

KOBİ'lerin Ekonomiye Sağladıkları Katkının Tahmini İçin Derin Öğrenme Tabanlı Model

Anıl UTKU^{1*}, Ali SEVİNÇ², M. Ali AKCAYOL³

¹ Bilgisayar Mühendisliği, Mühendislik Fakültesi, Munzur Üniversitesi, Tunceli, Türkiye

² Türkiye Küçük ve Orta Ölçekli İşletmeleri Geliştirme ve Destekleme İdaresi, Ankara, Türkiye

³ Bilgisayar Mühendisliği, Mühendislik Fakültesi, Gazi Üniversitesi, Ankara, Türkiye

*¹ anilutku@munzur.edu.tr, ² alisevinc71@gmail.com, ³ akcayol@gazi.edu.tr

(Geliş/Received: 10/08/2023;

Kabul/Accepted: 30/08/2023)

Öz: Küçük ve Orta Büyüklükteki İşletme (KOBİ)'ler, sermayesi, işgücü ve varlıkları, ulusal yönetmeliklere göre belirlenen eşik değerlerin altında olan özel sektör işletmeleridir. KOBİ'ler, özellikle gelişmekte olan ülkelerde olmak üzere dünyadaki çoğu ülkenin ekonomisinde önemli rol oynamaktadır. Dünya genelinde işletmelerin yaklaşık %90'ını oluşturan KOBİ'ler, istihdamın %50'sinden fazlasını sağlamaktadır. Ülke ölçeğinde KOBİ'lerin ekonomiye katkılarının tahin edilmesi planlama ve yatırım açısından oldukça önemlidir. Bu çalışmada, KOBİ'lerin ekonomiye sağladıkları katkıların tahminine yönelik derin öğrenme tabanlı bir model geliştirilmiştir. Geliştirilen LSTM tabanlı derin öğrenme modelinin sonuçları, RF, SVM, CNN, MLP, RNN ve GRU ile karşılaştırılmıştır. Deneysel sonuçlar, geliştirilen derin öğrenme modelinin 2,169 MSE, 1,473 RMSE, 1,175 MAE ve 0,959 R² değeri ile karşılaştırılan diğer modellerden daha başarılı tahmin performansına sahip olduğunu göstermiştir.

Anahtar kelimeler: KOBİ, ÇKKV, OCRA, ekonomi, derin öğrenme, makine öğrenmesi.

Deep Learning Based Model for Predicting the Contribution of SMEs to the Economy

Abstract: Small and Medium-sized Enterprises (SMEs) are private sector enterprises whose capital, workforce and assets are below the thresholds determined according to national regulations. SMEs play an important role in the economy of most countries in the world, especially in developing countries. SMEs, which make up approximately 90% of enterprises worldwide, provide more than 50% of employment. Estimating the contribution of SMEs to the economy at the country level is very important in terms of planning and investment. In this study, a deep learning-based model was developed to predict the contribution of SMEs to the economy. The developed LSTM-based deep learning model was compared with RF, SVM, CNN, GRU, MLP and RNN. Experimental results showed that the developed model had a better prediction performance than other models compared with 2.169 MSE, 1.473 RMSE, 1.175 MAE, and 0.959 R² values.

Key words: SME, MCDM, OCRA, economy, deep learning, machine learning.

1. Giriş

Küçük ve Orta Büyüklükteki İşletme (KOBİ), gelirleri, varlıkları veya çalışan sayıları belirli bir eşğin altında olan işletmelerdir [1]. Her ülkenin kendi küçük ve orta ölçekli işletme tanımı vardır. Ülkeler, küçük bir işletmenin ne olduğunu tanımlamak için sektörler arasında farklı yönergeler belirler. KOBİ'ler dünya çapında faaliyet gösteren işletmelerin çoğunluğunu oluşturmaktadır. Genellikle 50'den az çalışanı olan bağımsız firmalardır [2]. Ancak, maksimum çalışan sayısı ülkeden ülkeye farklılık göstermektedir. Çoğu şirket için üst limit 250 civarındadır. Bazı ülkeler toplam çalışan sayısını 200 olarak kabul etmektedir [3].

Türkiye'de KOBİ'ler, çeşitli kriterlere göre tanımlanmış olan işletmelerdir. Türkiye'deki KOBİ tanımı genellikle işletmelerin çalışan sayısı, yıllık net satış hasılatı veya aktif büyüklüğü gibi ölçütlere dayanmaktadır. Türkiye'deki KOBİ tanımı, 2005 yılında yürürlüğe giren küçük ve orta büyüklükteki işletmelerin tanımı ve sınıflandırılması hakkında yönetmeliğe dayanmaktadır. Bu yönetmelik çerçevesinde, Türkiye'de KOBİ'ler mikro işletmeler, küçük işletmeler ve orta büyüklükte işletmeler olarak tanımlanır. Mikro işletmeler, 0-9 arası çalışanı olan ve yıllık net satış hasılatı veya mali bilanço toplamı 3.500.000 TL'yi aşmayan işletmeler. Küçük işletmeler, 10-49 arası çalışanı olan ve yıllık net satış hasılatı veya mali bilanço toplamı 50.000.000 TL'yi aşmayan işletmelerdir. Orta büyüklükteki işletmeler ise 50-249 arası çalışanı olan ve yıllık net satış hasılatı veya mali bilanço toplamı 125.000.000 TL'yi aşmayan işletmelerdir. Bu tanımlar, işletmelerin büyüklüklerine göre

* Sorumlu yazar: anilutku@munzur.edu.tr. Yazarların ORCID Numarası: ¹ 0000-0002-7240-8713, ² 0000-0002-3421-2357, ³ 0000-0002-6615-1237

sınıflandırılmasında temel kriterleri belirler. Bu sınıflandırma, Türkiye'de KOBİ'lere yönelik destek politikalarının belirlenmesi ve uygulanmasında önemli bir rol oynamaktadır.

Değişen ekonomik manzara ve işletmelerin başarılı olmak için ihtiyaç duyduğu artan hız, KOBİ'ler için verimli bir zemin sağlamaktadır. Küçük boyutun rekabet avantajı da vardır. Birimler ve yönetim arasında doğrudan iletişim söz konusu olduğu için KOBİ'ler acil durumlara daha etkin ve hızlı tepki vermektedir [4]. Değişken koşullara ayak uydurmak veya pazardaki mevcut fırsatlardan yararlanmak için iş modellerinin değişmesi gerektiğinde, KOBİ'ler yeni veya revize edilmiş bir iş modelini uygulamak için daha iyi konumlandırılma eğilimindedir [5].

KOBİ'ler, çok sayıda insanı istihdam ederek ve inovasyonu şekillendirmeye yardımcı olarak ekonomide önemli bir rol oynar [6]. KOBİ'ler, sayıca büyük firmalardan fazla oldukları için çok sayıda çalışana istihdam ederler ve genellikle doğaları gereği girişimcidirler [7]. KOBİ'ler temelde farklı şekilde faaliyet gösterdikleri için büyük ve çok uluslu şirketlerden ayrılmıştır [8]. Büyük ve karmaşık firmalar muhasebe, tedarik zinciri yönetimi, finansal raporlama ve dünya çapındaki ofisler arasında bağlantı için gelişmiş kurumsal kaynak planlama sistemlerine veya daha derin organizasyonel süreçlere ihtiyaç duyabilir [9]. Ancak KOBİ'ler, faaliyet kapsamlarının dar olması nedeniyle daha az sisteme ihtiyaç duymaktadır.

KOBİ'lerin ülke ekonomisi üzerindeki büyük ekonomik etkilerini gösteren çok sayıda veri bulunmaktadır. Amerika Birleşik Devletleri (ABD)'ne özgü olarak, KOBİ'ler çeşitli şekillerde katkıda bulunarak ülke ekonomisinin başarısında önemli bir rol oynamaktadır. KOBİ'ler, ABD'deki tüm firmaların %99'undan fazlasını oluşturmaktadır. KOBİ'ler tüm ABD gayri safi yurt içi hasılabın %43,5'ine katkıda bulunur [10]. Tüm ABD özel bordrosunun %39,7'sini KOBİ'ler ödemektedir. Ayrıca KOBİ'ler, büyük işletmelere kıyasla 1995'ten 2020'ye kadar ABD'de 4,8 milyon yeni iş imkânı yaratmıştır [11].

KOBİ'lerin büyük şirketlere göre belirgin avantajları vardır. KOBİ'ler genellikle daha güçlü bir topluluk duygusu kazandırır [12]. Yerel üreticilerin desteklenmesi konusundaki yönlendirmeler, ülke genelinde şubesi olmayan KOBİ'leri desteklemeye yöneliktir. KOBİ'lerin kendi topluluklarını finansal olarak destekleme olasılığı daha yüksektir. Gelir toplamak ve ülke çapında yeni bir mağazaya yatırım yapmak yerine, KOBİ'lerin yerel kalması, yerel işi sürdürmesi, yerel olarak vergi ödemelerine katkıda bulunması ve yakındaki tedarikçilerden satın alması daha olasıdır [13]. Ayrıca, KOBİ'lerin aile geleneğini taşıması ve aile mesleğini nesilden nesile aktarması daha olasıdır.

KOBİ'ler, büyük işletmelere göre doğrudan belirli bir odağa sahip olabilir. Sınırlı personele sahip olan KOBİ'ler, sundukları hizmetlerin de kapsamını sınırlamak zorundadır [14]. Geniş bir pazar hakimiyetine sahip olmaya çalışmak yerine, başarılı KOBİ'ler genellikle kendilerini daha küçük bir hedef pazara derinlemesine entegre ederler.

Birçok teknolojik süreç ve yenilik, esnekliği ve yeniliği desteklemeleri nedeniyle KOBİ'lere atfedilir [15]. KOBİ'ler başarılı olmak için yeni ürün veya hizmetler oluşturmaya odaklanır. Bu nedenle, pazarın değişen gereksinimlerine daha hızlı uyum sağlama yeteneğine sahiptirler [16]. KOBİ'ler ülke ekonomisinin şekillenmesinde hayati bir rol oynamaktadır. KOBİ'ler, sosyal ve ekonomik açıdan faydalı etkileri nedeniyle ekonomi açısından oldukça önemli olarak kabul edilmektedir [17].

KOBİ'ler ürün tasarımı, fiyatlar ve verimlilik için rekabeti teşvik eder. KOBİ'ler olmasaydı, büyük işletmeler hemen hemen tüm faaliyet alanlarında tekel olurlardı [18]. KOBİ'ler büyük şirketlere, daha iyi tedarik edebildikleri bazı faaliyet alanlarında yardımcı olur. Büyük işletmelerin yarattığı hammadde temini ve mamulün dağıtımını gibi faaliyetler KOBİ'ler tarafından daha verimli bir şekilde geliştirilmektedir [19].

Yapay zekâ, en basit haliyle, bilgisayar bilimi ile veri kümelerini birleştirerek problem çözmeye olanak sağlayan bir araştırma alanıdır [20]. Yapay zekâ, sıklıkla birlikte anılan makine öğrenmesi ve derin öğrenmenin alt alanlarını da kapsar. Bu disiplinler, girdi verilerine dayalı olarak tahminler veya sınıflandırmalar yapan uzman sistemler yaratmaya çalışan yapay zekâ algoritmalarından oluşur [21]. Yapay zekâ, iş uygulamalarını ve koşullarını kökten değiştirerek yeni bir üretim devrimini tetiklemektedir. Yapay zekâ, hayatımızda ve ekonomimizde giderek daha önemli bir rol oynamaktadır. Yapay zekâ, üretkenlik ve ekonomik büyümenin önemli bir faktörü olarak değerlendirilmektedir [22]. İş verimliliğini artırarak ve büyük miktarda veriyi analiz ederek karar verme sürecini büyük ölçüde iyileştirebilir. Aynı zamanda yeni ürün ve hizmetlerin, pazarların ve endüstrilerin yaratılmasını sağlayabilir. Böylece tüketici talebini artırabilir ve yeni gelir akışları yaratabilir.

Bu çalışmada, KOBİ'lerin ekonomiye sağladıkları katkının tahminine yönelik derin öğrenme tabanlı karşılaştırmalı bir analiz sunuldu. Bu çalışmanın literatüre olan katkıları aşağıdaki gibi özetlenebilir:

- Synthetic Minority Over-sampling TEchnique for Time Series (SMOTE-TS) kullanılarak KOBİ verileri üzerinde veri arttırma işlemi gerçekleştirilmiştir.
- Geliştirilen Long-Short Term Memory (LSTM) tabanlı model, Random Forest (RF), Support Vector Machine (SVM), Convolutional Neural Network (CNN), Multi-Layer Perceptron (MLP), Recurrent Neural Network (RNN) ve Gated Recurrent Unit (GRU) ile uygulamalı olarak karşılaştırılmıştır.
- Deneysel sonuçlar, geliştirilen LSTM tabanlı modelin, karşılaştırılan modellere göre daha başarılı olduğunu ve 0,959 R Squared (R^2) değeri ile KOBİ'lerin ekonomiye sağladıkları katkının tahmininde etkili bir tahmin performansına sahip olduğunu göstermiştir.

Çalışmanın geri kalanı şu şekilde organize edilmiştir: Bölüm 1.1'de KOBİ'lerin mali durumlarına yönelik yapılmış literatürdeki çalışmalar incelenmiştir. Bölüm 2'de veriseti, veri boyutunun arttırılması, kullanılan yöntemler, geliştirilen LSTM tabanlı tahmin modeli ve değerlendirme metrikleri sunulmuştur. Bölüm 3'te deneysel sonuçlar ve Bölüm 4'te çalışmanın sonuçları sunulmuştur.

1.1. Literatürdeki çalışmalar

Bu bölümde, KOBİ'lerin mali durumlarına yönelik yapılmış literatürdeki yapay zekâ tabanlı çalışmalar incelenmiştir. Zhu ve ark. [23], KOBİ'lerin kredi riskini tahmin etme doğruluğunu arttırmak için Random Subspace (RS) ve MultiBoosting yöntemlerinin hibrit bir yaklaşımını sunmuştur. Geliştirilen model temel sınıflandırıcı olarak Decision Trees (DT) kullanmaktadır. 31 Mart 2014 ile 31 Aralık 2015 tarihleri arasında Çin menkul kıymetler piyasasından elde edilen 46 KOBİ'ye ait veriler kullanılmıştır. Geliştirilen hibrit model, DT, RS ve MultiBoosting ile karşılaştırılmıştır. Deneysel sonuçlar, geliştirilen modelin klasik yöntemlere göre daha başarılı olduğunu göstermiştir. Malakauskas ve Lakstutiene [24], KOBİ'lerin mali sıkıntı tahminlerine yönelik Lojistik Regresyon (LR), Yapay Sinir Ağları (YSA) ve RF algoritmalarının karşılaştırmalı bir analizini sunmuştur. Çalışmada, 12.000 KOBİ'ye ilişkin bir veriseti kullanılmıştır. Kısa dönemlik tahminler elde etmek için klasik mali oranlar kullanılarak zaman, kredi geçmişi ve yaş gibi faktörler kullanılarak geliştirilmiştir. Deneysel sonuçlar, RF'nin 0,68 AUC değeri ile karşılaştırılan diğer algoritmalarından daha başarılı olduğunu göstermiştir. Schalck ve Yankol- Schalck [25], 2012-2018 tarih aralığındaki hem finansal hem de finansal olmayan değişkenleri içeren bir Fransız KOBİ veriseti kullanarak, işletmelerin başarısızlık tahminine yönelik makine öğrenmesi tabanlı karşılaştırmalı bir analiz sunmuştur. Probit, LR ve XGBoost algoritmaları kullanılarak yapılan deneysel çalışmalar, XGBoost'un karşılaştırılan diğer modellerden daha başarılı olduğunu göstermiştir. Hamal ve Şenvar [26], 2013-2017 yılları arasındaki 341 Türk KOBİ'sinin mali tablolarını değerlendiren mali muhasebe sahtekârlığını tespit etmeye yönelik makine öğrenmesi yöntemlerinin karşılaştırmalı bir analizini sunmuştur. Çalışmada, kredi veren bankalardan elde edilen 321 hileli ve 1384 hileli olmayan bir veriseti kullanılmıştır. Verisetindeki sınıf dengesizliği sorununu azaltmak için SMOTE-TS örnekleme tekniği kullanılmıştır. SVM, Naive Bayes (NB), YSA, k-Nearest Neighbour (kNN), RF, LR ve Bagging algoritmaları kullanılarak yapılan deneysel çalışmalar, RF'nin 0,9374 doğruluk değeri ile karşılaştırılan diğer algoritmalarından daha başarılı olduğunu göstermiştir. Dang ve ark. [27], tedarik zinciri finans piyasasının riskini değerlendirmek ve kontrol etmek için derin öğrenme ve blockchain teknolojisinin bir uygulamasını sunmuştur. Çalışmada tedarik zinciri finansmanının olası kredi riskini tartışmak için tedarik zinciri finansmanının finansman modeli analiz edilmiştir. Potansiyel kredi riskini tahmin etmek için derin öğrenme teknolojisine dayalı tedarik zinciri finansmanının kredi değerlendirme modeli oluşturulmuştur. Deneysel sonuçlar, tedarik zinciri finansmanının kredi değerlendirme modelinin, 0,989 R^2 değerine sahip olduğunu göstermiştir. Zhang ve ark. [28], KOBİ'lerin tedarik zinciri finansında karşılaştığı kredi riskini tahmin etmek için demografik ve davranışsal verilerin birleştirilmesi yaklaşımını ele almıştır. Çalışmada, KOBİ'lerin finansal risklerini önceden tahmin etmek amacıyla demografik veriler (örneğin, işletmenin büyüklüğü, sektörü) ile davranışsal verilerin birleştirilmesi amaçlanmıştır. Deneysel sonuçlar, demografik ve davranışsal verilerin birleştirilmiş haliyle elde edilen tahminlerin, yalnızca bir tür veriyi kullanarak yapılan tahminlere göre daha doğru ve güvenilir olduğunu göstermektedir. Wang ve ark. [29] makine öğrenmesi tabanlı bir örnekleme stratejisi kullanarak KOBİ'lerin kredi riskini tahmin etmeyi amaçlamıştır. Araştırmada, gelişmiş tekniklerden yararlanarak kredi riski değerlendirmesinin doğruluğunu arttırmak ve kredi verme uygulamalarında etkili karar almayı desteklemek hedeflenmiştir. Çalışmada, çeşitli makine öğrenmesi algoritmalarını ve yeni bir örnekleme stratejisini içeren kapsamlı bir deneysel yaklaşım sunulmuştur. Deneysel sonuçlar, önerilen stratejinin KOBİ'lerin kredi riski tahminini önemli ölçüde iyileştirdiğini ve makine öğrenmesini tedarik zinciri finansmanı senaryolarına entegre etmenin etkinliğini arttırdığını göstermiştir.

2. Materyal ve Metot

Bu çalışmada, KOBİ'lerin 2009-2020 yılları arasındaki girdi ve çıktı verileri, OCRA yöntemiyle analiz edilerek ölçeklendirilmiş girdi ve çıktı tercih indeksleri elde edilmiştir. Kullanılan verisetinin boyutunun küçük olması sebebiyle veri artırma yapılmıştır. Veri artırma, mevcut verilerden yapay olarak yeni veriler oluşturmak ve modelleri eğitmek için mevcut verilerin çeşitliliğini artırmak amacıyla kullanılan bir tekniktir. Bu, eğitim verilerinin alt kümesine alana özgü teknikler uygulanarak yapılır. Bir modelin performansı büyük ölçüde veri setinin kalitesine ve miktarına bağlı olduğundan, sentetik olarak üretilmiş verilerin kullanılması model performansını bir dereceye kadar iyileştirmeye yardımcı olabilir. Bu çalışmada, SMOTE-TS kullanılarak veri artırma işlemi gerçekleştirilmiştir.

2.1. Veriseti

Bu çalışmada, TÜİK tarafından sunulan KOBİ'lere ait 2009-2020 yılları arası KOBİ sayısı, çalışan sayısı, personel maliyeti, Ar-Ge personel sayısı, ithalat, ücretli çalışanlar, üretim değeri, Ar-Ge harcaması girdi olarak, çalışan başına katma değer, ciro, patent tescil sayısı, ihracat yapan firma sayısı, katma değer ve ihracat verileri çıktı olarak alınmış, OCRA yöntemiyle analiz edilerek yıllar itibarıyla KOBİ'lerin performansı çıkarılmıştır. Şekil 1'de başlangıç verileri görülmektedir.

Yıllar	GİRDİ							ÇIKTI		
	KOBİ Sayısı	Çalışan Sayısı	Personel Maliyeti	Ar-Ge Personel Sayısı	Ücretli Çalışanlar	Üretim Değeri	Ar-Ge Harcaması	Çalışan başına Katma Değer	Ciro	Katma Değer
2009	2 625 455	7 650 393	64 962 202 566	16 641	5 395 836	465 356 998 744	924 404 844	26 692	1 778 426 955 243	116 277 117 269
2010	2 672 039	8 166 318	75 991 830 081	19 835	5 876 773	540 723 435 199	1 025 526 508	27 932	2 112 659 543 883	131 034 641 414
2011	2 728 856	8 887 281	91 398 374 116	22 457	6 561 303	662 813 157 423	1 188 256 016	31 406	2 696 959 678 958	157 757 024 994
2012	2 790 414	9 611 341	112 737 324 611	24 694	7 235 170	739 849 779 020	1 498 544 285	32 185	3 085 709 571 460	179 777 982 622
2013	2 839 698	10 247 166	138 502 379 496	31 484	7 832 741	914 773 885 226	2 081 139 758	36 670	3 507 294 609 147	227 055 355 689
2014	2 879 135	10 656 150	160 189 351 828	32 016	8 214 645	1 037 155 491 103	2 432 629 035	39 199	4 050 287 669 093	257 645 563 569
2015	2 931 040	10 972 438	183 046 654 098	35 023	8 499 570	1 145 775 164 785	2 976 736 090	45 287	4 553 370 394 668	290 080 377 375
2016	2 970 195	10 958 884	225 227 731 584	35 676	8 465 953	1 269 622 945 039	3 601 159 760	52 380	4 993 452 936 812	337 130 117 688
2017	3 087 152	11 211 604	246 059 671 248	40 235	8 626 976	1 504 357 421 199	4 484 162 991	60 650	6 298 907 064 719	382 845 711 002
2018	3 153 299	11 839 063	313 098 086 847	55 518	9 224 286	2 159 669 898 071	7 402 358 628	75 492	7 824 109 454 569	540 842 352 981
2019	3 221 233	11 329 276	360 686 433 737	59 631	8 662 465	2 340 488 812 456	8 984 450 850	88 519	8 940 593 564 475	609 412 130 719
2020	3 295 995	11 488 623	358 772 345 422	67 108	8 763 184	2 577 707 022 698	11 471 510 034	103 517	10 574 801 801 024	682 237 645 726

Şekil 1. Başlangıç verileri

Şekil 2'de OCRA yöntemiyle analiz edilerek ölçeklendirilmiş girdi ve çıktı tercih indeksleri görülmektedir.

Yıllar	Ölçeklendirilmiş girdi tercih indeksi	Ölçeklendirilmiş çıktı tercih indeksi	Ölçeklendirilmemiş genel tercih indeksi	Ölçeklendirilmiş genel tercih indeksi	Ekonomiye katkısının yıllar itibarıyla sıralanması
2009	0,0687	0,0850	0,0501	0,0163	12
2010	0,0595	0,0972	0,0515	0,1567	10
2011	0,0466	0,0491	0,1189	0,0025	11
2012	0,0336	0,0349	0,1700	0,0013	7
2013	0,0222	0,0457	0,1156	0,0679	9
2014	0,0149	0,0698	0,1433	0,0847	8
2015	0,0092	0,1351	0,2050	0,1443	6
2016	0,0095	0,1613	0,2166	0,1707	5
2017	0,0050	0,2131	0,2393	0,2180	4
2018	0,0063	0,3401	0,3401	0,3339	3
2019	0,0029	0,3778	0,3778	0,3807	2
2020	0,0000	0,4524	0,4524	0,4524	1

Şekil 2. Ölçeklendirilmiş girdi ve çıktı tercih indeksleri

Kullanılan veriseti 12 yıl için ölçeklendirilmiş girdi ve çıktı tercih indeksleri, ölçeklendirilmemiş genel tercih indeksi, ölçeklendirilmiş genel tercih indeksi ve ekonomiye katkısının yıllar itibarıyla sıralanması öz niteliklerinden oluşmaktadır. Orijinal verisetindeki veri sayısının az olması sebebiyle SMOTE-TS kullanılarak tablo verileri üzerinde veri artırma yapılmıştır.

2.2. Veri boyutunun arttırılması

SMOTE, zaman serisi verilerindeki sınıf dengesizliğini ele almak için tasarlanmış bir örnekleme yöntemidir. SMOTE'un zaman serisi verilerine uyarlanmış bir versiyonudur ve özellikle zaman serisi sınıflandırma problemlerinde nadir sınıfları daha iyi temsil etmek için kullanılır. Zaman serisi verileri, her örnek zaman bileşeni içerdiği için geleneksel SMOTE'un işleyişini doğrudan uygulamak zor olabilir. SMOTE-TS, zaman serileri içindeki yapıyı ve ilişkileri dikkate alarak sentetik örnekler oluşturur.

SMOTE-TS yaklaşımında öncelikle her zaman serisi örneği için, en yakın komşuları zaman serisinin benzer bölgelerinde aranır. Bu, zaman serisi verisinin yapısını koruyarak benzer örneklerin seçilmesini sağlar. Seçilen örnekler arasında bir çekirdeklenme yapılır ve sentetik örnekler oluşturulur. Bu çekirdeklenme işlemi, zaman serisi özelinde gerçekleştirilir ve verinin içsel yapısını korur. Oluşturulan sentetik örnekler veri kümesine eklenir. Orijinal veriseti, 2009-2020 yılları arasındaki verilerden oluşmaktadır. SMOTE-TS kullanılarak toplam veriseti boyutu 20000'e çıkarılmıştır.

2.3. Kullanılan yöntemler

RF, belirli bir verisetinin çeşitli alt kümelerinde birçok karar ağacı işleten ve tahmin doğruluğunu artırmak için karar ağaçlarından elde edilen sonuçları oylama yöntemiyle değerlendiren bir denetimli öğrenme algoritmasıdır [30]. RF, tek bir karar ağacına güvenmek yerine, her bir karar ağacından sonuçları toplar ve tahminlerini çoğunluk oylarına dayalı olarak belirler. Karmaşık bir sorunu çözmek ve modelin performansını iyileştirmek için birden çok sınıflandırıcıyı birleştirme süreci olan topluluk öğrenme kavramına dayanır [31].

SVM, önceden tanımlanmış sınıflara, etiketlere veya çıktılara dayalı olarak veri noktaları arasındaki sınırları belirleyen optimum veri dönüşümleri gerçekleştirerek karmaşık sınıflandırma, regresyon ve aykırı değer algılama sorunlarını çözmek için kullanan bir makine öğrenmesi algoritmasıdır [32]. SVM algoritmasının amacı, veri noktalarını belirgin bir şekilde sınıflandıran N boyutlu bir uzayda bir hiper düzlem bulmaktır. Hiper-düzlemin boyutu, özelliklerin sayısına bağlıdır. En iyi hiper-düzlem, iki sınıf arasındaki en büyük ayrımı veya marjı ifade etmektedir [33].

CNN, girdi verilerinden özellikleri çıkarmak için evrişimli katmanlar kullanan ve yaygın olarak bilgisayarla görme problemlerinde uygulanan bir derin öğrenme modelidir [34]. CNN, giriş verilerinden özellikleri otomatik olarak çıkarmak için evrişim katmanlarını kullanır. Girdi verileri, evrişim katmanları tarafından filtreleme tabi tutulur ve üretilen özellik haritaları daha sonraki işlem katmanlarına aktarılır [35]. Evrişimli katmanlar, girdi verileri üzerinde filtreleme ve özellik çıkarma işlemini gerçekleştiren CNN'in yapı taşlarıdır. Filtreleme, özellikleri çıkarmak için bir görüntüyü bir filtre ile evrişim işlemidir. Özellik çıkarma ise, görüntülerden örüntüleri veya özellikleri belirleme işlemidir. Hesaplama maliyetini düşürmek ve ağıın yeni girdilere genelleştirme kapasitesini artırmak için havuzlama katmanları kullanılır.

MLP, hem doğrusal olarak ayrılabilen hem de doğrusal olarak ayrılamayan verileri işleyebilen bir sinir ağıdır [36]. Bir katmandaki nöronları, bir sonraki katmana herhangi bir döngü olmadan ileri bir şekilde bağlayan, ileri beslemeli bir sinir ağı modelidir. MLP, verileri üç veya daha fazla katman aracılığıyla işleyen birbirine bağlı nöronlardan oluşur. MLP'nin temel yapısında, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı ile bir aktivasyon fonksiyonu bulunmaktadır [37].

RNN, önceki adımın çıktısının mevcut adıma girdi olarak beslendiği bir sinir ağı türüdür. RNN'in en önemli özelliği, bir dizi hakkında bazı bilgileri hatırlayan gizli durumudur [38]. Durum aynı zamanda hafıza durumu olarak da adlandırılır. Çıktıyı üretmek için tüm girdilerde veya gizli katmanlarda aynı görevi yerine getirdiği için her girdi için aynı parametreleri kullanır. Bu durum, diğer sinir ağlarının aksine parametrelerin karmaşıklığını azaltır [39].


GRU, her zaman adımında ağıın gizli durumunu seçici olarak güncellemek için geçiş mekanizmalarını kullanan bir tekrarlı sinir ağı modelidir [40]. Geçiş mekanizmaları, ağa giren ve çıkan bilgi akışını kontrol etmek için kullanılır. GRU, sıfırlama kapısı ve güncelleme kapısı olarak adlandırılan iki kapı mekanizmasına sahiptir [41]. Sıfırlama kapısı, önceki gizli durumun ne kadarının unutulması gerektiğini belirlerken, güncelleme kapısı, gizli durumu güncellemek için yeni girişin ne kadarının kullanılmasını gerektiğini belirler. GRU'nun çıktısı, güncellenen gizli duruma göre hesaplanır.

LSTM, zaman serileri, ses ve metin gibi sıralı verileri işlemek için özel olarak tasarlanmış tekrarlı sinir ağı modelidir [42]. LSTM, sıralı verilerdeki uzun vadeli bağımlılıkları öğrenme yeteneğine sahiptir. Bu durum

LSTM'i dil çevirisi, konuşma tanıma ve zaman serisi tahmini gibi görevler için çok uygun hale getirir. Geleneksel bir RNN, ağır uzun vadeli bağımlılıkları öğrenmesini zorlaştırabilen, zaman içinde geçen tek bir gizli duruma sahiptir [43]. LSTM, bilgileri uzun süre tutabilen bir bellek hücresi sunarak bu sorunu çözer. Bellek hücresi giriş kapısı, unutma kapısı ve çıkış kapısı olmak üzere üç kapı tarafından kontrol edilir. Bu kapılar, bellek hücresine hangi bilgilerin ekleneceğine, çıkarılacağına ve buradan çıktı alınacağına karar verir. Giriş kapısı, bellek hücresine hangi bilgilerin eklendiğini kontrol eder. Unutma kapısı, bellek hücresinden hangi bilgilerin çıkarılacağını kontrol eder. Çıkış kapısı, bellek hücresinden hangi bilgilerin çıktığını kontrol eder. Bu durum, LSTM'in ağ üzerindeki bilgileri seçici olarak tutmasına veya atmasına izin vererek uzun vadeli bağımlılıkları öğrenmesine imkân sağlar [44].

2.4. Geliştirilen LSTM tabanlı tahmin modeli

Geliştirilen LSTM tabanlı tahmin modeli, girdi katmanı, iki LSTM katmanı, dense katmanı ve çıktı katmanından oluşmaktadır. Geliştirilen LSTM tabanlı tahmin modelinin mimarisi, Şekil 3'te görülmektedir.



Şekil 3. Geliştirilen LSTM modelinin mimarisi

Girdi katmanında, girdi ve çıktı tercih indekslerinden oluşan arttırılmış veriseti modele girdi olarak sunulmaktadır. Geliştirilen model çift katmanlı bir LSTM yapısına sahiptir. Grid search kullanılarak elde edilen LSTM'in hiper parametreleri, gizli katman sayısı 2, her bir katmandaki nöron sayısı 32, aktivasyon fonksiyonu tanh, dropout oranı 1.7e-3, epoch sayısı 124, batch size 64, optimizasyon fonksiyonu Adam ve öğrenme oranı 8e-3'tür.

2.5. Değerlendirme metrikleri

Uygulanan modellerin tahmin performanslarının değerlendirilmesi amacıyla Mean Squared Error (MSE), Root Mean Squared Error (RMSE), Mean Absolute Error (MAE) ve R^2 metrikleri kullanılmıştır. MSE gerçek değerler ve tahmin edilen değerler arasındaki ortalama kare farkını değerlendirir. Modelin hata oranı azaldıkça MSE sıfıra yakınsar. MSE Eş. 1 kullanılarak hesaplanır.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2 \quad (1)$$

Toplam örnek sayısı n , gerçek gözlem verileri y ve tahmin edilen değerler ise \hat{y} ile ifade edilmektedir. RMSE, MSE değerinin karekökü alınarak Eş. 2'de görüldüğü gibi hesaplanır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y - \hat{y})^2} \quad (2)$$

MAE, gerçek gözlem değerleri ile tahmin edilen değerler arasındaki farkların mutlak değerlerinin ortalamasını ifade eder. MAE, Eş. 3 kullanılarak hesaplanır.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y - \hat{y}| \quad (3)$$

R^2 , verisetinin regresyon modeline ne kadar iyi uyduğunun göstergesidir. Korelasyon katsayısının kare değeridir. R^2 , Eş. 4 kullanılarak hesaplanır.

$$R^2 = \frac{\sum (y - \hat{y})^2}{(y - \bar{y})^2} \quad (4)$$


Gerçek gözlem verileri y , tahmin edilen değerler \hat{y} ve y değerlerinin ortalaması ise \bar{y} ile ifade edilmektedir.

3. Deneysel Analizler

Bu çalışmada, KOBİ'lerin ekonomiye katkılarının tahmin edilmesi amacıyla LSTM tabanlı bir derin öğrenme modeli geliştirilmiştir. Geliştirilen model, RF, SVM, CNN, MLP, RNN ve GRU gibi popüler makine öğrenmesi ve derin öğrenme modelleriyle uygulamalı olarak karşılaştırılmıştır. Uygulanan her bir modelin hiper-parametrelerinin belirlenmesi amacıyla Grid Search kullanılmıştır. GridSearchCV, scikit-learn kütüphanesinin bir parçası olan bir hiper-parametre ayarlama tekniğidir. Makine öğrenimi algoritmalarının performansını artırmak için kullanılan hiper-parametreler, algoritmanın çalışma şeklini ve sonuçlarını etkiler. GridSearchCV bu hiper-parametrelerin en iyi kombinasyonunu bulmak için kullanılır. Grid Search, belirli bir hiperparametre kümesi üzerinde tüm olası kombinasyonları dener ve bu kombinasyonlardan hangisinin en iyi sonuçları verdiğini değerlendirir. Cross-validation kullanarak bu değerlendirmeyi yapar. GridSearchCV aynı zamanda k-fold cross-validation yaparak, veri kümesini k parçaya böler ve bu bölmeleri kullanarak modelin performansını değerlendirir. SMOTE-TS kullanılarak elde edilen artırılmış verisetinin %80'i eğitim, %20'si ise test için kullanılmıştır. Eğitim verilerinin %10'unu ise model parametrelerini optimize edebilmek amacıyla doğrulama için kullanılmıştır. Tablo 1 ve Şekil 4'te karşılaştırmalı deneysel sonuçlar görülmektedir.

Tablo 1. Deneysel sonuçlar

Model	MSE	RMSE	MAE	R^2
RF	2,635	1,623	1,338	0,843
SVM	2,417	1,555	1,261	0,890
CNN	2,255	1,502	1,210	0,931
MLP	2,265	1,505	1,214	0,927
RNN	2,257	1,502	1,207	0,932
GRU	2,180	1,476	1,199	0,937
LSTM	2,169	1,473	1,175	0,959



Şekil 4. Karşılaştırmalı deneysel sonuçlar

Deneysel sonuçlar, LSTM'in karşılaştırılan diğer modellerden tüm hata metriklerine göre daha başarılı olduğunu göstermiştir. SVM'in RF'dan daha başarılı deneysel sonuçlara sahip olması verisetindeki nümerik öznitelikler ile açıklanabilir. RF, kategorik ve nümerik özelliklerin bir arada olduğu durumlarda avantajlıdır. RF, girdi uzayını hiper dikdörtgenlere bölmenin sınıflandırma açısından mantıklı olduğu varsayımını yapar. SVM, verileri daha yüksek boyutlu bir alana yansıtır. Böylece bu alanda doğrusal olarak ayrılabilirler.

CNN'in MLP'den daha başarılı olması, CNN'in girdi olarak tensörü alması ve MLP'nin ise girdi olarak vektörleri alması ile açıklanabilir. CNN, tensörleri girdi olarak aldığı için özellik çıkarımını daha başarılı bir şekilde yapacaktır. RNN'in CNN'den daha başarılı olması ise RNN'in sonuçları ağa geri besleyen tekrarlı mimarisiyle yorumlanabilir. CNN sabit bir girdi ve çıktı boyutuna sahiptir. RNN'de ise girdinin ve çıktının boyutu değişebilir.

GRU'nun RNN'den daha başarılı olması, GRU'da RNN'den farklı olarak bulunan geçiş mekanizmaları ile yorumlanabilir. GRU, bu sayede uzun vadeli bağımlılıkların hatırlanmasını sağlamaktadır. LSTM'in karşılaştırılan diğer modellerden daha başarılı olması ise LSTM'in RNN ve GRU gibi diğer tekrarlı sinir ağı modellerinden farklı olarak özel birimlere sahip olması ile yorumlanabilir. LSTM, bilgileri uzun süre hafızada tutabilen özel bellek birimleri içermektedir. Giriş kapısı, unutma kapısı ve çıkış kapısı gibi bu özel birimler yardımıyla uzun vadeli bağımlılıkların hatırlanması kolaylaşmaktadır.

4. Sonuç

KOBİ'ler, belirli bir sayıdan daha az çalışanı istihdam eden, bağlı ortaklık olmayan, bağımsız firmalar olarak tanımlanmaktadır. KOBİ belirleme kriterleri ülkeler ve sektörler arasında farklılık gösterir. KOBİ'ler çoğu ülkede işletmelerin büyük çoğunluğunu oluşturmaktadır. Tüm ekonomilerde, KOBİ'ler istihdam yaratılmasına ve sürdürülebilir büyümeye önemli katkılarda bulunmaktadır ve ekonomik gelişimin teşvik edilmesinde kritik bir rol oynamaktadır. KOBİ'lere yönelik politika, başta yeni teknoloji sektörü olmak üzere yeni iş fırsatlarının yaratılması için artan bir önem kazanmaktadır. Yapay zekâ uygulamalarının çeşitliliği ve potansiyeli gün geçtikçe çeşitlenmektedir. Günümüzde giderek artan sayıda işletme, faaliyetlerini ve koşullarını iyileştirmek için yapay zekâ odaklı çözümlerden faydalanmaktadır.

Bu çalışmada, KOBİ'lerin ekonomiye sağladıkları katkının tahminine yönelik derin öğrenme tabanlı karşılaştırmalı bir analiz sunulmuştur. TÜİK tarafından sunulan KOBİ'lere ait 2009-2020 yılları arası KOBİ sayısı, çalışan sayısı, personel maliyeti, Ar-Ge personel sayısı, ithalat, ücretli çalışanlar, üretim değeri, Ar-Ge harcaması girdi olarak, çalışan başına katma değer, ciro, patent tescil sayısı, ihracat yapan firma sayısı, katma değer ve ihracat verileri çıktı olarak alınmıştır. Bu veriler, OCRA yöntemiyle analiz edilerek yıllar itibarıyla KOBİ'lerin performansı çıkarılmıştır. Geliştirilen LSTM tabanlı bir derin öğrenme modeli kullanılarak KOBİ'lerin ekonomiye olan katkı dereceleri tahmin edilmiştir. Geliştirilen model, RF, SVM, CNN, GRU, MLP ve RNN ile karşılaştırmalı olarak analiz edilmiştir. MSE, RMSE, MAE ve R^2 metrikleri kullanılarak yapılan deneysel çalışmalar, geliştirilen modelin 2,169 MSE, 1,473 RMSE, 1,175 MAE ve 0,959 R^2 değeri ile karşılaştırılan diğer modellerden daha başarılı bir tahmin performansına sahip olduğunu göstermiştir.

Kaynaklar

- [1] Pedraza JM. The micro, small, and medium-sized enterprises and its role in the economic development of a country. *Bus and Manag Res* 2021; 10(1): 33.
- [2] Naab R, Bans-Akutey A. Assessing the use of e-business strategies by SMEs in Ghana during the Covid-19 pandemic. *Ann. Manag and Org. Res* 2021; 2(3): 145-160.
- [3] Cegarra-Leiva D, Sánchez-Vidal ME, Gabriel Cegarra-Navarro J. Understanding the link between work life balance practices and organisational outcomes in SMEs: The mediating effect of a supportive culture. *Pers rev* 2012; 41(3): 359-379.
- [4] Ramírez de la Cruz EE, Grin EJ, Sanabria-Pulido P, Cravacuore D, Orellana A. The transaction costs of government responses to the COVID-19 emergency in Latin America. *Public Administration Review* 2020; 80(4): 683-695.
- [5] Becker W, Schmid O. The right digital strategy for your business: an empirical analysis of the design and implementation of digital strategies in SMEs and LSEs. *Bus Res* 2020; 13(3): 985-1005.
- [6] Järvenpää AM, Kunttu I, Mäntyneva M. Using foresight to shape future expectations in circular economy SMEs. *Tech Inn Man Rev* 2020; 10(7).
- [7] Zainudin MF, Adam S, Fuzi NM. The impact of customer buying behavior towards small and medium enterprises (SMEs) perception during pandemic (COVID-19) in Johor. *Adv Int J of Bus, Entrepreneurship and SMEs* 2021; 10.
- [8] Miklian J, Hoelscher K. SMEs and exogenous shocks: A conceptual literature review and forward research agenda. *Int Small Bus J* 2022; 40(2): 178-204.
- [9] Vu T, Nguyen D, Luong T, Nguyen T, Doan T. The impact of supply chain financing on SMEs performance in Global supply chain. *Unc Supp Ch Man* 2022; 10(1): 255-270.
- [10] Matt DT, Rauch E. SME 4.0: The role of small-and medium-sized enterprises in the digital transformation. *Ind 4.0 for SMEs: Chal, opp and req* 2020; 3-36.
- [11] Bakhtiari S, Breunig R, Magnani L, Zhang J. Financial constraints and small and medium enterprises: A review. *Ec Rec* 2020; 96(315): 506-523.
- [12] Weaven S, Quach S, Thaichon P, Frazer L, Billot K, Grace D. Surviving an economic downturn: Dynamic capabilities of SMEs. *J of Bus Res* 2021; 128: 109-123.
- [13] Jayathilaka UR, Park GC. The Impact of Amazon Global Selling on Innovation Performance of SMEs. *J of Artif Intell and Mach Lear in Man* 2022; 6(2): 1-13.
- [14] Rahman MS, Abdelfattah FA, Bag S, Gani MO. Survival strategies of SMEs amidst the COVID-19 pandemic: application of SEM and fsQCA. *J of Bus & Ind Mark* 2022; 37(10): 1990-2009.
- [15] Pu G, Qamruzzaman MD, Mehta AM, Naqvi FN, Karim S. Innovative finance, technological adaptation and SMEs sustainability: the mediating role of government support during COVID-19 pandemic. *Sust* 2021; 13(16): 9218.
- [16] Benzidia S, Makaoui N. Improving SMEs performance through supply chain flexibility and market agility: IT orchestration perspective. *Supp Ch Forum: An Int J* 2020; 21(3): 173-184.
- [17] Rodríguez-Espíndola O, Cuevas-Romo A, Chowdhury S, Díaz-Acevedo N, Albores P, Despoudi S, Dey P. The role of circular economy principles and sustainable-oriented innovation to enhance social, economic and environmental performance: Evidence from Mexican SMEs. *Int J of Prod Econ* 2020; 248.
- [18] Mierin LA, Korostyshevskaya EM, Ragimova NS. The Impact of Monopolies on Small Business Development in Russia. *Am J Econ Sociol* 2019; 78(5): 1201-1228.
- [19] D'Amato D, Veijonaho S, Toppinen A. Towards sustainability? Forest-based circular bioeconomy business models in Finnish SMEs. *For Policy Econ* 2020; 110: 101848.
- [20] Ezugwu AE, Ikotun AM, Oyelade OO, Abualigah L, Agushaka JO, Eke CI, Akinyelu AA. A comprehensive survey of clustering algorithms: State-of-the-art machine learning applications, taxonomy, challenges, and future research prospects. *Eng App of Artif Int* 2022; 110: 104743.

- [21] Confalonieri R, Coba L, Wagner B, Besold TR. A historical perspective of explainable Artificial Intelligence. *Wiley Interdiscip Rev Data Min Knowl Discov* 2021; 11(1): e1391.
- [22] Aly H. Digital transformation, development and productivity in developing countries: is artificial intelligence a curse or a blessing?. *Rev of Econ and Pol Sci* 2022; 7(4): 238-256.
- [23] Zhu Y, Zhou L, Xie C, Wang GJ, Nguyen TV. Forecasting SMEs' credit risk in supply chain finance with an enhanced hybrid ensemble machine learning approach. *Int J of Prod Econ* 2019; 211: 22-33.
- [24] Malakauskas A, Lakštutienė A. Financial distress prediction for small and medium enterprises using machine learning techniques. *Eng Econ* 2021; 32(1): 4-14.
- [25] Schalck C, Yankol-Schalck M. Predicting French SME failures: new evidence from machine learning techniques. *App Econ* 2021; 53(51): 5948-5963.
- [26] Hamal S, Senvar Ö. Comparing performances and effectiveness of machine learning classifiers in detecting financial accounting fraud for Turkish SMEs. *Int J Comput Intell Syst* 2021; 14(1): 769-782.
- [27] Dang C, Wang F, Yang Z, Zhang H, Qian Y. Evaluating and forecasting the risks of small to medium-sized enterprises in the supply chain finance market using blockchain technology and deep learning model. *Oper Manag Res* 2022; 15(3-4): 662-675.
- [28] Zhang W, Yan S, Li J, Tian X, Yoshida T. Credit risk prediction of SMEs in supply chain finance by fusing demographic and behavioral data. *Transp Res E: Logist Transp* 2022, 158, 102611.
- [29] Wang L, Jia F, Chen L, Xu Q. Forecasting SMEs' credit risk in supply chain finance with a sampling strategy based on machine learning techniques. *Ann Oper Res* 2022, 1-33.
- [30] Zhou X, Lu P, Zheng Z, Tolliver D, Keramati A. Accident prediction accuracy assessment for highway-rail grade crossings using random forest algorithm compared with decision tree. *Reliab Eng Syst Saf* 2020; 200: 106931.
- [31] Islam MR, Nahiduzzaman M. Complex features extraction with deep learning model for the detection of COVID19 from CT scan images using ensemble based machine learning approach. *Expert Syst Appl* 2022; 195: 116554.
- [32] Rizwan A, Iqbal N, Ahmad R, Kim DH. WR-SVM model based on the margin radius approach for solving the minimum enclosing ball problem in support vector machine classification. *App Sci* 2021; 11(10): 4657.
- [33] Sueno HT, Gerardo BD, Medina RP. Multi-class document classification using support vector machine (SVM) based on improved Naïve bayes vectorization technique. *Int J Adv Trends Comp Sci Eng* 2020; 9(3).
- [34] Sharma AK, Chaurasia S, Srivastava DK. Sentimental short sentences classification by using CNN deep learning model with fine-tuned Word2Vec. *Proc Com Sci* 2020; 167: 1139-1147.
- [35] Nguyen DT, Nguyen TN, Kim H, Lee HJ. A high-throughput and power-efficient FPGA implementation of YOLO CNN for object detection. *IEEE Trans Very Large Scale Integr Syst* 2019; 27(8): 1861-1873.
- [36] He T, Li Z, Gong Y, Yao Y, Nie X, Yin Y. Exploring linear feature disentanglement for neural networks. 2022 IEEE International Conference on Multimedia and Expo (ICME), 18-22 June 2022, Taipei, Tayvan, pp. 1-6.
- [37] Djerioui M, Brik Y, Ladjal M, Attallah B. Heart Disease prediction using MLP and LSTM models. 2020 International Conference on Electrical Engineering (ICEE), 25-27 September 2020, Istanbul, Türkiye, pp. 1-5.
- [38] Eskandari H, Imani M, Moghaddam MP. Convolutional and recurrent neural network based model for short-term load forecasting. *Electr Power Syst Res* 2021; 195: 107173.
- [39] Ismail AA, Gunady M, Pessoa L, Corrada Bravo H, Feizi S. Input-cell attention reduces vanishing saliency of recurrent neural networks. *Adv. Neural Inf. Process Syst* 2019; 32.
- [40] Wang Y, Zheng D, Jia R. Fault diagnosis method for MMC-HVDC based on Bi-GRU neural network. *Energies* 2022; 15(3): 994.
- [41] Qin Y, Chen D, Xiang S, Zhu C. Gated dual attention unit neural networks for remaining useful life prediction of rolling bearings. *IEEE Trans Ind Inform* 2020; 17(9): 6438-6447.
- [42] Ding D, Zhang M, Huang Y, Pan X, Feng F, Jiang E, Yang M. Towards backdoor attack on deep learning based time series classification. 2022 IEEE 38th International Conference on Data Engineering (ICDE), 9-12 May 2022, Kuala Lumpur, Malezya, pp. 1274-1287.
- [43] Bynagari NB. The difficulty of learning long-term dependencies with gradient flow in recurrent nets. *Eng Int* 2020; 8(2): 127-138.
- [44] Patil S, Mudaliar VM, Kamat P, Gite S. LSTM based Ensemble Network to enhance the learning of long-term dependencies in chatbot. *Int J Simul Multidiscip Des Optim* 2020; 11: 25.