derecesine göre azalan sırada sıralanır ve kullanıcı tercihinine göre en iyi k özelliği seçer.

G. Bagging

Bagging algoritması orjinal veri setinden elde edilen veriler tahminciler uygulanarak bir topluluk oluşturulur. Oluşturulan alt örnekler veri setinde bulunan sayı ile aynı sayıya sahiptirler. Örnekler oluşturulurken orjinalinde bulunan bazı örnekler bu toplulukta bulunmaz. Bu örnekler birleştirilirken sınıflandırma sonuçları oylama ile belirlenir. Bagging algoritması tutarlı bir tahminde bulunur bu özelliği ile tekli ağaçlara göre daha etkin sonuçlar elde edilir.

H. Lazy Predict Library

Lazy Predict kütüphanesi veri hazırlığı yaparken veri seti için uygun olabilecek algoritmaları bizim için listeler. Lazy Predict kütüphanesi birden fazla model eğiterek en iyi modele ulaşmayı hedefler.

III. BULGULAR

Bu çalışmada analizler için Intel Core i7 10870H işlemciye sahip, 32 GB DDR4 belleğe

sahip olan bir bilgisayar kullanılmıştır. Veri seti üzerinde 15 farklı makine öğrenmesi üzerinde 10 fold değeri üzerinde deneysel çalışmalar yapılmıştır. Random Forest, XGBClassifier, LGBM, SVC, Extra Trees, Bagging ve KNN yöntemlerin sınıflandırma başarısı Tablo 1 de gösterilmiştir.

Tablo 1. Lazy Predict sonucu elde edilen performans değerleri

Model	AUC	ROC	F1
LGBMClassifier	%91	%91	%91
SVC	%90	%90	%90
ExtraTreesClassifier	%90	%90	%90
RandomForest	%89	%89	%89
XGBClassifier	%88	%88	%88
Label Propagation	%87	%87	%87
Label Spreading	%87	%87	%87
NuSVC	%86	%86	%86
BaggingClassifier	%86	%86	%86
KNeighborsClassifier	%85	%85	%85
AdaBoostClassifier	%83	%83	%83
Logistic Regression	%83	%83	%83
RidgeClassifier	%83	%83	%83
LinearSVC	%83	%83	%83
Perceptron	%81	%81	%81
GaussianNB	%74	%74	%74
DummyClassifier	%49	%50	%32

Tablo 1’de farklı makine öğrenmesi yöntemleri ile elde edilen değerler detaylı bir şekilde verilmiştir. Yapılan analizlerde en yüksek doğruluk değerleri veren ve en hızlı çalışma zamanını yakalayan 7 adet algoritma en iyi doğruluk değerleri sıra ile LGBM Classifier %91, SVC

Algoritması %90, Extra Trees Algoritması %90, Random Forest %89, XGBClassifier %88, Bagging Algoritması %86 ve KNN algoritması %85 olarak tespit edilmiştir. Yapılan analizlerin iyileştirilmesi amacıyla her bir algoritma üzerinde hiper parametre ayarlaması uygulanmıştır. Hiper parametre ayarlama işlemi sonucunda elde edilen yeni değerler Tablo 2 de gösterilmiştir.

IV. TARTIŞMA

Tablo 2 de görüldüğü gibi LGBM Classifier algoritmasının doğruluk değeri %91.33 iken hiper parametre tuning işlemleri uygulandıktan sonra %93.47’ye çıkarılmıştır.SVC algoritması ise %90.12’den %95.72’ye çıkarılarak en başarılı sonuç tespit edilmiştir.Extra Trees Classifier algoritması hiper parametre tuning işlemleri uygulanmadan önce %90.89 değerine sahipken işlem uygulandıktan sonra %91.87’ye çıkarılmıştır. Hiper parametre tuning uygulanan diğer algoritmalar ise sırasıyla Random Forest %89.27’den %89.57, XGBClassifier algoritması %88.05 den %91.34,Bagging Classifier algoritması %86.63 den %92.48 ve son olarak KNN %80.16 dan %83.27 ye çıkarılmıştır.

Tablo 2. Hiper parametre uygulandıktan sonra algoritma değerleri

Model	AUC	Hiper Parametre AUC
LGBMClassifier	%91.33	%93.47
SVC	%90.12	%95.72
ExtraTrees	%90.89	%91.87
RandomForest	%89.27	%89.57
XGBClassifier	%88.05	%91.34
BaggingClassifier	%86.63	%92.48
KNNClassifier	%80.16	%83.27

V. SONUÇLAR

İş yaşam dengesi günümüz iş dünyasında önemli bir konu olarak ele alınmaktadır. Çünkü

çalışanların yaşamında ve davranışlarında önemli sonuçlara neden olmaktadır. Çalışanların çalışma ortamları, saatlerin düzensizliği, aşırı iş yükü gibi nedenler çalışanların yıpranmasına ve performansına etki etmektedir. Çalışan yıpranması, çalışan kaybı olarak tanımlanabilir. Bu verilerin doğru bir şekilde işlenerek firmalar için doğru bir sonuç üretmesi için bu çalışmada yapay zeka ve makine öğrenmesi kullanılması önerilmiştir. İlk önce makine öğrenmesi algoritmaları varsayılan hali ile uygulanmıştır. Ardından, bu algoritmaların performansı iyileştirmek için hiper parametre tuning işlemi uygulanmıştır. Hiper parametre tuning işlemleri uygulanmadan önce en yüksek doğruluk değeri veren algoritma LGBM Classifier olarak tespit edilmiştir. Hiper Parametre tuning işlemi uygulandıktan sonraki sonuçlar incelendiğinde SVC makine öğrenmesi yönteminin %95.72 doğruluk oranına çıktığı tespit edilmiş ve literatürde SVC algoritması ile elde edilen en yüksek doğruluk puanı olarak tespit edilmiştir. Gelecek çalışmalarda IBM verilerinin genişlemesi ve güncellenmesi ile farklı makine öğrenmesi yöntemlerinin kullanılması ile başarı oranının artırılması düşünülmektedir.

KAYNAKLAR

- [1] Korkmaz, O., & Erdoğan, E. (2014). İş Yaşam Dengesinin Örgütsel Bağlılık ve Çalışan Memnuniyetine Etkisi. *Ege Academic Review*, 14(4).
- [2] Alduayj, S. S., & Rajpoot, K. (2018, November). Predicting employee attrition using machine learning. In *2018 international conference on innovations in information technology (iit)* (pp. 93-98). IEEE.
- [3] Chi, C. G., & Gursoy, D. (2009). Employee satisfaction, customer satisfaction, and financial performance: An empirical examination. *International journal of hospitality management*, 28(2), 245-253.
- [4] Ranjan, J., Goyal, D. P., & Ahson, S. I. (2008). Data mining techniques for better decisions in human resource management systems. *International Journal of Business Information Systems*, 3(5), 464-481.
- [5] CELİK, U. (2019). VERİ MADENCİLİĞİ YÖNTEMLERİ İLE İŞ YAŞAM DENGESİNDE YIPRANMA DURUMU TAHMİNİ. *Journal of Management and Economics Research*, 17(1), 63-76.
- [6] Fallucchi, F., Coladangelo, M., Giuliano, R., & William De Luca, E. (2020). Predicting employee attrition using machine learning techniques. *Computers*, 9(4), 86.
- [7] Jain, R., & Nayyar, A. (2018, November). Predicting employee attrition using xgboost machine learning approach. In *2018 international conference on system modeling & advancement in research trends (smart)* (pp. 113-120). IEEE.
- [8] Qutub, A., Al-Mehmadi, A., Al-Hssan, M., Aljohani, R., & Alghamdi, H. S. (2021). Prediction of employee attrition using machine learning and ensemble methods. *Int. J. Mach. Learn. Comput*, 11(2), 110-114.
- [9] Najafi-Zangeneh, S., Shams-Gharneh, N., Arjomandi-Nezhad, A., & Hashemkhani Zolfani, S. (2021). An Improved Machine Learning-Based Employees Attrition Prediction Framework with Emphasis on Feature Selection. *Mathematics*, 9(11), 1226.
- [10] Bhartiya, N., Jannu, S., Shukla, P., & Chapaneri, R. (2019, March). Employee attrition prediction using classification models. In *2019 IEEE 5th International Conference for Convergence in Technology (I2CT)* (pp. 1-6). IEEE.
- [11] Raza, A., Munir, K., Almutairi, M., Younas, F., & Fareed, M. M. S. (2022). Predicting Employee Attrition Using Machine Learning Approaches. *Applied Sciences*, 12(13), 6424.
- [12] Aydılek, İ. B. (2018). Yazılım hata tahmininde kullanılan metriklerin karar ağaçlarındaki bilgi kazançlarının incelenmesi ve iyileştirilmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(5), 906-914.