



MALİYYƏ BAZARINDAKI SƏHM QİYMƏTLƏRİNİN PROQNOZLAŞDIRILMASINDA MAŞIN ÖYRƏNMƏ ALQORİTMLƏRİ

Gülınar Rövşən qızı Mirzəyeva¹ , **Nərmin Zahid qızı Allahyarova^{2*}** 
^{1,2} Azərbaycan Respublikasının Prezidenti yanında Dövlət İdarəçilik Akademiyası,
Bakı, Azərbaycan
*narmin.allakhyarova@gmail.com

Bu məqalədə maliyyə bazarlarında səhmlərin qiymət proqnozu üçün Maşın öyrənmə alqoritmləri və dərin öyrənmə texnikalarına əsaslanan yanaşmaların analizi araşdırılmışdır. Eksponensial və sadə ortalamalar kimi texniki analiz anlayışları araşdırılır. Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Convolutional Neural Network (CNN) və XGBoost kimi maşın öyrənməsi modellərinin daxil edilməsi üçün müxtəlif qlobal indekslər analiz edilir. Araşdırmalar göstərir ki, hər modelin fərqli xüsusiyyətləri var və ən effektiv yanaşmanı seçmək konkret məlumatlar və proqnoz məqsədlərindən asılıdır. XGBoost və GRU kimi mürəkkəb modellərin çətinliyi onların ümumi performansında əks olunur və bu modellər daha mürəkkəb vaxt sırası kimi müəyyən nümunələri ən dəqiq şəkildə proqnoz edə bilən effektiv vasitələr kimi təklif olunur.

Açar sözlər: maşın öyrənmə, LSTM, CNN, GRU, XGBoost.

GİRİŞ

Müasir maliyyə bazarları, qlobal iqtisadiyyatın sürətli inkişafı və texnoloji yeniliklər sayəsində əhəmiyyətli dəyişikliklərə məruz qalmışdır. İnvestisiya strategiyalarının dəyişməsi, bazarın mürəkkəbliyi və qeyri-müəyyənliyi ilə bağlı yeni yanaşmaların yaranmasına səbəb olmuşdur. Ənənəvi investisiya metodları artıq müasir bazar şərtlərinə uyğun gəlmir, çünki bazarların sürətli dəyişməsi və çoxsaylı amillərin eyni anda təsir göstərməsi investorlara daha yüksək risk və qeyri-müəyyənlik yaradır. Bu yeni şəraitdə investisiya dünyasında texnologiyanın rolu artmış və yeni alətlər bazarların daha düzgün təhlil edilməsini mümkün etmişdir.

Maşın öyrənmə texnologiyaları səhm birjasında verilənlərin təhlili və investisiya qərarlarının optimallaşdırılması üçün geniş tətbiq olunur. Bu texnologiyalar, bazar tendensiyalarını daha dəqiq proqnozlaşdıraraq investorlar üçün yeni imkanlar yaradır. Lakin ML (machine learning) alqoritmlərinin istifadəsi məlumat manipulyasiyası, bazar inhisarlaşması və etik problemlər kimi risklərlə də müşayiət oluna bilər. Bu səbəbdən, maşın öyrənmənin maliyyə bazarlarında effektiv tətbiqi üçün tənzimləyici mexanizmlər və etik standartlar vacibdir. Məqalə, ML-in səhm birjasındakı rolunu, mövcud təsirlərini və gələcək perspektivlərini qiymətləndirərək, bu texnologiyaların həm imkanlarını, həm də risklərini vurğulayır.

Bu kontekstdə, maşın öyrənmə və süni intellekt texnologiyaları maliyyə sektorunda inqilabi təsirə malikdir. Bu texnologiyalar, böyük verilənlərin təhlili və mürəkkəb nümunələrin aşkar edilməsi sahəsində güclü vasitələr təqdim edir. Xüsusilə, səhm qiymətlərinin proqnozlaşdırılması sahəsində maşın öyrənmə alqoritmləri investorlar üçün daha dəqiq və effektiv qərar verməyə imkan verir. Keçmiş məlumatların və müxtəlif iqtisadi göstəricilərin analizinə əsaslanaraq, bu alqoritmlər bazar trend və dəyişikliklərini qabaqcadan müəyyən etməyə kömək edir ki, bu da öz növbəsində maliyyə bazarlarında daha düzgün proqnozlar verməyə və daha mütərəqqi investisiya strategiyalarını inkişaf etdirməyə imkan yaradır. Nəticədə investorların riskləri azalır və gəlirlilik dərəcəsində artım müşahidə olunur. Amma, bu texnologiyaların istifadəsi də özündə məlumat manipulyasiyası, inhisarlaşma kimi risklər də gətirir. Bu risklər isə sağlam bazarın strukturunu pozur.




Məqalənin məqsədi maşın öyrənmə texnologiyalarının səhm birjasında rolunu, tətbiq sahələrini və təsirini araşdırmaqdır. Məqalədə ML-in bazar analizi və proqnozlaşdırmada yaratdığı imkanlar və üstünlüklər vurğulanır. Bununla yanaşı, məlumat manipulyasiyası və bazar inhisarlaşması kimi potensial risklər də təhlil olunur. Tədqiqat, maliyyə bazarlarında ML-in istifadəsinin həm müsbət, həm də mənfi tərəflərinə diqqət çəkərək, bu sahədə ehtiyac duyulan tənzimləmə və etik standartların əhəmiyyətini göstərir. Məqalə gələcəkdə ML-in səhm birjasında davamlı və şəffaf tətbiqi üçün əsasları göstərməyi hədəfləyir.

1. MAŞIN ÖYRƏNMƏ ALQORİTMLƏRİNİN SƏHM QIYMƏTİ PROQNOZLAŞDIRILMASINDA TƏTBİQİ

Maşın öyrənmə alqoritmləri, maliyyə bazarlarının kompleksliyini təhlil etmək və qiymət proqnozlarını düzgün şəkildə təxmin etmək üçün güclü vasitələrdir. Bu alqoritmlər, bazarların qeyri-səlis və mürəkkəb təbiətini daha yaxşı başa düşmək və müxtəlif amillərin interaktiv təsirlərini qiymətləndirmək üçün istifadə edilir. Neyron şəbəkələri, qərar ağacları və dəstək vektor maşınları kimi alqoritmlər, xüsusilə səhm qiymətlərinin proqnozlaşdırılması sahəsində geniş tətbiq olunur. Hər bir alqoritm özünəməxsus xüsusiyyətləri ilə bazarda fərqli yanaşmalar təqdim edir.

Dəstək vektor maşınları (SVM) xüsusilə qeyri-xətti proqnozlaşdırmalar üçün effektivdir. SVM böyük verilənlər bazasında sərhəd xətləri və bölgələr yaradaraq, bazarın müxtəlif vəziyyətlərini ayırmağa çalışır. Bu metod maliyyə bazarlarında səhm qiymətlərinin dəyişikliklərinin proqnozlaşdırılması üçün tətbiq edilir, çünki SVM verilənlərin çox ölçülü təhlilini təmin edir. SVM-lər, xüsusən qeyri-xətti əlaqələri yaxşı tutaraq daha dəqiq nəticələr əldə etməyə imkan verir və bu xüsusiyyətləri ilə bazar proqnozlarında üstünlük təşkil edir [1].



Neyron şəbəkələri maşın öyrənmənin ən geniş istifadə olunan yanaşmalarından biridir. Bu alqoritmlər insan beyninin strukturuna bənzər şəkildə məlumatları müxtəlif qatlar üzrə ötürərək təhlil edirlər. Neyron şəbəkələri səhm qiymətlərinin proqnozlaşdırılmasında, xüsusilə zaman seriyalarında məlumatları analiz etmək üçün istifadə edilir. Alqoritm keçmiş qiymət məlumatlarını və bazar şəraitini nəzərə alaraq gələcək qiymət dəyişikliklərini proqnozlaşdırır. Bu yanaşma, bazarın dəyişkənliyini və qeyri-müəyyənliyini nəzərə alaraq daha dəqiq nəticələr verir [2].

Qərar ağacları isə başqa bir məşhur maşın öyrənmə metodudur və çoxsaylı alqoritmik təhlil və qərar vermə proseslərini asanlaşdırır. Bu metod müəyyən bir problemin müxtəlif ehtimallarını və onların təsirlərini təhlil edərək ən uyğun qərarı tapmağa kömək edir. Bu metodun məqsədi səhm qiymətləri üzərində tətbiqi, qiymət dəyişikliklərinə təsir edən müxtəlif amillərin müəyyənləşdirilməsi və bu amillərə əsaslanaraq bazar trendini qiymətləndirməkdir. Qərar ağacları, həmçinin investisiya portfellerinin diversifikasiyasını optimallaşdırmaqda istifadə olunur. Bu alqoritm verilənlərin bölünməsi ilə daha çox düzgün proqnozlar əldə etməyə imkan verir [1].

Hər bir alqoritm, özünün tətbiq sahəsində fərqli üstünlüklər təqdim edir və bazarın müxtəlif aspektlərini daha yaxşı başa düşmək üçün bunlar birgə istifadə oluna bilər. Nəticədə, maşın öyrənmə metodları maliyyə bazarlarında daha düzgün proqnozlar vermək üçün güclü vasitələrə çevrilmişdir və investorların qərar qəbul etmə prosesini daha da effektivləşdirir. Bu yanaşmalar, həmçinin risklərin idarə edilməsi və investisiya strategiyalarının optimallaşdırılması sahəsində böyük bir inqilab yaratmışdır.

2. SƏHM BİRJASINDA MAŞIN ÖYRƏNMƏ MODELƏRİNİN QIYMƏTLƏNDİRİLMƏSİ METODLARI: METRİKLƏR

Maşın öyrənmə alqoritmlərinin proqnozlaşdırma performansını qiymətləndirmək düzgün qərar vermək üçün əvəzsiz rol oynayır. Bu məqsədlə müxtəlif metriklərdən istifadə olunur. Bu metriklər alqoritmlərin düzgünlük səviyyəsini ölçərək, modellərin maliyyə bazarlarında tətbiqinin nə dərəcədə effektiv olduğunu müəyyən etməyə kömək edir. Həssaslıq, etibarlılıq və proqnozlaşdırma dəqiqliyi kimi əsas metriklər, alqoritmlərin gücünü və zəifliklərini başa düşmək və optimallaşdırmaq üçün vacibdir. Bu metriklərdən hər biri fərqli aspektləri təhlil edərək alqoritmlərin ümumi performansını qiymətləndirmək üçün əhəmiyyətlidir.

Həssaslıq (Sensitivity) bir modelin doğru müsbət nəticələri tapmaq qabiliyyətini ölçür. Maliyyə bazarlarında, məsələn, qiymət artımlarını doğru şəkildə proqnozlaşdırmaq mühüm əhəmiyyət kəsb edir. Bu metrik modelin nə qədər düzgün şəkildə proqnozlaşdırdığını və müsbət dəyişiklikləri necə aşkarladığını göstərir. Həssaslıq xüsusi hallarda səhv müsbət (false positive) nəticələri azaltmaq və yalnız real müsbət nəticələri aşkarlamaq üçün əhəmiyyətlidir. Həssaslığın yüksək olması, modelin bazardakı qiymət dəyişikliklərinə daha doğru cavab verdiyini və potensial olaraq düzgün investisiya qərarları almağa kömək etdiyini göstərir [2].

Etibarlılıq (Specificity) isə, modelin yanlış mənfi nəticələri (false negatives) azaltmağa və yalnız doğru mənfi nəticələri aşkarlamağa nə qədər müvəffəq olduğunu ölçür. Yəni, modelin qiymətlərin düşməsinə düzgün müəyyənləşdirmə qabiliyyətini göstərir. Etibarlılığın yüksək olması bazar dəyişikliklərinin təhlilində modelin nə qədər etibarlı və düzgün qərarlar verdiyini göstərir. Bu metrik risklərin qiymətləndirilməsi və səhv proqnozların minimallaşdırılması baxımından vacibdir. Məsələn, maliyyə bazarlarında qiymətlərin azalmasını gözləyərkən səhvən qiymət artımını proqnozlaşdıran modellər investorları yanlış istiqamətə yönləndirə bilər [3].

Proqnozlaşdırma Dəqiqliyi (Accuracy) modelin ümumilikdə doğru nəticələr vermə nisbətini ölçür və çox istifadə olunan bir metrikdir. Bu, sadəcə olaraq doğru proqnozların ümumi sayının bütün proqnozlarla nisbətini göstərir. Lakin bu metrik, xüsusilə balanssız verilənlərdə - məsələn, bazar dəyişikliklərinin nadir olduğu hallarda - yanıldıcı ola bilər. Dəqiqlik yalnız ümumi performans göstərsə də, həssaslıq və etibarlılıq kimi daha spesifik metriklər, proqnozların düzgünlüyünü daha dəqiq qiymətləndirə bilər. Maliyyə bazarlarında bu, modelin ümumi uğurunun göstəricisi olsa da, onun yalnız bəzi məsələlərdə və ya xüsusi şəraitdə nə qədər uğurlu olduğunu göstərir [3].

Bundan əlavə, proqnozlaşdırma modelinin performansını qiymətləndirmək üçün **F1 ölçüsü** də mühüm əhəmiyyət kəsb edir. Bu ölçü həssaslıq və etibarlılığın harmonik ortalamasını təklif edir və hər iki metrik arasında balans təmin edir. F1 ölçüsü, xüsusən məlumatın qeyri-bərabər olduğu və hər iki növ səhvin (doğru və yanlış) vacib olduğu hallarda daha faydalıdır. Maliyyə bazarlarında qeyri-bərabər paylanmalarla qarşılaşarkən F1 ölçüsü düzgün proqnozlar əldə etməyə kömək edən balanslı yanaşma təmin edir [4].



Mərkəzləşdirilmiş kvadrat səhv (MSE) və kök mərkəzləşdirilmiş kvadrat səhv (RMSE) də maliyyə bazarlarında modellərin performansını qiymətləndirmək üçün geniş istifadə olunur. Bu metriklər proqnoz və həqiqi qiymətlər arasındakı fərqi ölçərək modelin nə qədər dəqiq olduğunu göstərir. MSE daha çox modelin ümumi səhvini ölçərkən, RMSE isə həmin səhvi ölçmək üçün daha intuitiv və vizual baxımdan aydın bir yanaşma təklif edir. Bu metriklər, proqnozlaşdırma dəqiqliyi və modelin təkmilləşdirilməsi baxımından əhəmiyyətlidir, çünki onlar modelin səhvini daha konkret şəkildə ölçərək optimallaşdırılmasına kömək edir [3].

Məqalə boyunca müzakirə edilən müxtəlif metriklər modelin performansını daha düzgün və ətraflı qiymətləndirməyə imkan verir. Hər bir metrikin özünəməxsus üstünlükləri və istifadə sahələri var, bu da onların müxtəlif növ problemlərdə tətbiqini asanlaşdırır. Metriklər modelin doğruluğunu, səhvlərini və ümumi effektivliyini qiymətləndirərək, düzgün model seçiminə və optimallaşdırma proseslərinə istiqamət verir. Bu cür metriklər, həmçinin modellərin müqayisəsi və inkişafı üçün əvəzolunmaz vasitələrdir.

Yahoo Finance-dan toplanmış Apple Inc.-ə aid tarixi məlumatlardan ibarət məlumat bazası üzərində ML alqoritmlərini daha ətraflı və tətbiq edərək öyrənək.

3. MATERIAL VƏ METODLAR

Burada istifadə olunan materiallar və metodlar müzakirə edilir. Əvvəlcə istifadə olunan məlumat dəstinin təsviri təqdim olunur, daha sonra bütün integrasiya olunmuş xüsusiyyətlərin təqdimatı və təsviri verilir. Nəhayət, proqnozlar vermək üçün istifadə olunan metodlar, alqoritmlər və inkişaf etdirilmiş modellər təqdimat vasitəsilə izah edilir.

3.1. Məlumat bazası

İlkin məlumat bazası, Yahoo Finance [18]-dən toplanmış Apple Inc.-ə aid tarixi məlumatlardan ibarətdir. Bu məlumat dəsti 40 ildən çox bir müddəti əhatə edən səhmlərin qiymətlərini ehtiva edir və 7 sütundan ibarətdir. Buraya Açılış (Open), Ən Yüksək (High), Ən Aşağı (Low), Bağlanış (Close) və Düzəldilmiş Bağlanış (Adjusted Close) qiymətləri, həmçinin tarix və əməliyyat həcmi daxildir. Bu məlumatlar Cədvəl 1-də göstərilmişdir.

Cədvəl 1.

Əməliyyatların tarixi və həcmiTarix	Açılış	Ən yüksək	Ən aşağı	Bağlanış	Düzəldilmiş bağlanış	Əməliyyat həcmi
1980-12-12	0.128348	0.128906	0.128348	0.128348	0.098943	469033600
1980-12-15	0.122210	0.122210	0.121652	0.121652	0.093781	175884800
1980-12-16	0.113281	0.113281	0.112723	0.112723	0.086898	105728000
1980-12-17	0.115513	0.116071	0.115513	0.115513	0.089049	86441600
1980-12-18	0.118862	0.119420	0.118862	0.118862	0.091630	73449600

3.2. Xüsusiyyətlər

İlkin məlumat dəstinə əlavə olaraq 43 başqa xüsusiyyət də əlavə olunmuş və hədəf dəyişəni ilə əlaqələrinə əsaslanaraq həm korrelyasiya metodu, həm də SelectKBest istifadə edilərək test edilmişdir. Hədəf dəyişəni, Adj Close qiymətinin dəyəri olaraq təyin edilmişdir [6, 7]. İlk 27 xüsusiyyət birbaşa Apple Inc. səhmləri ilə əlaqəlidir, bunlara qiymət məlumatları, əməliyyat həcmi və hərəkətli orta və moment kimi texniki göstəricilər daxildir. Digər xüsusiyyətlər isə faiz dərəcələri və indekslərin birləşməsidir. Bu xüsusiyyətlər ya hesablanmış, ya da bir neçə mənbədən toplanmışdır, bunla-



ra Yahoo Finance, Federal Ehtiyatlar İqtisadi Məlumatı (FRED), St. Louis Federal Ehtiyat Bankı tərəfindən idarə olunan onlayn məlumat bazası aiddir [8].

Korrelyasiya təhlilinə başlamaqla nəticələr Cədvəl 2-də göstərilmişdir.

Cədvəl 2.

Korrelyasiya təhlilinin nəticələri

Nº	Xüsusiyyət	Korrelyasiya	Nº	Xüsusiyyət	Korrelyasiya
1	Adj Close	0.999757	26	DCOILWTICO	0.163709
2	Low	0.999527	27	TE6	0.141010
3	High	0.999503	28	MOM5	0.089892
4	Open	0.999472	29	MOM4	0.080078
5	SMA5	0.999335	30	MOM3	0.067485
6	EMA10	0.999167	31	MOM2	0.052424
7	EMA12	0.999064	32	RSI	0.070301
8	EMA20	0.998661	33	ROC5	-0.014739
9	EMA26	0.998045	34	ROC10	-0.017059
10	SMA25	0.997924	35	ROC15	-0.012191
11	EMA50	0.997375	36	ROC20	-0.023569
12	SMA50	0.996326	37	DGS5	-0.116094
13	EMA100	0.995705	38	DE1	-0.325379
14	SMA100	0.994129	39	DE2	-0.307576
15	EMA200	0.992396	40	DGS10	-0.291304
16	SMA200	0.990344	41	Volume	-0.472102
17	IXIC	0.963842	42	DBAA	-0.509228
18	GSPC	0.963491	43	DAAA	-0.502064
19	DJI	0.931631	44	DE6	-0.524144
20	NYA	0.878639	45	TE1	-0.530573
21	MACD	0.266051	46	DE5	-0.538855
22	TE5	0.228270	47	DE4	-0.543380
23	DTB3	0.185540	48	TE2	-0.556787
24	DTB6	0.184989	49	TE3	-0.563363
25	DTB4WK	0.166905			

Korrelyasiya təhlilinə əlavə olaraq, ən yaxşı xüsusiyyətləri seçmək üçün SelectKBest metodu tətbiq olunmuşdur. Bu metod, ən çox istifadə olunan xüsusiyyət seçmə texnikalarından biridir və maşın öyrənmə filtrlərinə əsaslanır. O, çıxış dəyişəni ilə ən güclü əlaqəyə malik xüsusiyyətləri müəyyən etmək üçün statistik testlərdən istifadə edir və prosedur ilkin olaraq, verilənlər və mövcud problemə əsasən uyğun statistik testin təyin olunmasını əhatə edir. Regressiya hallarında, SelectKBest metodu $f_{\text{regression}}$ seçimini təklif edir ki, bu da ən yaxşı xüsusiyyətləri seçmək üçün burada istifadə olunmuşdur [9].

Bundan əlavə, ən yaxşı 20 xüsusiyyətin digər xüsusiyyətlərlə müqayisədə çox daha yüksək nəticələr əldə etdiyi müşahidə olunur. (xüsusilə korrelyasiya təhlilində) Burada 20-ci ən yaxşı xüsusiyyət (NYA) 0.876839-a, 21-ci (MACD) isə 0.266051-ə uyğundur. Bu, xüsusiyyətlərin proqnozlaşdırma modeli üçün əhəmiyyətli bir fərqi göstərir.

3.3. Performans Ölçüləri

Maşın öyrənmə modelləri və məlumatların hazırlanmasına keçməzdən əvvəl, bu modelləri qiymətləndirmək üçün bir neçə performans ölçüsünün seçilməsi vacibdir. Bu ölçülər bu alqoritmlərin qiymətləndirilməsində əsas rol oynayır və proqnozların faktiki dəyərlərlə müqayisədə keyfiyyətini obyektiv şəkildə ölçmə imkanı təmin edir. Müxtəlif modellərin performansını qiymətləndirmək üçün regressiya tapşırığına uyğun ixtisaslaşmış ölçülərdən istifadə etmək qərara alınmışdır, çünki proqnoz səhvlərinin həm böyüklüyünü, həm də istiqamətini ölçən ölçüləri seçmək vacibdir. Köhnə ölçülərdən olan Kök Orta Kvadrat Xətası (RMSE) və Orta Mütləq Xəta (MAE) tez-tez istifadə olunur, çünki bunlar asanlıqla başa düşülür və proqnoz dəqiqliyini ölçmək üçün aydın bir üsul təqdim edir. Buna görə də, müxtəlif modelləri qiymətləndirmək üçün beş müxtəlif ölçü istifadə etmək qərara alınmışdır. Bunlar, Orta Mütləq Xəta (MAE), Orta Kvadrat Xəta (MSE), Kök Orta Kvadrat Xəta (RMSE), Orta Mütləq Faiz Xətası (MAPE) və Müəyyənlik Əmsalı (R^2) ölçüləridir.

MAE proqnozlar və faktiki dəyərlər arasındakı mütləq fərqlərin ortalamasını ölçən sadə bir göstəricidir. Bu ölçü, proqnoz səhvlərinin ortalama böyüklüyünü istiqamətindən asılı olmayaraq birbaşa



göstərir. Sadə dillə desək, MAE proqnozlar və faktiki dəyərlər arasındakı mütləq fərqlərin ortalaması olaraq hesablanır, burada daha kiçik mütləq fərq, daha yaxşı proqnoz keyfiyyətini göstərir [10]:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad (1)$$

Burada x_i faktiki dəyərləri, y_i proqnozlaşdırılan dəyərləri, n isə müşahidələrin ümumi sayıdır. MSE digər bir ümumi ölçüdür və reqressiya modellərinin performansını qiymətləndirmək üçün proqnozlaşdırılmış və faktiki dəyərlər arasındakı kvadrat fərqlərin ortalamasını ölçür. Bu ölçü, səhvləri kvadratladığı üçün daha böyük səhvlərə kiçik səhvlərdən daha çox əhəmiyyət verir. [11]:

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

RMSE proqnoz səhvlərinin ortalamə böyüklüyünü təqdim edərək, proqnozların dəqiqliyini ölçmək üçün çox faydalıdır. Bu ölçü daha böyük səhvləri xüsusi vurğulayır, çünki səhvlər kvadratlaşdırılır, amma nəticə faktiki dəyərlər ilə eyni ölçü vahidində olduğu üçün daha aydın başa düşülə bilər [12]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2} \quad (3)$$

Digər mühüm ölçü MAPE-dir (Orta Mütləq Faiz Xətası), bu proqnozların faktiki dəyərlərlə müqayisədə orta faiz səhvini anlamaq üçün faydalı bir ölçüdür. MAPE proqnozlar və faktiki dəyərlər arasındakı mütləq faiz fərqlərinin ortalamasını hesablayır. MAPE xüsusilə proqnozların faktiki dəyərlərlə müqayisədə nisbi dəqiqliyini anlamaq lazım olduqda, verilənlərin miqyasından asılı olmayaraq faydalıdır. Məsələn, səhmlərin qiymətlərini proqnozlaşdırmaq kontekstində, bu metriklərin mütləq dəyərlərini müxtəlif səhmlər arasında və ya eyni səhmin qiymət dəstinin fərqli alt qrupları arasında müqayisə etmək heç bir fayda vermir. Belə hallarda faiz dəyərini hesablayan bir ölçü, məsələn, MAPE çox faydalıdır:

$$MAPE = 100 \frac{1}{n} \sum_{i=1}^n \left| \frac{x_i - y_i}{x_i} \right| \quad (4)$$

Nəhayət, R^2 (Müəyyənlik Əmsalı) də istifadə edilmişdir. Bu, verilənlərdəki dəyişkənliyin model tərəfindən izah olunan nisbətini göstərən mühüm statistik ölçüdür. 1-ə daha yaxın dəyərlər, modelin verilənlərə yaxşı uyğunlaşdığını göstərir, mənfi dəyərlər və 0-a yaxın dəyərlər isə modelin pis uyğunlaşdığını göstərir. R^2 modelin izahedici gücünü başa düşmək üçün faydalı bir ölçüdür və əvvəlki MAPE ölçüsü kimi müxtəlif modellər arasında sürətli müqayisələr üçün xüsusilə faydalıdır [13]:

$$R^2 = 1 - \frac{\sum_{i=1}^n (x_i - y_i)^2}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (5)$$

3.4. Texniki Göstəricilərin Hesablanması

Xam səhmlərin qiymətlərinə əlavə olaraq, xüsusiyyətlər dəstini zənginləşdirmək üçün texniki göstəricilər hesablanmışdır. Bu göstəricilər, əvvəlki bölmələrdə müzakirə olunduğu kimi, maliyyə analizində səhmlərin qiymətindəki trendləri və momentumu tutmaq üçün geniş istifadə olunan bir neçə SMA (Sadə Hərəkətli Orta) və EMA (Ekspensial Hərəkətli Orta) daxildir. Bir neçə SMA və EMA dəyərləri, proqnozdan əvvəlki günə qədər olan tarixə əsaslanaraq müxtəlif pəncərə uzunluqları ilə hesablanmışdır. Bu yanaşma, modelə səhmlərin qiymət dəyişikliklərinə dair müxtəlif perspektivlər təqdim etmək məqsədini güdür. Konkret olaraq, SMA-lar 5, 25, 50, 100 və 200 günlük dövrlər üzrə hesablanmışdır, EMAlar isə 10, 12, 20, 26, 50, 100 və 200 günlük dövrlər üçün hesablanmışdır. Bu göstəricilər həm qısa müddətli, həm də uzun müddətli qiymət trendlərini tutmağa kömək etdi.

3.5 Normalizasiya və Məlumatların Hazırlanması

Texniki göstəricilər və maliyyə indeksləri integrasiya edildikdən sonrakı addım hədəf dəyişəni əlavə etməkdir. Bu, modelin proqnozlaşdıracağı dəyişəndir və əvvəlki bölmələrdə qeyd edildiyi kimi, bu hədəf növbəti günün Adj Close dəyəri olacaqdır. Bunun üçün yalnız Adj Close dəyərinin ötürülmüş qiymətinə bərabər yeni bir sütun yaratmaq lazım idi. Bu addımın sonunda cəmi 21 sütundan ibarət olan bir məlumat dəsti əldə olundu. İlk 20 sütun seçilmiş 20 xüsusiyyəti təmsil edir, 21-ci sütun isə hədəf dəyişənini göstərir.

Məlumat dəsti daha sonra çox məşhur **sklearn.preprocessing** kitabxanasının **MinMaxScaler** funksiyası istifadə edilərək normalizə edildi [7], Bu, verilənləri 0-dan 1-ə qədər olan əvvəlcədən müəyyən edilmiş aralığa miqyaslandırdı. Bu addım, maşın öyrənmə modellərinin performansını və effektivliyini artırmaq üçün çox vacibdir, çünki bütün xüsusiyyətlərin model qurma prosesinə bərabər şəkildə töhfə verməsini təmin etməyə kömək edir və daha yüksək dəyərləri olan bəzi dəyişənlərin aşağı dəyərlərə sahib olan digər dəyişənləri üstələməsinin qarşısını alır. Bu mərhələdə məlumatlar maşın öyrənmə modellərinə daxil edilməsi üçün hazırlanmışdır. Növbəti addım məlumatları sabit ölçülü zaman ardıcılıqlarına təşkil etməkdir, Burada hər bir ardıcılıq bütün xüsusiyyətləri əhatə edir. Bunun üçün əvvəlcə "input window" adlanan bir anlayışdan istifadə etmək lazımdır. Bu da ardıcıl müşahidə dəstlərini daxil etməyi nəzərdə tutur. Zaman pəncərəsi üçün bir dəyər təyin etmək üçün iki sadə model ilə testlər keçirildi: biri iki GRU qatından, digəri isə iki LSTM qatından ibarət idi. Nəticədə ən yaxşı dəyərin 100 olduğu qənaətinə gəldi. Testlər hər bir modeli öyrətmək və qiymətlərin dəyərini 10 dəfə proqnozlaşdırmaqdan ibarət idi, burada təlim və test alt dəstləri arasında 80/20 bölgüsü saxlanılırdı. Hər bir proqnoz üçün metriklər qeydə alındı və onların orta dəyərləri hesablanaraq Cədvəl 3 və 4-də təqdim olunmuşdur.

Cədvəl 3.

Giriş pəncərəsi - GRU					
Giriş pəncərəsi	OMX	OKX	KOKX	OMFX	R ²
25	6.26876	77.20209	8.65152	4.65%	0.97240
50	7.31752	101.58542	9.99415	5.32%	0.96358
75	7.01544	95.13397	9.61283	5.11%	0.96580
100	6.05663	70.33266	8.32452	4.52%	0.97458
125	6.15711	73.20857	8.46008	4.58%	0.97361
150	7.01215	93.64945	9.54157	5.13%	0.96606

Cədvəl 4.

Giriş pəncərəsi - LSTM					
Giriş pəncərəsi	OMX	OKX	KOKX	OMFX	R ²
25	5.32076	59.54124	7.58995	4.21%	0.97871
50	4.80348	47.84422	6.80072	3.88%	0.98285
75	5.10483	55.17844	7.25437	4.07%	0.98017
100	4.47343	40.44012	6.30300	3.67%	0.98542
125	5.04923	57.31991	7.17754	4.03%	0.97928
150	5.15170	55.66220	7.23008	4.10%	0.97982

Bu prosesdəki son addım, məlumatları təlim və test dəstlərinə ayırmaqdır. Beləliklə modellər təlim prosesi zamanı görmədiyi məlumatlarla qiymətləndirilə bilərdi. Ümumiyyətlə, istifadə olunan ümumi nisbət 80% məlumatın təlim üçün ayrılması və 20%-nin test üçün ayrılmasıdır. Qeyd etmək lazımdır ki, təlim və test məlumatları arasında 15%-lik bir doğrulama alt dəstinin daxil edilməsi də test edilib. Bu alt dəstənin daxil edilməsi, xüsusilə CNN və RNN alqoritmlərini istifadə edən modellər üçün ümumilikdə daha pis nəticələrə səbəb oldu, xüsusilə R² metriklərində müvafiq olaraq 21 və 33 faizlik enişlər baş verdi. Buna görə də, doğrulama alt dəstini yalnız təlim və test alt dəstlərini



daxil etməklə dəyişdirmək qərarına gəlinmişdir, çünki doğrulama alt dəstinin daxil edilməsinin əsas səbəbi təlim məlumatlarında həddindən artıq uyğunlaşmanı (overfitting) azaltmaq və test məlumatlarında performansını yaxşılaşdırmaq idi, lakin bu nəticə göstərilmədi. Bu addımlar həyata keçirildikdən sonra, məlumatlar modelin təlim və qiymətləndirmə prosesində istifadə edilməyə hazır oldu. Burada təlim dəsti modelin parametrlərini tənzimləmək üçün, test dəsti isə modelin görünməyən məlumatlar üzərində performansını qiymətləndirmək üçün istifadə edildi.

4. PROQNOZLAŞDIRMA MODELƏRİ

Bu bölmə, Apple Inc. səhmlərinin qiymətlərini proqnozlaşdırmaq üçün istifadə olunan modelləri ətraflı şəkildə izah edir. Ümumilikdə 44 fərqli model tətbiq olundu. Hər bir model 2.3-cü bölmədə təqdim olunan metriklərə əsasən təlim edildi və qiymətləndirildi. Burada 10 testdən ibarət bir dəst istifadə olunmuşdur və bu bölmədə orta dəyər təqdim edilir.

Bütün modellər, 0.001 öyrənmə sürəti və MSE itki funksiyası ilə Adam optimizatoru istifadə edilərək tərtib edilmişdir. Çıxış qatında davamlı səhm qiymətlərini proqnozlaşdırmaq üçün xətti aktivasiya funksiyası istifadə edilir. Bundan əlavə, EarlyStopping və ReduceLROnPlateau funksiyaları da tətbiq edilmişdir, sonuncusu isə modelin təlim prosesi zamanı öyrənmə sürətini tənzimləmək üçün istifadə olunur. Modelin performansını yaxşılaşdırmağa davam etmədikdə onu azaldır və bu, modelin yaxınlaşmasını (convergence) yaxşılaşdırmağa kömək edir [19]. Digər bir alət isə keras_tuner-in BayesianOptimization funksiyasıdır [19]. BayesianOptimization funksiyası, modellər üçün ən yaxşı hiperparametrlərin kombinasiyonlarını müəyyən etməyə imkan verir, eyni zamanda təlim dəstində MSE-ni minimuma endirən hiperparametrləri optimallaşdırır. Bu metod, mümkün olan geniş konfigurasiyaları effektiv şəkildə araşdırmaq üçün faydalıdır. Sonra bu funksiya, dərin öyrənmə modellərinin qatlarında ideal yaddaş hüceyrələrinin sayını və dropout qatlarında istifadə ediləcək ən yaxşı nisbəti tapmaq üçün istifadə olundu, burada 64 və 256 vahidləri və dropout nisbəti üçün 0.1 ilə 0.5 arasında axtarış edildi.

4.1. LSTM Model

Qurulan ilk neyron şəbəkə modeli yalnız LSTM qatlarından ibarətdir. Bu qatların arasında və ya ardınca dropout qatları (yəni bəzi neyronları təsadüfi şəkildə deaktiv edən qatlar – overfitting-in qarşısını almaq üçün) əlavə olunub. Sonda isə dense qat (yəni sıx əlaqəli çıxış qatı) var, bu qat modelin yekun nəticəsini verir. Bunun üçün modelin müxtəlif konfigurasiyaları hazırlanmışdır, məsələn, iki, üç, dörd və beş LSTM qatı, yaddaş hüceyrələri üçün 256 və dropout nisbəti üçün 0.1 hiperparametr dəyərləri ilə, bu da sonra model testləri boyunca istifadə olunan ilkin dəyərlərdir.

Yəni modelin fərqli versiyaları sınıanıb: yəni modelə 2, 3, 4 və ya 5 LSTM qatı əlavə edilərək fərqli konfigurasiyalar yaradılıb. İstifadə olunan hiperparametrlər cədvəl 5-də əks olunmuşdur.

- Hər bir LSTM qatında olan yaddaş hüceyrələrinin sayı 256-dır (yəni LSTM qatlarının "ölçüsü" 256-dır),
- Dropout nisbəti isə 0.1-dir, yəni hər iterasiyada neyronların 10%-i deaktiv edilir.

Cədvəl 5-dəki performans testləri göstərir ki, modelin ən yaxşı versiyası iki LSTM qatı olan modeldir, çünki o, ilk dörd metrikdə ən aşağı dəyərlərə və modellər arasında ən yüksək R^2 dəyərinə sahib idi.

Cədvəl 5.

Model	LSTM modeli				R^2
	OMX	OKX	KOKX	OMFX	
2 LSTM	4.47343	40.44012	6.30300	3.67%	0.98542
3 LSTM	6.39245	93.64143	8.81530	5.02%	0.96624
4 LSTM	13.27586	326.50295	17.63884	9.49%	0.88230
5 LSTM	12.78660	296.52519	16.96558	9.26%	0.89311



BayesianOptimization metodu, həm LSTM qatları üçün yaddaş hüceyrələrinin ideal sayının 256, həm də dropout qatları üçün ideal nisbət 0.1 olduğunu göstərdi. Son optimallaşdırılmış modelin arxitekturası cədvəl 6-da göstərilmişdir.

Cədvəl 6.**Yekun LSMT modeli**

Layer Type	Units	Dropout Rate	Activation	Input Shape	Output Shape
Input	-	-	-	-	(None, 100, 20)
LSTM	256	-	-	(None, 100, 20)	(None, 100, 256)
Dropout	-	0.1	-	(None, 100, 256)	(None, 100, 256)
LSTM	256	-	-	(None, 100, 256)	(None, 256)
Dropout	-	0.1	-	(None, 256)	(None, 256)
Dense	1	-	Linear	(None, 256)	(None, 1)

4.2. GRU Model

İkinci model olan GRU üçün, LSTM modelinə bənzər bir arxitektura qəbul edilmişdir, yalnız LSTM qatları GRU qatları ilə əvəzlənmişdir. Cədvəl 7-də göstərilən ən yaxşı model iki GRU qatından ibarətdir.

Cədvəl 7.**GRU modeli**

Model	OMX	OKX	KOKX	OMFX	R ²
2 GRU	6.05663	70.33266	8.32452	4.52%	0.97458
3 GRU	6.68641	86.15809	9.19105	4.98%	0.96894
4 GRU	7.18087	101.49023	9.90276	5.33%	0.96341


Cədvəl 8.**Yekun GRU modeli**

Layer Type	Units	Dropout Rate	Activation	Input Shape	Output Shape
Input	-	-	-	-	(None, 100, 20)
GRU	192	-	-	(None, 100, 20)	(None, 100, 192)
Dropout	-	0.1	-	(None, 100, 192)	(None, 100, 192)
GRU	256	-	-	(None, 100, 192)	(None, 256)
Dropout	-	0.1	-	(None, 256)	(None, 256)
Dense	1	-	Linear	(None, 256)	(None, 1)

Əvvəlki modeldə olduğu kimi, hiperparametr axtarışı BayesianOptimization istifadə edərək aparılmışdır. GRU modelinin son arxitekturası iki GRU qatının dropout qatları ilə birləşdirilməsindən ibarətdir. Burada birinci və ikinci GRU qatları üçün müvafiq olaraq 192 və 256 vahidlərinin optimal dəyərləri tapılmışdır və hər iki dropout qatında 0.1 dropout nisbətləri istifadə edilmişdir. Bunlar Cədvəl 8-də göstərilmişdir.

4.3. CNN Model

CNN-lər daha çox vizionla əlaqəli tapşırıqlar üçün istifadə olunsada, onlar zaman seriyalarının proqnozlaşdırılması üçün ən çox istifadə olunan alqoritmlərdən biridir [14]. Bu, yalnız hesablama effektivliyinə görə deyil, xüsusən RNN-lərlə müqayisədə, həm də onların iyerarxik xüsusiyyətləri çıxarma qabiliyyətinə görədir. Bu qabiliyyət, həm qısa, həm də uzun müddətli asılılıqları tutmalarına imkan verərək, onları zaman seriyası tətbiqləri üçün çox çevik edir [5, 15].

**Şəkil 1. CNN modeli**



CNN-lərin bu tip model və kontekstdə performansını qiymətləndirmək üçün əvvəlcəyəniz özləri test edilmiş, sonra LSTM ilə, nəhayət GRU ilə müxtəlif birləşmələrdə istifadə edilmişdir. İlk mərhələdə, CNN-lər yalnız özləri test edilib, onların stok qiymətlərini proqnozlaşdırmaq tapşırığında necə performans göstərdiyi yoxlanılmışdır. CNN-lər verilənlərdə naxışları tanımaqda yaxşı bir qabiliyyət göstərsə də, onlar stok qiymətini minimal dərəcədə məqbul olan bir səhvlə izləyə bilmədilər. Bu da Şəkil 1-də göstərilmişdir.

4.4. RNN Model

RNN modeli üçün əvvəlki modellərdə olduğu kimi RNN qatlarının tək başına və GRU və LSTM qatları ilə birləşdirildiyi müxtəlif kombinasiya testləri aparılmışdır (Cədvəl 16). CNN modellərindən fərqli olaraq, bu qatların əksər kombinasiya nəticələri istənilən nəticəni verməmişdir. Lakin iki GRU qatından sonra iki RNN qatından ibarət olan modellər və bir LSTM qatından sonra iki RNN qatından ibarət olan modellər ən yaxşı nəticələri əldə etmişdir. Bu iki modelə əlavə olaraq, yalnız RNN-lərdən ibarət olan model də seçilmişdir, çünki o, digər qat növləri tətbiq edilmədən çox yaxşı nəticələr göstərmişdir. Bu modellərin son arxitekturaları və optimallaşdırılmış dəyərləri Cədvəllər 9–10-da göstərilmişdir.

Cədvəl 9.

RNN modeli					
Model	OMX	OKX	KOKX	OMFX	R ²
2 RNN	13.42476	312.82043	17.50414	9.40%	0.88723
3 RNN	11.00183	203.15732	14.07731	8.00%	0.92676
4 RNN	54.26821	5309.99157	67.45029	38.61%	-0.91418
2 RNN + 1 GRU	16.08922	487.06017	21.59222	11.02%	0.82442
2 RNN + 1 LSTM	35.61142	2324.05876	46.58004	24.14%	0.16221
2 RNN + 1 GRU	52.63348	4534.71260	67.37217	36.14%	-0.67760
3 RNN + 2 GRU	58.07854	4581.42100	73.94511	39.95%	-0.97597
3 RNN + 1 LSTM	51.58560	4527.09365	65.51352	36.24%	-0.63195
3 RNN + 2 LSTM	49.62855	4271.35011	63.29981	34.38%	-0.53947
1 GRU + 2 RNN	34.71628	3311.86846	43.18345	24.90%	-0.19388
2 GRU + 2 RNN	6.86930	85.52000	9.10183	5.18%	0.96917
1 LSTM + 2 RNN	5.20305	59.16789	7.28287	4.05%	0.97867
2 LSTM + 2 RNN	15.04343	360.47080	18.85734	10.79%	0.87006

Cədvəl 10.

Yekun RNN modeli

Layer Type	Units	Dropout Rate	Activation	Input Shape	Output Shape
Input	-	-	-	-	(None, 100, 20)
SimpleRNN	64	-	-	(None, 100, 20)	(None, 100, 64)
Dropout	-	0.1	-	(None, 100, 64)	(None, 100, 64)
SimpleRNN	64	-	-	(None, 100, 64)	(None, 100, 64)
Dropout	-	0.1	-	(None, 100, 64)	(None, 100, 64)
SimpleRNN	160	-	-	(None, 100, 64)	(None, 160)
Dropout	-	0.1	-	(None, 160)	(None, 160)
Dense	1	-	linear	(None, 160)	(None, 1)

4.5. XGBoost model

XGBoost modeli üçün giriş verilənləri əvvəlki modellərdən fərqli şəkildə hazırlandı. Əvvəlki prosesdən fərqli olaraq, burada verilənlər sabit zaman sırasına görə deyil, sadəcə 80% təlim və 20% test bölməsi ilə bölündü. Bu bölmədən sonra müstəqil dəyişənlər və hədəf dəyişəni ayırdı və əvvəlki prosesə bənzər şəkildə işlənməmişdir.

Model XGBRegressor funksiyası istifadə edilərək quruldu [16], və Cədvəl 11-də göstərilən parametrlərdən istifadə edildi. Bu parametr dəyərləri, scikit-learn kitabxanasının GridSearchCV funksiyasından istifadə edilərək optimallaşdırılmış

Cədvəl 11.

XGBoost modeli üçün parametrlər

Parameter	Value
n_estimators	2000
colsample_bytree	1
learning_rate	0.2
max_depth	3
gamma	0

dır [7]. Bu dəyər aralıqları, Kaggle platformasında yerləşən “A Guide on XGBoost hyperparameters tuning” adlı sənəddən alınmışdır [17].


XGBoost modelini konfigurasiya etdikdən sonra, proqnozlaşdırma prosesi iterativ şəkildə aparıldı. Giriş pəncərəsi olmadığı üçün model hər bir proqnozdan sonra əvvəlki proqnozları və əvvəlki real dəyəri istifadə edilən verilənləri yeniləməli oldu. Bu üsul modelin öz proqnozlarını və faktiki müşahidə edilən verilənləri daxil edərək proqnozlarını tənzimləməyə imkan verdi. Bu iterativ yeniləmə yanaşması zaman seriyası verilənləri üçün yaxşı uyğun gəlir, burada hər yeni proqnoz həm əvvəlki proqnozlardan, həm də dəyərlərdən məlumat ala bilər.

XGBoost modelini konfigurasiya etdikdən sonra proqnozlaşdırma prosesi iterativ şəkildə aparıldı. Giriş pəncərəsi olmadığından model hər bir proqnozdan sonra əvvəlki proqnozları və əvvəlki real dəyəri nəzərə alaraq proqnoz üçün istifadə olunan məlumatları yeniləməli idi. Bu metod modelin həm öz proqnozlarını, həm də faktiki müşahidə olunan məlumatları daxil etməklə proqnozlarını tənzimləməsinə imkan verdi. Bu iterativ yeniləmə yanaşması, hər yeni proqnozun həm əvvəlki proqnozlar, həm də əvvəlki dəyərlər əsasında formalaşdığı zaman sıralı verilənlər üçün uyğundur.

5. NƏTİCƏLƏR VƏ ONLARIN MÜZAKİRƏSİ

Bu bölmədə zaman seriyalarının proqnozlaşdırılmasında seçilmiş bütün modellərin performansını ilə bağlı nəticələr təqdim olunur. Modellərin fərqli təlim və test alt qrupları, eləcə də müxtəlif səhmlərin qiymətləri üzrə performansını qiymətləndirmək və müqayisə etmək üçün Zaman Seriyası Çarpaz Doğrulama (Time Series Cross Validation) texnikasından istifadə edilmişdir. Bu texnika zaman seriyaları üçün idealdır, çünki ənənəvi çarpaz doğrulamadan fərqli olaraq, məlumatların zaman ardıcılığını qoruyur.

Zaman Seriyası Çarpaz Doğrulama texnikasında test dəsti həmişə təlim dəstindən sonra gələn məlumatlardan ibarətdir və beləliklə, modelin keçmiş məlumatlardan istifadə edərək gələcək məlumatları proqnozlaşdırmaq bacarığı qiymətləndirilir [20]. Bu analiz üçün 10 qatlamadan (folds) istifadə olunmuşdur (Şəkil 2-də göstərildiyi kimi). Bu, modelin hər dəfə daha kiçik zaman pəncərəsi olmaqla 10 dəfə təlim alması və hər dəfə indiyə qədər görmədiyi gələcək məlumatlarla yoxlanması deməkdir. Hər qatlama üçün performans MAE, MSE, RMSE, MAPE və R^2 göstəriciləri ilə qiymətləndirilmişdir.



Şəkil 2. Proqnozlaşdırma modelinin qatlamaları

Qeyd etmək lazımdır ki, hər bir alt dəst MinMaxScaler funksiyasından istifadə edilərək 0 və 1 arasında fərdi şəkildə miqyaslandırılmışdır. Bu, model üçün sabit giriş təmin edərək yalnız alt dəstlərin ölçüsünü dəyişdirmiş, lakin dəyərlərin öz ölçüsünü sabit saxlamışdır.



Daha sonra, model proqnoz verdikdən sonra həmin proqnozların 0 və 100 arasında real dəyərlərə qaytarılması tələb olunurdu. Bu metod iki əsas problemi həll edir.


Birincisi, hesablanmış metriklərin çox kiçik dəyərlərə malik olması səbəbindən oxunmazlıq problemidir. İkincisi isə müxtəlif alt dəstlər arasında sabit miqyasın qorunmasıdır. Əgər alt dəstlər MinMaxScaler tətbiq olunmadan əvvəl real dəyərlərinə uyğun miqyaslandırılarsa, onların fərqli miqyasları olacaq və bu, mütləq metriklərin şərhini mənasız edəcəkdir.

Nəticələrin təhlili göstərir ki, yalnız iki GRU qatından ibarət olan model və XGBoost modeli, sınaqdan keçirilən digər modellərlə müqayisədə ən yaxşı ümumi performansı nümayiş etdirmişdir. Bu, MAE, MSE, RMSE, MAPE və R^2 göstəricilərinin bütün qatlamalar (folds) üzrə aşağı orta dəyərləri ilə sübut olunur. Sınaqdan keçirilmiş modellər arasında GRU modeli ən yaxşı MSE və MAPE göstəricilərini əldə etmişdir, XGBoost modeli isə ən yaxşı MAE, RMSE və R^2 nəticələrini göstərmişdir. Bu iki model bütün metriklər üzrə çox oxşar nəticələrə malik olduqları üçün digər modellərdən xüsusilə fərqlənmişlər.


Növbəti ən yaxşı model LSTM modeli olmuşdur. Bu model yaxşı nəticələr göstərsə də, əvvəlki iki modelə nisbətən bütün metriklər üzrə zəif performans nümayiş etdirmişdir. Bu modelin zəif performansının əsas səbəbi 1-ci qatlamada (fold 1) zəif nəticə verməsi olmuşdur. Bundan əlavə, RNN + GRU qatlarından ibarət olan model ardıcıl olaraq 5-ci, CNN + GRU modeli isə 4-cü yeri tutmuşdur.

LSTM + GRU, CNN + LSTM və RNN modelləri isə yuxarıda qeyd olunan modellərdən xeyli zəif nəticə göstərmişdir. Baxmayaraq ki, bu modellərin ümumi orta göstəriciləri zəif olmuşdur, onlar yenə də yaxşı proqnozlar verə bilirlər. Məsələn, CNN + LSTM modeli fold 6-da çox uğurlu nəticə göstərmişdir, yalnız CNN + GRU modeli tərəfindən keçilmişdir. Ən zəif performansı isə RNN + LSTM qatlarından ibarət olan model nümayiş etdirmişdir. Bu, gözlənilməz bir nəticədir, çünki LSTM qatının əlavə edilməsi, yalnız RNN-lərdən ibarət modelə nisbətən performans artırmalı idi. Burada GRU qatlarının daxil edilməsinin modelin performansına çox müsbət təsir etdiyini vurğulamaq lazımdır. Bu təsir yalnız GRU, LSTM + GRU, CNN + GRU və GRU + RNN modellərində açıq şəkildə müşahidə olunmuşdur. Modellərin ən yaxşı qatlamalar (folds) üzrə proqnoz qrafikləri Şəkil 3–10-da təqdim edilmişdir. Fold 9 bütün modellər üçün ən yaxşı nəticə verən qatlama olmuşdur, lakin CNN qatlarından ibarət modellər üçün (CNN + LSTM və CNN + GRU) ən yaxşı nəticə fold 6-da əldə edilmişdir.


Şəkil 3. LSTM modelinin 9-cu qatının proqnoz əyrisi




Şəkil 4. GRU modelinin 9-cu qatının proqnoz əyrisi



Şəkil 5. LSTM+GRU modelinin 9-cu qatının proqnoz əyrisi




Şəkil 6. CNN+GRU modelinin 6-cı qatının proqnoz əyrisi




Qrafiklərin təhlili göstərir ki, GRU, LSTM və XGBoost modelləri fold 9 üçün ən yaxşı performansını nümayiş etdirmişdir. Bu da onların qiymət dalğalanmalarını dəqiq və yaxından izləmək qabiliyyətini vurğulayır. GRU + RNN modeli də uğurlu nəticə göstərmiş və ən yaxşı modellərə yaxın yer tutmuşdur. Fold 6-da bütün modellər yaxşı nəticə əldə etmişdir. Bu, bu qatlamının daha az mürəkkəb olmasına, yəni digər qatlamalarla müqayisədə daha az böyük amplitudalı dalğalanmalara malik olmasına aid edilə bilər. Bu, qeyd olunan modellərin aşağı dəyişkənlik olan ssenariləri çox effektiv idarə edə bildiyini göstərir.

Digər tərəfdən, RNN və LSTM + RNN modellərinin real qiymətləri digər modellərlə eyni dəqiqliklə uyğunlaşdırmaqda çətinlik çəkdiyi müşahidə olunur. Bu, xüsusilə son proqnozlarda daha aydın görünür, çünki burada faiz səhvi ilkin proqnozlara nisbətən artır. Bütün nəticələr göstərir ki, bu modellər yüksək dalğalanmaların olduğu nümunələri öyrənməkdə və qəfil amplituda artımlarına uyğunlaşmaqda çətinlik çəkə bilərlər.

Şəkil 7. CNN+LSTM modelinin 6-cı qatının proqnoz əyrisi




Şəkil 8. LSTM+RNN modelinin 9-cu qatının proqnoz əyrisi




Bundan əlavə, bütün modellərin sürətli qiymət dəyişikliklərinə uyğunlaşmaqda çətinlik çəkdiyi ayıq şəkildə görünür. Bu problem xüsusilə fold 9-un son hissəsində daha da qabarıq şəkildə müşahidə olunur, çünki burada qiymət dalğalanmalarının miqyası qatlamının digər hissələrinə nisbətən daha böyükdür. Digər bir vacib məqam isə ən zəif modellərin, məsələn, RNN və LSTM + RNN-in proqnozlarında ayıq şəkildə müşahidə olunan gecikmədir. Bu gecikmə, hesablanmış metriklər üzrə zəif performansla birbaşa təsir etmişdir.

Şəkil 9. RNN modelinin 9-cu qatının proqnoz əyrisi



Şəkil 10. XGBoost modelinin 9-cu qatının proqnoz əyrisi



YEKUN NƏTİCƏ

Bu tədqiqat işində LSTM, GRU, CNN, RNN və XGBoost modelləri tətbiq edilərək fərqli səhmlərin qiymət proqnozlaşdırma üsulları araşdırılmış və müqayisə olunmuşdur. Bu yanaşmaların zaman seriyası məlumatları kontekstində imkanları və məhdudiyyətləri barədə dərin anlayış təmin edilmişdir. Təhlil göstərdi ki, hər bir model özünəməxsus xüsusiyyətlərə malik olsa da, ən səmərəli yanaşmanın seçimi verilənlərin spesifik xüsusiyyətlərindən və proqnoz məqsədindən asılıdır. Bu işdə XGBoost və GRU modelləri məlumatları daha yaxşı ümumiləşdirməyi bacarmışdır. Həmin iki qabaqcıl modelin mürəkkəbliyi onların ümumi performansına əhəmiyyətli dərəcədə təsir etmişdir və onların daha mürəkkəb zaman seriyalarında, məsələn, səhmlərin qiymət proqnozlaşdırılmasında xüsusilə effektiv ola biləcəyini göstərmişdir.

Əksinə, RNN və CNN modelləri dəyişkən performans nümayiş etdirmişdir, bu da göstərir ki, modelin konfigurasiyasının düzgün tənzimlənməsi vacibdir. Bu modellər GRU qatları ilə birləşdirildikdə, onların nəticələrinin əhəmiyyətli dərəcədə yaxşılaşdığı müşahidə olunmuşdur. Lakin, yalnız RNN və ya LSTM qatları ilə birləşdirildikdə eyni nəticə əldə edilməmişdir.

Gələcək İşlər:

- Yeni məşin öyrənmə alqoritmlərinin və ya fərqli alqoritm kombinasiyalarının sınaqdan keçirilməsi.
- Daha müxtəlif səhmləri əhatə edən məlumat dəstinin istifadə olunması fərqli maliyyə bazarları və artım faizlərini əhatə edən məlumatlar ilə modeli daha dayanıqlı etmək.
- İqtisadi göstəricilər və fərqli səhmlərin eyni məlumat dəstinə daxil edilməsi, bunun bazarın ümumi vəziyyəti barədə daha geniş baxış təmin edə biləcəyi ehtimal edilir.
- Qiymətlərin istiqamətini (artacaq və ya azalacaq) proqnozlaşdırmaq üçün təsnifat texnikalarının tətbiqi. Bu yanaşma maliyyə qərarlarının qəbulunda daha əhəmiyyətli və praktik nəticələr verə bilər.
- Ensemble modellərinin tətbiqi, fərqli yanaşmaların birləşdirilməsi ilə proqnozların daha stabil və dəqiq olması təmin edilə bilər.
- Zaman Seriyası Çarpaz Doğrulamanın (Time Series Cross Validation) giriş pəncərəsinin ölçüsünə və model arxitekturalarının seçiminə tətbiq edilməsi, bu metod daha effektiv modelləşdirməyə kömək edə bilər.

ƏDƏBİYYAT

1. Bishop, C. M. Pattern Recognition and Machine Learning / C. M. Bishop, - 2006.
2. Breiman, L. Random Forests / L. Breiman, - 2001.
3. Cortes, C., & Vapnik, V. Support-Vector Networks / C., Cortes, & V. Vapnik, - 2005.



4. Əfəndiyev, R., & İbrahimov, N. Süni intellektin Azərbaycanda məşğulluq sektoruna perspektiv təsir imkanları // İpək yolu jurnalı, - 2023.
5. Naufal, G.R.; Wibowo, A. Time Series Forecasting Based on Deep Learning CNN-LSTM-GRU Model on Stock Prices // Int. J. Eng. Trends Technol, - 2023, 71, - p. 126-133.
6. <https://pandas.pydata.org/> (accessed on 28 September 2024)
7. <https://scikit-learn.org> (accessed on 5 October 2024).
8. <https://fred.stlouisfed.org/> (accessed on 28 September 2024)
9. <https://medium.com/@Kavya2099/optimizing-performance-selectkbest-for-efficient-feature-selection-in-machinelearning-3b635905ed48> (accessed on 30 September 2024)
10. Cort, J. Willmott and Kenji Matsuura. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance // Clim. Res, - 2005, 30, - p. 79-82.
11. <https://www.britannica.com/science/meansquared-error> (accessed on 30 September 2024)
12. <https://www.deepchecks.com/glossary/root-mean-squareerror/> (accessed on 30 September 2024)
13. <https://www.investopedia.com/terms/c/coefficient-of-determination.asp> (accessed on 30 September 2024)
14. Hu, Z.; Zhao, Y.; Khushi, M. A Survey of Forex and Stock Price Prediction Using Deep Learning // Appl. Syst. Innov, - 2021.
15. Mancuso, P.; Piccialli, V.; Sudoso, A.M. A machine learning approach for forecasting hierarchical time series // Expert Syst. Appl, - 2021, 182, - p. 115102
16. <https://xgboost.readthedocs.io/en/latest/python/> (accessed on 5 October 2024)
17. <https://www.kaggle.com/code/prashant111/a-guide-on-xgboost-hyperparameters-tuning/> (accessed on 5 October 2024)
18. <https://finance.yahoo.com/> (accessed on 28 September 2024)
19. <https://keras.io> (accessed on 4 October 2024)
20. <https://www.geeksforgeeks.org/>

MACHINE LEARNING ALGORITHMS IN FORECASTING STOCK PRICES IN THE FINANCIAL MARKET

G.R. Mirzayeva, N.Z. Allahyarova

The article analyzes approaches based on Machine Learning algorithms and Deep Learning techniques for stock price prediction in financial markets. Concepts of technical analysis, such as exponential and simple moving averages, are explored. Various global indices are analyzed to incorporate Machine Learning models, including Recurrent Neural Network (RNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU), Convolutional Neural Network (CNN), and XGBoost. Research indicates that each model has distinct characteristics, and selecting the most effective approach depends on specific data and forecasting objectives. The complexity of models like XGBoost and GRU is reflected in their overall performance, and these models are proposed as effective tools capable of most accurately predicting complex time series patterns.

Key words: *machine learning, LSTM, CNN, GRU, XGBoost*



АЛГОРИТМЫ МАШИННОГО ОБУЧЕНИЯ В ПРОГНОЗИРОВАНИИ ЦЕН АКЦИЙ НА ФИНАНСОВОМ РЫНКЕ

Г.Р. Мирзаева, Н.З. Аллахьярова

В данной статье исследуются и анализируются подходы прогнозирования цен акций на финансовом рынке, основанные на алгоритмах машинного обучения и технике глубокого изучения. Изучаются экспоненциальные и простые методы усреднения технического анализа. Для внедрения моделей машинного обучения анализируются различные глобальные индексы, такие как: Recurrent Neural Network (RNN), Long Short- Term Memory (LSTM), Gated Recurrent Unit (GRU), Convolutional Neural Network (CNN) и XGBoost. Исследования показывают, что каждая модель имеет разные характеристики, и выбор наиболее эффективного зависит от конкретных данных и целей прогнозирования. Предлагаются модели XGBoost и GRU как обладающие наиболее эффективными инструментами, которые качественно прогнозируют сложные временные ряды.

Ключевые слова: машинное обучение, LSTM, CNN, GRU, XGBoost