



ارزیابی و اعتبارسنجی معماری بهینه یادگیری عمیق در پیش‌بینی قیمت سهام (رویکرد الگوریتم حافظه کوتاه مدت ماندگار LSTM)

امیر شریف‌فر^۱

مریم خلیلی عراقی^۲

ایمان رئیسی وانانی^۳

میرفیض فلاح^۴

تاریخ دریافت مقاله: ۱۴۰۰/۰۱/۱۶ تاریخ پذیرش مقاله: ۱۴۰۰/۰۲/۱۱

چکیده

امروزه انواع مدل‌های هوش مصنوعی جایگاه خود را در محاسبات و پیش‌بینی‌های بازارهای مالی تثبیت کرده‌اند؛ در این میان معماری‌های مبتنی بر یادگیری عمیق که خود براساس الگوریتم‌های یادگیری ماشینی می‌باشند، از طریق رفع ضعف‌های مدل‌های سنتی شبکه عصبی در خصوص پیش‌بینی ساختارهای دینامیک، مورد توجه قرار گرفته‌اند. مهمترین مزیت الگوریتم‌های یادگیری عمیق نسبت به مدل‌های سنتی شبکه عصبی، استخراج خودکار ویژگی‌های مناسب از ورودی‌های خام می‌باشد که از آن برای روند یادگیری مدل استفاده می‌کند؛ به عبارتی الگوریتم‌های این روش از چندین لایه‌ی پردازش اطلاعات و به ویژه اطلاعات غیرخطی بهره می‌برند تا بهترین ویژگی‌های مناسب را از ورودی خام استخراج نمایند. در پژوهش حاضر توانایی معماری‌های الگوریتم حافظه کوتاه‌مدت ماندگار (LSTM)^۱ جهت پیش‌بینی قیمت سهام مورد بررسی قرار گرفته است؛ علاوه بر این، ضمن طبقه‌بندی عوامل موثر بر قیمت سهام، مولفه‌های نشان‌دهنده معاملات سهامداران حقیقی و حقوقی به عنوان عاملی اثرگذار بر قیمت سهام معرفی و بررسی شده است. برای اجرای مدل از سه گروه داده‌های قیمتی، شاخص‌های تکنیکال و معاملات سهامداران حقیقی و حقوقی استفاده شده است. نتایج تحقیق نشان از عملکرد بهتر معماری LSTM همراه با لایه Drop Out نسبت به مدل ساده آن و همچنین مدل RNN دارد.

کلمات کلیدی

پیش‌بینی قیمت سهام، یادگیری عمیق، حافظه کوتاه‌مدت ماندگار LSTM، شبکه عصبی بازگشتی RNN

- ۱- دانشجوی دکتری، گروه مدیریت مالی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. am.sharifar@gmail.com
- ۲- استادیار، گروه مدیریت بازرگانی، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. (نویسنده مسئول) m.khaliliaraghi@gmail.com
- ۳- دانشیار، دانشکده مدیریت و حسابداری، گروه مدیریت صنعتی، دانشگاه علامه طباطبائی، تهران، ایران. imanraeesi@atu.ac.ir
- ۴- دانشیار، گروه مدیریت مالی، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران. fallahshams@gmail.com

ارزیابی و اعتبار سنجی معماری بهینه... / شریف فر، خلیلی عراقی، رئیسی وانانی و فلاح

مقدمه

اهمیت و جایگاه بی‌بدیل بازار سرمایه در اقتصاد کشورها بر کسی پوشیده نیست؛ این نهاد مالی نقشی تعیین‌کننده در تخصیص بهینه منابع و تأمین منابع مالی بنگاه‌های اقتصادی دارد که در نهایت کمک شایانی به رشد و شکوفایی اقتصاد یک کشور می‌کند. بسط و توسعه کمی و کیفی بازار سرمایه ایران در سال‌های اخیر در کنار بهره‌گیری از ابزارهای نوین مالی باعث هدایت نقدینگی از بازارهای موازی به این حوزه شده است که افزایش حجم معاملات و توجه هرچه بیشتر آحاد جامعه به بازار سرمایه را در پی داشته است. شناخت و بررسی رفتار قیمت سهام همواره مورد توجه سرمایه‌گذاران و پژوهشگران این حوزه بوده است؛ فعالان این بازار درصدد دستیابی و به کارگیری روش‌هایی هستند تا بتوانند با پیش‌بینی آتی قیمت سهام، سود سرمایه خود را افزایش دهند. بنابراین، ضروری است که روش‌های مناسب، صحیح و متکی به اصول علمی در تعیین قیمت آینده سهام فرآروی افراد سرمایه‌گذار قرار گیرد [۳].

برخی پدیده‌ها نظیر قیمت سهام دارای ماهیت پیچیده‌ای هستند که یافتن یک مدل ریاضی برای مدل کردن رابطه غیرخطی بین عناصر ورودی و خروجی را، دشوار می‌سازد؛ تغییرات قیمت در بازار سهام تحت تأثیر عوامل متعددی نظیر متغیرهای کلان اقتصادی - نرخ بهره بانکی، نرخ تسعیر ارز، تورم - و همچنین رویدادهای سیاسی، وضعیت صنعت، سیاست‌های شرکتی، انتظارات سرمایه‌گذاران و تحرکات سایر بازارهای موازی قرار دارد [۱۳]. داده‌های تاریخی نشان می‌دهد ویژگی‌های پیچیده قیمت سهام، مانند غیر خطی بودن، عدم قطعیت، نوسان و پویایی، پیش‌بینی آن را دشوار می‌کند و نتایج پیش‌بینی را با عدم قطعیت زیادی مواجه می‌سازد [۲۶]. نظر به اینکه اکثر محققین بر این عقیده هستند که بازارهای مالی از روندی غیرخطی پیروی می‌کند [۴۰]، استفاده از مدل‌های غیرخطی و تکنیک‌های پیشرفته، محبوبیت روزافزون و گسترده‌ای در بین متخصصین بازارهای مالی جهت پیش‌بینی قیمت پیدا کرده است؛ استفاده از روش‌های هوش مصنوعی در زمره این‌گونه فعالیت‌ها هستند.

در سال‌های اخیر، مدل‌های پیش‌بینی مبتنی بر یادگیری عمیق^۲ که عمدتاً عملکرد بهتری نسبت به روش‌های سنتی دارند، ظهور پیدا کرده‌اند. یادگیری عمیق شاخه‌ای از مبحث یادگیری ماشین و هوش مصنوعی می‌باشد و مجموعه‌ای از الگوریتم‌هایی است که تلاش می‌کنند مفاهیم انتزاعی سطح بالا را با استفاده از یادگیری در سطوح و لایه‌های مختلف مدل کنند [۲۶]. به عبارت دیگر الگوریتم‌های این روش از چندین لایه‌ی پردازش اطلاعات و به ویژه اطلاعات غیرخطی بهره می‌برند تا بهترین ویژگی‌های مناسب را از ورودی خام استخراج نمایند [۲۹]. از میان تکنیک‌های مختلف یادگیری عمیق که در علوم مختلف کاربردهای فراوانی دارد، پژوهشگران حوزه مالی جهت پیش‌بینی قیمت با توجه به ویژگی‌های سری‌های

زمانی مالی، عمدتاً از معماری‌های بخصوصی نظیر شبکه عصبی بازگشتی (RNN)^۳ و حافظه کوتاه‌مدت ماندگار (LSTM) استفاده کرده‌اند [۳۶]. در پژوهش حاضر نیز ضمن معرفی الگوریتم‌های مذکور به مقایسه توانایی معماری‌های مختلف LSTM در پیش‌بینی قیمت سهام پرداخته شده است.

مبانی نظری و پیشینه تحقیق

فراخور موضوع پژوهش در این بخش دو مبحث اصلی به تفکیک مورد بررسی قرار می‌گیرد؛ در بخش اول به عوامل موثر بر قیمت سهام پرداخته می‌شود، چرا که انتخاب مناسب متغیرهای ورودی در کنار سایر عوامل یکی از مهمترین ارکان بررسی روند و پیش‌بینی قیمت سهام می‌باشد؛ در بخش دوم نیز به کاربرد معماری‌های مختلف یادگیری عمیق در پیش‌بینی سری‌های زمانی مالی پرداخته می‌شود.

الف. عوامل موثر بر قیمت سهام

فارغ از مدل‌ها و تکنیک‌های مختلف استفاده شده جهت پیش‌بینی قیمت در بازارهای مالی، یکی از مهم‌ترین مباحث مورد توجه پژوهشگران شناسایی عوامل موثر بر قیمت سهام است و محققین این حوزه براساس مطالعات خود به دسته‌بندی‌های مختلفی اشاره کرده‌اند به عنوان مثال باباجانی و همکارانش (۱۳۹۸) در پژوهش خود به چهار طبقه مولفه‌های بنیادین شرکت، مولفه‌های فنی، مولفه‌های کلان اقتصادی و مولفه‌های روانشناسی و رفتاری اشاره کرده‌اند؛ پژوهش حاضر ضمن تکمیل طبقه‌بندی مذکور، بر اساس تحقیقات انجام شده در این حوزه، عوامل موثر بر قیمت سهام را در شش گروه اصلی عوامل بنیادی شرکت^۴، عوامل فنی^۵، داده‌های قیمتی، عوامل کلان اقتصادی، عوامل روانشناسی و رفتاری و معاملات سهامداران حقیقی و حقوقی دسته‌بندی کرده است.

▪ عوامل بنیادی: در این بخش اساساً به ارزش ذاتی سهم توجه می‌شود، و برای تعیین ارزش ذاتی سهم به صورت‌های مالی، سوابق تقسیم سود، سیاست‌های فروش و توان موسسه در افزایش سود و بسیاری دیگر از عوامل محیط داخلی و محیط اقتصادی شرکت توجه می‌شود.

▪ عوامل فنی (تکنیکال): انواع شاخص‌ها و ابزارهای مورد استفاده تحلیل‌گران فنی در این رشته می‌باشد. صاحب‌نظران این حوزه که آنها را تحلیل‌گران تکنیکی یا چارتیست^۶ نیز می‌نامند [۱۰]، داده‌های قیمت و حجم معاملات یک دارایی را بر اساس فرمول‌های مشخصی پردازش کرده و خروجی این محاسبات را در قالب اشکال و نمودار نمایش می‌دهند. بررسی رفتار قیمت سهام و روند آن در گذشته و همچنین بررسی الگوهای قیمتی مورد توجه پژوهشگران این حوزه است که در نهایت از مجموع موارد فوق جهت پیش‌بینی قیمت آینده استفاده می‌کنند.

ارزیابی و اعتبارسنجی معماری بهینه.../شریف‌فر، خلیلی عراقی، رئیسی وانانی و فلاح

▪ داده‌های قیمتی: در برخی از مطالعات داده‌های قیمت در رسته عوامل فنی (تکنیکال) طبقه‌بندی شده است حال آنکه تکنیکالیست‌ها با استفاده از داده‌های قیمتی به محاسبه انواع شاخص‌ها و اسیلاتورهای مورد نیاز خود می‌پردازند. از این رو می‌توان گفت داده‌های قیمتی، ورودی مورد نیاز جهت محاسبه انواع ابزارهای متفاوت تحلیلی آن‌ها می‌باشد که در این تحلیل در یک گروه جداگانه طبقه‌بندی شده است و شاخص‌هایی که با انجام محاسبات بر روی داده‌های قیمتی بدست آمده است را در گروهی جداگانه تحت عنوان عوامل فنی قرار گرفته است.

▪ معاملات سهامداران حقیقی و حقوقی: یکی از مهمترین عواملی که بر قیمت سهام در بازار سرمایه ایران اثرگذار است و در پژوهش‌های گذشته مغفول مانده است تحرکات سهامداران حقیقی و حقوقی است. بررسی روند گذشته قیمت سهام بسیاری از شرکت‌ها نشان می‌دهد عواملی نظیر حمایت سهامدار حقوقی از سهام یک شرکت و یا ورود سهامدار حقیقی با حجم و قدرت بالا می‌تواند محرک رشد قیمت سهام باشد و یا برعکس آن فروش سهام توسط سهامدار حقوقی باعث افت قیمت گردد. در پژوهش حاضر مواردی که می‌تواند این عامل - معاملات سهامداران حقیقی و حقوقی - را بررسی نماید مورد توجه قرار گرفته و متغیرهایی نظیر سرانه حجم خرید و فروش سهامداران حقیقی و حقوقی و همچنین تغییر مالکیت از سهامداران حقیقی به حقوقی در طی یک جلسه معاملاتی به عنوان ورودی مدل استفاده شده است.

لازم به ذکر است در خصوص موضوع فوق، طبقه‌بندی دقیقی به دلیل وجود هم‌پوشانی بین گروه‌ها نمی‌توان داشت به عنوان مثال مولفه نرخ ارز را هم می‌توان در دسته عوامل بنیادگرایانه سهم طبقه‌بندی کرد چرا که ممکن است افزایش و یا کاهش آن تاثیر مستقیمی بر متغیرهای عملکردی شرکت نظیر میزان فروش و هزینه‌ها داشته باشد و از طرفی می‌توان عامل مذکور را به دلیل ماهیت آن در گروه عوامل کلان اقتصادی طبقه‌بندی کرد؛ در این پژوهش عواملی که کلیت بازار سرمایه را تحت تأثیر قرار می‌دهد در رسته عوامل کلان اقتصادی طبقه‌بندی شده است.

جدول ۱: عوامل موثر بر قیمت سهام طبقه

پژوهش‌های مرتبط	عامل	
[۵]، [۱۱]	سود هر سهم (EPS)	عوامل بنیادی شرکت
[۲۰]	بازده کل دارایی	
[۵]	سود تقسیمی هر سهم (DPS)	
[۲۱]	نسبت ارزش دفتری به ارزش بازار	

فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و هشتم / پاییز ۱۴۰۰

[۳]، [۲۵]، [۲۰]، [۱۲]، [۱۱]	نسبت P/E	عوامل بنیادی شرکت
[۱۱]	خالص ارزش دارایی ها (NAV)	
[۵]	تعداد سهام شرکت	
[۱۸]، [۲۵]، [۱۷] [۱]، [۷]، [۲۴]	بیشترین قیمت	داده‌های قیمتی
[۱۸]، [۲۵]، [۱۷] [۱]، [۷]، [۲۴]	کمترین قیمت	
[۱]، [۷]، [۲۴]	قیمت آغازین	
[۱۷]، [۷]	میانگین قیمت	
[۱۷]	آخرین قیمت	
[۱۷]	قیمت روز گذشته	
[۵] [۱۸]، [۲۵]، [۳] [۱]، [۷]، [۱۲]	حجم معاملات روزانه سهام	
[۱۲]	شاخص قدرت نسبی (RSI)	عوامل فنی (تکنیکال)
[۱۲]	تغییرات شاخص قدرت نسبی	
[۱۲]	میانگین متحرک ساده (SMA)	
[۲۲]	میانگین متحرک نمایی (EMA)	
[۱۲]	تغییرات میانگین متحرک ساده	
[۱۲]	شاخص واگرایی و همگرایی میانگین متحرک (MACD)	
[۲۲]	ویلیام %R	
[۲۲]	استاکستیک %K	
[۲۲]	استاکستیک %D	
[۱۲]	تغییرات شاخص واگرایی و همگرایی میانگین متحرک	
[۳]، [۱۸] [۲۵]، [۲۱]، [۱۰]، [۱۲]، [۸]، [۱۵]	نرخ ارز	عوامل کلان اقتصادی
[۱۸]، [۲۵]، [۲۱] [۲۰]، [۱۰]، [۱۲] [۲۴]، [۸]، [۱۵]	قیمت جهانی نفت خام	
[۱۸]، [۲۵]	قیمت اونس طلا	
[۱۰]، [۱۵]	قیمت سکه طلا	عوامل کلان اقتصادی
[۳]، [۲۱]	قیمت طلای ۱۸ عیار	
[۱۵]، [۲۱]	نرخ تورم	
[۱۷]	ارزش بازار	
[۲۱]	نرخ بهره	
[۲۳]	شاخص قیمت زمین	
[۲۳]	هزینه مسکن	
[۲۰]، [۲۳]	شاخص قیمت مصرف کننده (CPI)	
[۲۳]	پایه پولی	

ارزیابی و اعتبار سنجی معماری بهینه... / شریف فر، خلیلی عراقی، رئیسی وانانی و فلاح

[۲۳]	کرایه مسکن اجاره ای	
[۴]، [۸]، [۱۲]، [۱۰]، [۲۵]، [۱۸]	شاخص کل	
[۴]	شاخص مالی	
[۴]	شاخص صنعت	
[۲۵]، [۱۷]	تعداد افرادی که سهم را در یک روز خریداری کرده اند	عوامل روانشناسی
[۷]، [۱۷]، [۲۵]	تعداد دفعات معاملات	و رفتاری
پژوهش حاضر	سرانه حجم خرید سهامدار حقیقی	معاملات سهامداران حقیقی و حقوقی
پژوهش حاضر	سرانه حجم خرید سهامدار حقوقی	
پژوهش حاضر	سرانه حجم فروش سهامدار حقیقی	
پژوهش حاضر	سرانه حجم فروش سهامدار حقوقی	
پژوهش حاضر	تغییر مالکیت حقیقی به حقوقی	

شایان ذکر است در پژوهش‌های گذشته، داده‌های برخی عوامل بصورت سالانه می‌باشد و در طول سال تغییر نمی‌کند حال آنکه سایر متغیرها بصورت روزانه تغییر می‌کنند، از این رو در راستای لزوم همسان بودن دوره زمانی متغیرها و همچنین افق زمانی پیش‌بینی تحقیق که بصورت روزانه می‌باشد، در نهایت متغیرهای ورودی مدل در سه دسته به شرح جدول ذیل تعیین گردیده است:

جدول ۲: متغیرهای ورودی مدل

معاملات سهامداران حقیقی و حقوقی	شاخص های تکنیکال	داده های قیمتی
سرانه حجم خرید سهامدار حقیقی سرانه حجم خرید سهامدار حقوقی سرانه حجم فروش سهامدار حقیقی سرانه حجم فروش سهامدار حقوقی تغییر مالکیت حقیقی به حقوقی	Weighted 10-day moving average	اولین قیمت
	Momentum	بالاترین قیمت
	RSI	پایین ترین قیمت
	Williams %R	آخرین قیمت
	OBV	قیمت میانگین
	CCI	حجم معاملات
	Stochastic	ارزش معاملات
	K%	
	D%	
	MACD	MACD line
		signal

ب. یادگیری عمیق

یادگیری عمیق گونه‌ای از شبکه‌های عصبی مصنوعی است که شامل چندین لایه پردازش اطلاعات است که به الگوریتم توانایی بیشتری هم‌گامی با داده‌ها را می‌دهد. مهمترین مزیت الگوریتم‌های یادگیری عمیق نسبت به مدل سنتی شبکه عصبی، استخراج خودکار ویژگی‌های مناسب از ورودی‌های خام می‌باشد که از آن برای روند یادگیری مدل استفاده می‌کند [۳۶]. به عبارتی شبکه عصبی که از یادگیری عمیق استفاده می‌کند نوع خاصی از ANN است که از چند لایه تشکیل شده و در هر لایه نقش آفرینی متفاوتی داشته به طوری که شبکه کلی عملکرد بهتری از شبکه‌های کم‌عمق آن دارد [۳۷]. این امر باعث گردیده تکنیک‌های یادگیری عمیق در حوزه گسترده‌ای از علوم مختلف مانند پردازش تصویر، فیلم، گفتار، تحلیل متن و سری‌های زمانی استفاده شود؛ از این میان در حوزه پیش‌بینی قیمت سهام عمدتاً الگوریتم‌های شبکه عصبی بازگشتی (RNN) و حافظه کوتاه‌مدت ماندگار (LSTM) مورد توجه محققین می‌باشد که در ادامه بدان پرداخته شده است.

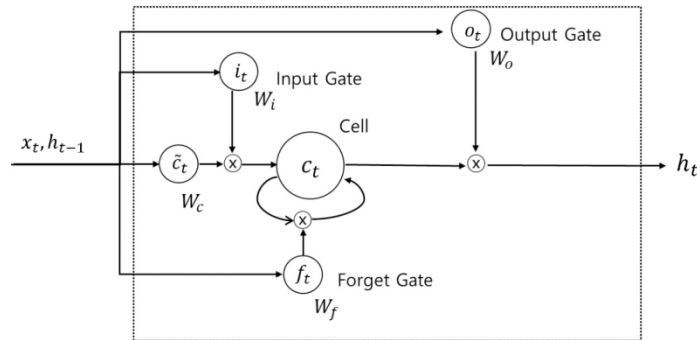
- شبکه عصبی بازگشتی (RNN)

RNN شبکه عصبی با یک حلقه پس‌خور می‌باشد که خاصیت آن‌ها در قیاس با شبکه عصبی مصنوعی (ANN) این است که رفتار آن‌ها هم بوسیله خودشان و هم به وسیله ورودی‌های خارجی به شبکه تعیین می‌گردد و نسبت به شبکه‌های عصبی مصنوعی، ساختارهای دینامیک را - که از ویژگی‌های بازار سهام است - بهتر مدل‌سازی می‌کنند [۲]. در حقیقت از آنجاییکه شبکه‌های عصبی بازگشتی در خود یک حلقه بازگشتی دارند قابلیت حفظ اطلاعات در خود شبکه را دارند.

- الگوریتم حافظه کوتاه‌مدت ماندگار (LSTM)

LSTM یکی از عمده‌ترین مشکلات معماری RNN که همان مشکل محو شدگی گرادیان^۷ است را مرتفع کرده است. مشکل مذکور اشاره به این مساله دارد که مقادیر گرادیان‌ها با حرکت به سمت ابتدای شبکه رفته رفته به حدی کوچک می‌شوند که تغییرات وزن بصورت ناچیزی صورت می‌گیرد و به این علت فرایند آموزش بشدت کند می‌شود و در حالات شدیدتر این مساله باعث متوقف شدن فرایند آموزش می‌گردد. LSTM که نوع خاصی از شبکه عصبی بازگشتی است توانایی یادگیری وابستگی‌های بلندمدت در طول زمان را دارد. هاخریتر و اشمیدهور در پژوهش خود از طریق معرفی دروازه‌ها^۸ و بلوک‌های حافظه^۹ بر روی معماری RNN بر مشکل محو شدگی گرادیان فائق آمدند. شکل ذیل نحوه عملکرد بلوک‌های حافظه در الگوریتم LSTM را نشان می‌دهد.

ارزیابی و اعتبار سنجی معماری بهینه.../شریف فر، خلیلی عراقی، رئیسی وانانی و فلاح



شکل ۱: ساختار LSTM با بلوک حافظه (منبع: [۳۹])

معادلات مرتبط با هر بلوک حافظه در ساختار LSTM به شرح ذیل است:

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (۱)$$

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (۲)$$

$$\tilde{c}_t = \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (۳)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (۴)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (۵)$$

$$h_t = o_t * \tanh(c_t) \quad (۶)$$

در معادلات بالا W ماتریس وزن، b بردار بایاس، $\sigma(\cdot)$ تابع زیگموید و $\tanh(\cdot)$ تابع تانژانت هایپربولیک می باشد. در رابطه (۱) متغیرهای ورودی x_t و h_{t-1} وارد چهار دروازه به نام‌های دروازه ورودی i_t ، دروازه خروجی o_t ، دروازه فراموشی f_t و سلول حالت \tilde{c}_t می‌شوند. برای دروازه‌های ورودی و خروجی وزن‌های متناظر هر دروازه محاسبه می‌شود و از تابع زیگموید جهت فعال‌سازی استفاده می‌شود. تابع زیگموید مقادیر بین صفر و یک اخذ می‌کند. چنانچه خروجی برابر با عدد یک باشد کل مقدار متناظر آن حفظ خواهد شد و اگر خروجی برابر با عدد صفر باشد مقدار متناظر آن بکلی حذف می‌شود. برای دروازه‌های دیگر، دروازه تعدیل‌کننده ورودی \tanh ، برای تعیین میزان اطلاعات جدیدی که می‌بایست در سلول حالت انعکاس یابد استفاده می‌شود. در نهایت، مقادیری که در c_t منعکس می‌شود از طریق جمع کردن ضرب نقطه‌ای بردارهای i_t و \tilde{c}_t با ضرب نقطه‌ای بردارهای f_t و c_{t-1} حاصل می‌گردد. در نهایت برای محاسبه خروجی h_t نیز از ضرب نقطه‌ای مقادیری که از دروازه خروجی بدست آمده با مقدار حاصل از $\tanh(\cdot)$ بدست می‌آید.

فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و هشتم / پاییز ۱۴۰۰

گائو و همکارانش در سال ۲۰۲۰ به مقایسه قدرت انواع مدل‌های LSTM، MLP^{۱۴}، CNN^{۱۵} در خصوص پیش‌بینی شاخص‌های SP500 و Nikkei225 در افق زمانی یک روزه پرداخته‌اند. آن‌ها از متغیرهای ورودی شاخص‌های تکنیکال، داده‌های قیمتی جهت و شاخص‌های کلان اقتصادی جهت پیش‌بینی استفاده کرده و در نهایت با استفاده از خطای RMSE بهترین عملکرد به ترتیب به مدل‌های CNN، LSTM و MLP بوده است [۳۰].

هیرانشا و همکارانش در سال ۲۰۱۸ با استفاده از داده‌های قیمتی ۵ شرکت در بورس اوراق بهادار هند بین سال‌های ۱۹۹۷ الی ۲۰۱۵ و بهره‌گیری از الگوریتم‌های LSTM، RNN، CNN، MLP به پیش‌بینی قیمت سه روز آتی سهام پرداختند [۳۲]. دینگ و همکارانش (۲۰۱۵) روش یادگیری عمیقی را برای پیش‌بینی بازار سهام رویدادمحور به منظور استخراج متون خبری، اطلاعات از اینترنت و روزنامه‌ها ارائه نمودند. آن‌ها با استفاده از داده تاریخی سهام S&P500 از الگوریتم CNN و شبکه تنسور عصبی برای مدلسازی اثرات کوتاه‌مدت و بلندمدت شرایط بر تغییرات قیمت سهام استفاده کردند [۲۸]. همچنین سانگ لی و سئونگ در سال ۲۰۱۸ با استفاده از معماری‌های LSTM، RNN، GRU و داده‌های قیمتی با بازه زمانی ۳۶ دقیقه‌ای به پیش‌بینی قیمت برای دقیقه آتی اقدام کردند [۳۹]. هائو و جیانگ نیز در سال ۲۰۲۰ با ارائه مدل ترکیبی CNN-LSTM به پیش‌بینی قیمت سهام در تایم فریم‌های مختلف نمودند [۳۱]. ژو و همکارانش (۲۰۱۸) با بررسی سهام ۴۲ شرکت در بورس شانگهای با استفاده از شاخص‌های تکنیکال و تایم فریم ۲۴۲ دقیقه‌ای به پیش‌بینی یک دقیقه آتی با استفاده از الگوریتم‌های LSTM و CNN پرداختند [۴۴]. همچنین دهیونگ وون و همکارانش در سال ۲۰۱۹ با استفاده از پارامترهای مختلف موثر بر مدل LSTM و با استفاده از داده‌های قیمتی به بررسی پیش‌بینی پذیری قیمت رمزارزها پرداخته‌اند، آنها جهت بهینه‌سازی مدل از ترکیبات مختلف تعداد نورون‌ها، تابع فعالسازی و Dropout استفاده کرده‌اند [۲۷]. در بخش داخلی، مطالعات انگشت‌شماری در حوزه کاربرد معماری‌های مختلف یادگیری عمیق در مباحث مالی انجام شده است منجمله پژوهش شوشتریان و همکاران در سال ۱۳۹۷ که سعی در پیش‌بینی قیمت فلزات گرانبها با استفاده از دو روش LSTM و RNN داشتند [۱۶]. همچنین آقای دامی (۱۳۹۶) با استفاده از بازنمایی‌های عددی و متنی با روش LSTM اثرات زمانی وقایع گذشته را بر روی قیمت‌های موجود بررسی کرده است [۹].

سوالات پژوهش

۱. پیش‌بینی قیمت سهام در بورس تهران با استفاده از معماری‌های مختلف مدل LSTM چگونه

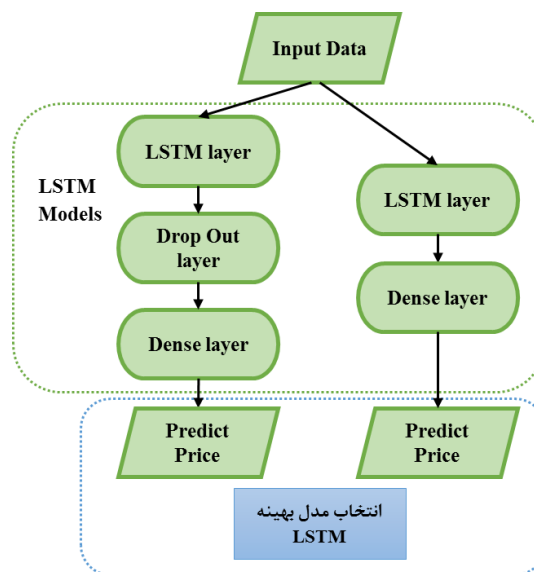
است؟

ارزیابی و اعتبارسنجی معماری بهینه.../شریف‌فر، خلیلی عراقی، رئیسی وانانی و فلاح

۲. کدام معماری LSTM عملکرد بهتری در پیش‌بینی قیمت سهام دارد؟
۳. عملکرد معماری‌های منتخب مدل LSTM در مقایسه با مدل RNN چگونه است؟

چارچوب نظری

بررسی پژوهش‌های مرتبط با پیش‌بینی قیمت سهام با استفاده از مدل LSTM نشان می‌دهد عموماً از دو معماری (لایه‌چینی) به شرح نمودار ذیل استفاده شده است که در این پژوهش نیز هر دو معماری مورد بررسی قرار گرفته است [۲۷،۳۵،۳۰].



شکل ۲: مدل انتخاب معماری منتخب LSTM

برای انتخاب معماری بهینه LSTM نیاز است که هر دو مدل استفاده شده با پارامترهای مختلف مورد بررسی قرار گیرد؛ لازم به ذکر است پارامترهای تاثیرگذار در ساخت معماری بهینه LSTM شامل مواردی نظیر تعداد نورون‌ها^{۱۶} در لایه LSTM، اندازه دسته^{۱۷} و تابع فعال‌سازی^{۱۸} می‌باشد؛ به عنوان مثال تعداد کم نورون‌ها باعث ایجاد خطای بیشتری می‌شود و شبکه همگرا نمی‌شود و از طرفی تعداد نورون‌های زیاد به دلیل ایجاد بیش‌برازش منجر به خطای بالا می‌شود [۶]؛ از این رو موارد مذکور با توجه به خروجی اخذ شده بهینه‌سازی گردیده است. انتخاب پارامترهای مختلف بر اساس نتایج تحقیقات انجام شده در این حوزه می‌باشد [۲۷،۳۴،۴۳].

جدول ۳: پارامترهای مختلف مورد استفاده در اجرای مدل

پارامتر	مقادیر
تعداد نرون (N)	۲۵۶، ۱۲۸، ۶۴
Batch Size	۱۲۸، ۶۴، ۳۲
optimizer	Adam
Loss	Mean Square Error

جدول ۴: توابع فعال‌سازی مورد استفاده در اجرای مدل

توابع فعال‌سازی	رابطه ریاضی
تابع یکسو ساز (Relu)	$g(z) = \max(0, z)$
تانژانت هیپربولیک	$g(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$

جهت اجرای مدل، داده‌ها به دو بخش داده‌های آموزش (۸۰ درصد) برای ساخت مدل و داده‌های آزمایش (۲۰ درصد) برای آزمون مدل استفاده شده است؛ همچنین جهت بهتر شدن فرآیند یادگیری، مرحله آموزش هر مدل به تعداد ۵۰ مرتبه تکرار^{۱۹} گردیده است. علاوه بر این، باید توجه داشت که تفاوت مقیاس‌ها در متغیرهای مختلف، نتایج را تحت تاثیر قرار می‌دهد که معمولاً برای از بین بردن تاثیر نامطلوب مذکور، نرمال‌سازی داده انجام می‌شود. در این تحقیق برای نرمال‌سازی از روش کمینه - بیشینه^{۲۰} برای تبدیل داده‌ها به مجموعه جدید که در آن همه مقادیر بین ۰ و ۱ است، از رابطه زیر استفاده شده است:

$$Z = \frac{X - Min}{Max - Min}$$

که در آن Z مقدار نرمال شده بین ۰ و ۱ است.

روش شناسی پژوهش

این پژوهش از نظر هدف، کاربردی، از نظر روش گردآوری اطلاعات توصیفی - پیمایشی و پس رویدادی است. همچنین از نظر ابزارهای گردآوری اطلاعات، کتابخانه‌ای می باشد و بدلیل ماهیت مدل‌سازی و پیش‌بینی، از نوع پژوهش استقرایی است. مدل‌سازی در این پژوهش بر اساس داده‌های مربوط به سهام پذیرفته شده در بورس اوراق بهادار تهران صورت گرفته است، از این رو جامعه تحقیق شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران می‌باشد؛ از این میان، سهام شرکت ذوب آهن اصفهان به دلیل حجم معاملات روزانه نسبتاً بالا در مقایسه با سایر شرکت‌ها و همچنین درصد سهام شناور آزاد مناسب برای تحلیل انتخاب شده است. قلمرو زمانی متغیرهای ورودی بازه بین سال‌های ۱۳۹۶-۱۳۹۸ و بصورت روزانه می‌باشد.

در این پژوهش مجموعه متغیرهای داده‌های قیمتی از نرم‌افزار TseClient، مجموعه متغیرهای

ارزیابی و اعتبارسنجی معماری بهینه.../شریف‌فر، خلیلی عراقی، رئیسی وانانی و فلاح

داده‌های معاملات سهامداران حقیقی و حقوقی از سایت Tsetmc، همچنین شاخص‌های تکنیکال با استفاده از داده‌های قیمتی و بر اساس پژوهش‌های کارا (۲۰۱۱) و پاتل (۲۰۱۵) به شرح جدول ذیل محاسبه گردیده است [۳۳،۳۸] و در نهایت جهت طراحی مدل از نرم افزار Python نسخه ۳.۸ همراه با توابع کتابخانه‌ای کراس استفاده شده است.

جدول ۵: معادلات شاخص‌های تکنیکالی

نام شاخص	نحوه محاسبه
Weighted 10-day moving average	$\frac{(10)C_t + (9)C_{t-1} + \dots + C_{t-9}}{n + (n-1) + \dots + 1}$
Momentum	$C_t - C_{t-9}$
Stochastic K%	$\frac{C_t - LL_{t-(n-1)}}{HH_{t-(n-1)} - LL_{t-(n-1)}} \times 100$
Stochastic D%	$\frac{\sum_{i=0}^{n-1} K_{t-i}}{10} \%$
Relative strength index (RSI)	$100 - \frac{100}{1 + \left(\frac{\sum_{i=0}^{n-1} UP_{t-i}}{n} \right) / \left(\frac{\sum_{i=0}^{n-1} DW_{t-i}}{n} \right)}$
Moving average convergence divergence (MACD)	$MACD(n)_{t-1} + \frac{2}{n+1} \times (DIFF_t - MACD(n)_{t-1})$
MACD Signal	$\left(MACD * \frac{2}{n+1} \right) + (Signal_{prev} * \left(1 - \frac{2}{n+1} \right))$
Larry William's R%	$\frac{H_n - C_t}{H_n - L_t} \times 100$
On Balance Volume (OBV)	$OBV_{prev} + \begin{cases} volume, & \text{if close} > close_{prev} \\ 0, & \text{if close} = close_{prev} \\ -volume, & \text{if close} < close_{prev} \end{cases}$
CCI (Commodity channel index)	$\frac{M_t - SM_t}{0.015D_t}$

H_t آخرین قیمت در زمان t C_t بالاترین قیمت در زمان t

LL_t, HH_t کمینه و بیشینه قیمت در t روز آخر L_t پایین‌ترین قیمت در زمان t

upward price change (UP_t) تغییرات قیمت صعودی در زمان t

downward price change (DW_t) تغییرات قیمت نزولی در زمان t

$$EMA(k)_t = EMA(k)_{t-1} + \alpha \times (C_t - EMA(k)_{t-1})$$

A عامل تعدیل شده است که برابر عبارت $\frac{2}{k+1}$ بطوری که k میانگین متحرک نمایی k روزه است.

$$M_t = \frac{H_t + L_t + C_t}{3} \quad SM_t = \frac{(\sum_{i=1}^n M_{t-i+1})}{n} \quad D_t = \frac{(\sum_{i=1}^n |M_{t-i+1} - SM_t|)}{n}$$

تجزیه و تحلیل داده‌ها

جهت انتخاب معماری بهینه LSTM، هر دو معماری معرفی شده در مدل با پارامترهای مختلف اجرا شده است و در نهایت بهترین نتایج حاصل از هر معماری مقایسه گردیده است؛ بنابراین معماری منتخب حاصل از اجرای الگوریتم به تعداد ۳۶ دفعه با لایه‌ها و پارامترهای متفاوت می‌باشد.

الف. معماری اول LSTM

در این قسمت، مدل LSTM با معماری لایه های ذیل اجرا شده است.



در جداول زیر خطاهای میانگین قدرمطلق درصد خطا (MAPE^۱) و مجذور میانگین مربعات خطا (nRMSE^۲) در اجرای مدل به تعداد ۱۸ دفعه با استفاده از جایگشت‌های مختلف تعداد نورون‌ها (N) و اندازه دسته و استفاده از دو تابع فعال‌سازی relu و tanh آورده شده است:

جدول ۷: خطای اجرای هر مدل به تفکیک پارامترهای tanh مختلف با تابع فعال‌سازی

تعداد نورون			نوع خطا	تابع فعال‌سازی tanh	
۲۵۶	۱۲۸	۶۴		۳۲	۶۴
%۳,۴۳	%۲,۰۶	%۲,۲۸	MAPE	۳۲	اندازه دسته
%۳,۹۶	%۲,۶۱	%۲,۷۱	nRMSE		
%۱,۷۸	%۱,۶۶	%۲,۱۳	MAPE	۶۴	
%۲,۱۸	%۲,۰۷	%۲,۶۶	nRMSE		
%۱,۸۵	%۱,۷۱	%۲,۱۱	MAPE	۱۲۸	
%۲,۳۲	%۲,۲۷	%۲,۶۸	nRMSE		

جدول ۶: خطای اجرای هر مدل به تفکیک پارامترهای relu مختلف با تابع فعال‌سازی

تعداد نورون			نوع خطا	تابع فعال‌سازی relu	
۲۵۶	۱۲۸	۶۴		۳۲	۶۴
%۳,۴۹	%۳,۶۹	%۲,۰۷	MAPE	۳۲	اندازه دسته
%۴,۰۶	%۴,۳۴	%۲,۵۱	nRMSE		
%۲,۰۰	%۲,۴۷	%۲,۶۷	MAPE	۶۴	
%۲,۴۶	%۲,۸۸	%۳,۴۲	nRMSE		
%۱,۸۰	%۲,۱۴	%۲,۴۰	MAPE	۱۲۸	
%۲,۲۶	%۲,۵۶	%۲,۸۴	nRMSE		


با توجه به نتایج بدست آمده از اجرای مدل در قسمت الف، ترکیب پارامترهای N=۱۲۸ و Batch size=۶۴ بهترین دقت پیش‌بینی را دارد.

ب. معماری دوم LSTM (با لحاظ لایه Dropout)



ارزیابی و اعتبارسنجی معماری بهینه.../شریف‌فر، خلیلی عراقی، رئیسی وانانی و فلاح

از معایب مربوط به شبکه‌های عصبی عمیق، مشکل بیش‌برازش^{۲۳} و زمان محاسباتی بالا است. شبکه‌های عصبی عمیق در معرض بیش‌برازش هستند چون تعداد لایه‌های اضافه شده این امکان را ایجاد می‌کند که وابستگی‌های ناپاب در داده‌های آموزشی مدل شود. با استفاده از روش Dropout می‌توان به از بین بردن بیش‌برازش کمک نمود؛ در این شیوه درصد مشخصی از واحدها به صورت تصادفی از لایه‌های مخفی حذف می‌شود. این کار به از بین بردن وابستگی‌های نادر در داده‌های آموزشی کمک می‌کند [۶]. شکل زیر نحوه عملکرد لایه Dropout را نشان می‌دهد.



شکل ۳: عملکرد لایه Dropout (منبع: [۴۰])

نتایج اجرای مدل LSTM با لحاظ کردن لایه Dropout به شرح جدول ذیل است.

جدول ۹: خطای اجرای هر مدل به تفکیک پارامترهای \tanh مختلف با تابع فعالسازی

تعداد نورون			نوع خطا	تابع فعالسازی tanh	اندازه دسته
۲۵۶	۱۲۸	۶۴			
٪۱،۷۴	٪۲،۴۰	٪۱،۸۳	MAPE	۳۲	
٪۲،۱۲	٪۲،۶۵	٪۲،۴۷	nRMSE		
٪۱،۹۶	٪۲،۱۷	٪۲،۱۲	MAPE	۶۴	
٪۲،۶۵	٪۳،۰۰	٪۲،۴۴	nRMSE		
٪۲،۰۴	٪۲،۵۸	٪۲،۵۲	MAPE	۱۲۸	
٪۲،۶۳	٪۲،۹۴	٪۳،۳۲	nRMSE		

جدول ۸: خطای اجرای هر مدل به تفکیک پارامترهای relu مختلف با تابع فعالسازی

تعداد نورون			نوع خطا	تابع فعالسازی relu	اندازه دسته
۲۵۶	۱۲۸	۶۴			
٪۱،۷۴	٪۱،۹۲	٪۲،۰۸	MAPE	۳۲	
٪۲،۱۸	٪۲،۵۶	٪۲،۷۳	nRMSE		
٪۱،۵۶	٪۱،۴۷	٪۱،۹۳	MAPE	۶۴	
٪۱،۸۴	٪۱،۷۸	٪۲،۴۲	nRMSE		
٪۲،۳۳	٪۱،۸۳	٪۲،۰۸	MAPE	۱۲۸	
٪۳،۰۴	٪۲،۴۵	٪۲،۵۵	nRMSE		

با توجه به نتایج بدست آمده از اجرای مدل با معماری دوم، ترکیب پارامترهای $N = 128$ و $\text{Batch size} = 64$ با تابع فعالسازی relu بهترین دقت پیش‌بینی را دارد؛ و همانگونه که مشخص است خطای بدست آمده با پارامترهای مذکور از نتایج منتخب معماری اول به مراتب بهتر است.

ارزیابی عملکرد

در بخش‌های قبلی اشاره گردید الگوریتم LSTM که حالت خاصی از الگوریتم RNN است درصدد برطرف کردن مشکل مدل مذکور که همان محو شدگی گرادیان هست می‌باشد. در این بخش جهت ارزیابی عملکرد با استفاده از معیارهای MAPE و nRMSE مدل‌های منتخب معماری اول، دوم LSTM با مدل RNN مقایسه شده است.

جدول ۱۰: مقایسه خطای اجرای مدل‌های منتخب

نام مدل	نوع خطا	
	MAPE	nRMSE
RNN	٪۲,۳۷	٪۲,۷۲
منتخب معماری اول LSTM	٪۱,۶۶	٪۲,۰۷
منتخب معماری دوم LSTM	٪۱,۴۷	٪۱,۷۸

همانطور که از جدول بالا مشخص است دقت مدل منتخب معماری دوم LSTM نسبت به مدل‌های دیگر بالاتر می‌باشد؛ همچنین مقادیر nRMSE برای هر سه مدل کمتر از سطح ۰,۰۵ می‌باشد که نشان از برازش مناسب مدل‌های مذکور دارد [۲۱].

در ادامه به منظور بررسی رابطه میان مقدار واقعی قیمت سهام و مقدار پیش‌بینی شده از ضریب همبستگی پیرسون استفاده شده است که نتایج آن در جدول ذیل آورده شده است؛ با توجه به اینکه سطح معنی‌داری برای هر سه مدل از سطح خطای ۰,۰۵ کمتر است وجود همبستگی بین مقدار واقعی قیمت سهام و مقدار پیش‌بینی شده به لحاظ آماری مورد تایید قرار گرفته است.

جدول ۱۱: ضریب همبستگی پیرسون میان مقدار واقعی قیمت سهام و مقدار پیش‌بینی شده

نام مدل	RNN	منتخب معماری اول LSTM	منتخب معماری دوم LSTM
ضریب همبستگی پیرسون	۰,۹۴۷	۰,۹۳۲	۰,۹۸۲
سطح معنی‌داری	۰,۰۰۰	۰,۰۰۰	۰,۰۰۰
تعداد داده آزمایش	۹۱	۹۱	۹۱

نظر به اینکه براساس نتایج جدول شماره ۱۰، مدل منتخب معماری دوم LSTM نسبت به مدل‌های دیگر عملکرد بهتری داشته است، در ادامه نتایج حاصل از اجرای این مدل به شرح ذیل آورده شده است:

ارزیابی و اعتبارسنجی معماری بهینه.../شریف‌فر، خلیلی عراقی، رئیسی وانانی و فلاح

جدول ۱۲: ساختار معماری منتخب LSTM

Model: "sequential"


Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, ۱۲۸)	۷۷۳۱۲
dropout (Dropout)	(None, ۱۲۸)	۰
dense (Dense)	(None, 1)	۱۲۹

Total params: ۷۷,۴۴۱

Trainable params: ۷۷,۴۴۱


Non-trainable params: ۰

با تکرار ۵۰ مرتبه بهینه‌سازی، فرآیند کاهش خطا در مرحله آموزش در قالب نمودار زیر آمده است:



شکل ۴: فرآیند کاهش خطا برای مرحله آموزش در مدل منتخب LSTM

در ادامه نمودار قیمت واقعی سهام شرکت ذوب آهن اصفهان به همراه قیمت پیش‌بینی به تفکیک داده‌های آموزش و آزمایش نشان داده شده است:



شکل ۵: داده‌های واقعی قیمت سهام شرکت ذوب آهن اصفهان به همراه نمودار پیش‌بینی با استفاده از مدل منتخب

بحث و نتیجه‌گیری

یکی از مهمترین عواملی که در کارکرد یک مدل پیش‌بینی اثرگذار است انتخاب متغیرهای ورودی مناسب است؛ و چنانچه یک مدل با استفاده از داده‌های مناسب آموزش داده شود می‌تواند عملکرد درستی داشته باشد؛ لذا در خصوص پیش‌بینی قیمت سهام نیز انتخاب عوامل موثر بر قیمت اهمیت بسزایی دارد، در این پژوهش ضمن بررسی تحقیقات گذشته در این حوزه، مولفه‌های تاثیرگذار بر قیمت سهام شرکت‌ها در شش گروه اصلی طبقه‌بندی شده است که شامل عوامل بنیادی شرکت، عوامل فنی، داده‌های قیمتی، عوامل کلان اقتصادی، عوامل روانشناسی و رفتاری و در نهایت عوامل مرتبط با معاملات سهامداران حقیقی و حقوقی می‌باشد.

شایان ذکر است یکی از مهمترین عواملی که بر قیمت سهام در بازار سرمایه ایران اثرگذار است و در پژوهش‌های گذشته مورد غفلت واقع شده است تحرکات سهامداران حقیقی و حقوقی است. بررسی روند گذشته قیمت سهام بسیاری از شرکت‌ها نشان می‌دهد عواملی نظیر حمایت سهامدار حقوقی از سهام یک شرکت و یا ورود سهامدار حقیقی با حجم و قدرت بالا می‌تواند محرک رشد قیمت سهام باشد و یا برعکس آن فروش سهام توسط سهامدار حقوقی باعث افت قیمت گردد. در پژوهش حاضر مواردی که می‌تواند این عامل - معاملات سهامداران حقیقی و حقوقی - را بررسی نماید مورد توجه قرار گرفته و متغیرهایی نظیر سرانه حجم خرید و فروش سهامداران حقیقی و حقوقی و همچنین تغییر مالکیت از سهامداران حقیقی به حقوقی در طی یک جلسه معاملاتی، به همراه داده‌های قیمتی و شاخص‌های تکنیکال به عنوان ورودی مدل استفاده شده است.

انتخاب مدل مناسب جهت پیش‌بینی قیمت سهام همواره از حوزه‌های بحث‌برانگیز و مورد توجه پژوهشگران بوده است. به موازات انواع روش‌های مختلف مورد استفاده، محققان حوزه یادگیری ماشینی نیز با استفاده از الگوریتم‌های متنوع موجود در این بخش سعی در پیش‌بینی قیمت داشته‌اند. یادگیری ماشینی به مفهوم مطالعه الگوریتم‌های کامپیوتری می‌باشد که بر اساس تجربه می‌آموزند و پیشرفت می‌کنند. یادگیری عمیق گونه‌ای از الگوریتم‌های یادگیری ماشینی است که شامل چندین لایه پردازش اطلاعات است که به الگوریتم توانایی بیشتری را با داده‌ها می‌دهد. مهمترین مزیت الگوریتم‌های یادگیری عمیق همانند الگوریتم حافظه کوتاه‌مدت ماندگار (LSTM) نسبت به مدل سنتی شبکه عصبی، استخراج خودکار ویژگی‌های مناسب از ورودی‌های خام می‌باشد که از آن برای روند یادگیری مدل استفاده می‌کند [۳۶]. LSTM که نوع خاصی از شبکه عصبی بازگشتی (RNN) است توانایی یادگیری وابستگی‌های بلندمدت در طول زمان را دارد؛ در پژوهش حاضر از دو معماری مختلف LSTM با ترکیب

ارزیابی و اعتبارسنجی معماری بهینه.../شریف‌فر، خلیلی عراقی، رئیسی وانانی و فلاح

پارامترهای مختلف جهت انتخاب الگوریتم بهینه پیش‌بینی قیمت استفاده شده است؛ بررسی‌ها نشان داد پارامترهای تاثیرگذار در ساخت معماری بهینه LSTM شامل مواردی نظیر تعداد نوروها در لایه LSTM، اندازه دسته و تابع فعال‌سازی می‌باشد؛ از این رو در مرحله اول با استفاده از ترکیبات مختلف پارامترهای مذکور (بررسی ۱۸ ترکیب مختلف)، مقادیر بهینه برای هر معماری بدست آمد و در مرحله نهایی مقایسه نتایج حاصل از هر دو معماری نشان داد از بین ۳۶ ترکیب مورد بررسی، در نهایت معماری LSTM همراه با لایه Dropout با پارامترهای $N = 128$ ، $\text{Batch size} = 64$ و با تابع فعال‌سازی relu عملکرد بهتری نسبت به مدل ساده آن دارد؛ علاوه بر این منتخب هر دو معماری LSTM، عملکرد بهتری نسبت به مدل RNN داشتند. شایان ذکر است به منظور بررسی رابطه میان مقدار واقعی قیمت سهام و مقدار پیش‌بینی شده از ضریب همبستگی پیرسون استفاده شده است و تحلیل مقدار nRMSE نشان از برازش مناسب مدل منتخب دارد.

پیشنهادها و محدودیت‌ها

با توجه عملکرد مناسب مدل پیشنهادی در پژوهش حاضر، محققین می‌توانند در بررسی‌های آینده به ارزیابی مدل مذکور در طیف گسترده‌تری از سهام شرکت‌ها و همچنین بازه‌های زمانی مختلف بپردازند؛ همچنین علاوه بر پیش‌بینی قیمت یک سهم، می‌توان از روش پیشنهادی این پژوهش جهت پیش‌بینی انواع شاخص استفاده کرد و با شناسایی عوامل اقتصادی موثر بر شاخص جهت تعیین ورودی‌های مناسب مدل بهره برد.

در این پژوهش عملکرد معماری‌های مختلف الگوریتم LSTM بررسی شده است و در نهایت نتایج حاصل از معماری بهینه بدست آمده با الگوریتم RNN مقایسه گردیده است؛ محققین می‌توانند در پژوهش‌های آتی عملکرد مدل پیشنهادی را با سایر روش‌های هوش مصنوعی مقایسه نمایند.

باتوجه به محدودیت امکان استفاده از متغیرهای متعدد در داده‌های ورودی، در این تحقیق نهایتاً از ۲۲ متغیر ورودی استفاده شده که در قالب سه گروه اصلی داده‌های قیمتی، شاخص‌های تکنیکال و معاملات سهامداران حقیقی و حقوقی طبقه‌بندی شده‌اند؛ در بررسی‌های آتی محققین می‌توانند با توجه به دسته‌بندی ارائه شده در این پژوهش از طیف دیگری از متغیرهای ورودی جهت پیش‌بینی قیمت سهام استفاده نمایند و نتایج را مقایسه نمایند.

منابع

- ۱) احمدخان بیگی سهیل، عبدالوند ندا. پیش‌بینی قیمت سهام با رویکرد ترکیبی شبکه عصبی مصنوعی و الگوریتم رقابت استعماری مبتنی بر تئوری آشوب. راهبرد مدیریت مالی (۱۳۹۶)
- ۲) باباجان، جعفر؛ تقوا، محمدرضا؛ بولو، قاسم؛ عبدالهی، محسن. پیش‌بینی قیمت سهام در بورس تهران با استفاده از شبکه عصبی بازگشتی بهینه شده با الگوریتم کلونی زنبور عسل مصنوعی. راهبرد مدیریت مالی. (۱۳۹۸)
- ۳) بدیعی حسین، رضازاده روح اله، محمودی هادی. پیش‌بینی رفتار قیمتی سهام در بورس اوراق بهادار با استفاده از شبکه‌ی عصبی مصنوعی. مجله مهندسی مالی و مدیریت اوراق بهادار. (۱۳۹۶)
- ۴) بهرامی آسو، همه خانی صادق. استفاده از شبکه عصبی برای پیش‌بینی روند قیمت سهام. فصلنامه مطالعات مدیریت و حسابداری. (۱۳۹۵)
- ۵) بیات علی، باقری زینب. پیش‌بینی قیمت سهام با استفاده از الگوریتم کرم شب تاب (FA). دانش مالی تحلیل اوراق بهادار. (۱۳۹۶)
- ۶) پورذاکر عربانی سودابه، ابراهیم پور کومله حسین. بهینه‌سازی پیش‌بینی تقاضای وجه نقد دستگاه‌های خودپرداز شبکه بانکی کشور با استفاده از شبکه عصبی بازگشتی عمیق LSTM. ۱۳۹۸. مجله تحقیق در عملیات در کاربردهای آن. سال شانزدهم
- ۷) حافظی رضا، شهرابی جمال، هداوندی اسماعیل. توسعه‌ی مدل ترکیبی هوشمند برای پیش‌بینی بازار سهام تهران. مجله تحقیق در عملیات و کاربردهای آن (۱۳۹۲)
- ۸) حیدری زارع بهزاد، کردلوئی حمیدرضا. پیش‌بینی قیمت سهام با استفاده از شبکه عصبی مصنوعی. فصلنامه مدیریت. شماره ۱۷ بهار ۱۳۸۹
- ۹) دامی سینا، خدابخش جوینانی فاطمه، پیش‌بینی بازار سهام با استفاده از یادگیری عمیق بازنمایی‌های عددی و متنی. کنفرانس ملی دانش و فناوری نوین در علوم مهندسی در عصر تکنولوژی (۱۳۹۶)
- ۱۰) راعی رضا، چاوشی کاظم؛ پیش‌بینی بازده سهام در بورس اوراق بهادار تهران: مدل شبکه عصبی مصنوعی و مدل چندعاملی؛ دانشکده مدیریت دانشگاه تهران. سال ۵ - شماره ۱۵ (۱۳۸۲)
- ۱۱) رفیعی فاطمه، زهرابی زهره. پیش‌بینی قیمت بازار سهام با استفاده از ابزار هوشمند شبکه عصبی. کنفرانس بین‌المللی جامع علوم مهندسی در ایران. (۲۰۱۶)

ارزیابی و اعتبار سنجی معماری بهینه... / شریف‌فر، خلیلی عراقی، رئیسی وانانی و فلاح

- ۱۲) ساده احسان، احتشام راثی رضا، شیدایی نرمیقی علی. مدل فازی عصبی با ترکیب الگوریتم ژنتیک جهت پیش بینی قیمت سهام در صنعت خودرو در بورس اوراق بهادار تهران. مجله مهندسی مالی و مدیریت اوراق بهادار (۱۳۹۶)
- ۱۳) سارنج، علیرضا؛ قدس، مجید؛ تهرانی، رضا. پیشبینی شاخص کل بورس اوراق بهادار تهران با استفاده از رویکرد ترکیبی الگوریتم های فراابتکاری، هوش مصنوعی و معادله پارامتریک موجه. مهندسی مالی و مدیریت اوراق بهادار. (۱۳۹۷)
- ۱۴) سعیدی علی، رامشه منیژه. عوامل تعیین کننده ریسک سیستماتیک سهام در بورس اوراق بهادار تهران. مجله پژوهش های حسابداری مالی. (۱۳۹۰)
- ۱۵) سینایی حسنعلی، مرتضوی سعیدالله، تیموری اصل یاسر. پیش بینی شاخص بورس اوراق بهادار تهران با استفاده از شبکه های عصبی مصنوعی. بررسی های حسابداری و حسابرسی. (۱۳۸۴)
- ۱۶) شوشتریان بیژن، زاهدی اسماعیل، یزدی نژاد محسن، هرمزان ساره. پیش بینی قیمت فلزات گرانبها با استفاده از الگوریتم های یادگیری عمیق. کنفرانس بین المللی نوآوری و تحقیق در علوم مهندسی. گرجستان - تفلیس (۱۳۹۷)
- ۱۷) طلوعی اشلقی عباس، حق دوست شادی. مدل سازی پیش بینی قیمت سهام با استفاده از شبکه عصبی و مقایسه آن با روشهای پیش بینی ریاضی. پژوهش های اقتصادی (۱۳۸۶)
- ۱۸) عاملی احمد، رضانی ملیحه. پیش بینی قیمت سهام با استفاده از شبکه عصبی فازی مبتنی بر الگوریتم ژنتیک و مقایسه با شبکه عصبی فازی. فصلنامه تحقیقات مدل سازی اقتصادی (۱۳۹۴)
- ۱۹) قائمی محمدحسین، طوسی سعید. بررسی عوامل موثر بر بازده سهام عادی شرکت های پذیرفته شده در بورس اوراق بهادار تهران. چشم انداز مدیریت بازرگانی (۱۳۸۵)
- ۲۰) قلی زاده محمدحسن، وحیدپور قاسم، پیش بینی قیمت سهام با روش رگرسیون فازی. پژوهشنامه علوم اقتصادی (۱۳۹۰)
- ۲۱) کیانی ماوی رضا، صیادی نیک کامران. کاربرد الگوریتم های مختلف یادگیری در پیش بینی قیمت سهام با استفاده از شبکه عصبی. مدیریت توسعه و تحول (۱۳۹۳)
- ۲۲) لاری دشت بیاض محمود، محمدی شعبان. یک شبکه عصبی مصنوعی منظم بیزی برای پیش بینی بازار سهام. پژوهش حسابداری (۱۳۹۵)

فصلنامه مهندسی مالی و مدیریت اوراق بهادار / شماره چهل و هشتم / پاییز ۱۴۰۰

- ۲۳) مهرآرا محسن، معینی علی، احراری مهدی، هامونی امیر. الگوسازی و پی شبینی شاخص بورس اوراق بهادار تهران و تعیین متغیرهای مؤثر بر آن. فصلنامه پژوهش‌ها و سیاست‌های اقتصادی. (۱۳۸۸)
- ۲۴) مکیان سیدنظام الدین، موسوی فاطمه السادات. پیش‌بینی قیمت سهام شرکت فرآورده‌های نفتی پارس با استفاده از شبکه عصبی و روش رگرسیون. فصلنامه مدل‌سازی اقتصادی. (۱۳۹۱)
- ۲۵) منجمی امیرحسین، ابزری مهدی و رعیتی شوازی علیرضا. پیش‌بینی قیمت سهام در بازار بورس اوراق بهادار با استفاده از شبکه‌ی عصبی فازی و الگوریتم‌های ژنتیک و مقایسه‌ی آن با شبکه‌ی عصبی مصنوعی. فصلنامه اقتصاد مقداری (۱۳۸۸)
- ۲۶) نیکو مهلا؛ مقایسه توانایی مدل‌های یادگیری ماشینی در پیش‌بینی شاخص قیمت سهام بورس اوراق بهادار تهران. پایان‌نامه کارشناسی ارشد، دانشگاه ارومیه، (۱۳۹۷)

- 27) Do-Hyung Kwon, Ju-Bong Kim, Ju-Sung Heo, Chan-Myung Kim and Youn-Hee Han; (2019) "Time Series Classification of Cryptocurrency Price Trend Based on a Recurrent LSTM Neural Network" Journal Of Information Processing Systems.
- 28) Ding, X; Zhang, Y; Liu, T; Duan, J; (2015) "Deep learning for event-driven stockprediction", IJCAI
- 29) Deng, L.; Yu, D; (2014). "Deep Learning: Methods and Applications". Foundations and Trends in Signal Processing. 7(3-4): 1-199
- 30) Gao Penglei, Zhang Rui, Yang Xi; (2020) "The Application of Stock Index Price Prediction with Neural Network." Mathematical and Computational Applications
- 31) Hao Yaping, Qiang Gao; (2020) "Predicting the Trend of Stock Market Index Using the Hybrid Neural Network Based on Multiple Time Scale Feature Learning." Applied science.
- 32) Hiransha M, E.A. Gopalakrishnan, Vijay Krishna Menon, and K.P. Soman; (2018) "Nse stock market prediction using deep-learning models." Procedia Computer Science, 132:1351-1362
- 33) Kara, Y, Acar Boyacioglu, M., & Baykan, Ö. K; (2011) "Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul stock exchange. Expert systems with Application.
- 34) Kim Tae-Young, Cho Sung-Bae; (2019) "Predicting residential energy consumption using CNN-LSTM neural networks" Energy: 72-81
- 35) Livieris I, Pintelas E, Pintelas P; (2020) "A CNN-LSTM model for gold price time-series forecasting" Neural Computing and Applications

- 36) O.B. Sezer, M.U. Gudelek and A.M. Ozbayoglu; (2020) "Financial time series forecasting with deep learning: A systematic literature review: 2005–2019", Applied Soft Computing Journal
- 37) O.B. Sezer, A.M. Ozbayoglu; (2018) "Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach." Applied Soft Computing Journal
- 38) Patel Jigar, Sahil Shah, Priyank Thakkar, K Kotecha; (2015) "Predicting stock market index using fusion of machine learning techniques. " Expert Systems with Applications
- 39) Sang I Lee and Seong Joon Yoo; (2018) "Threshold-based portfolio: the role of the threshold and its applications." The Journal of Supercomputing, September.
- 40) Thomaidis, N; (2007), "Efficient Statistical Analysis of Financial Time-Series using Neural Networks and GARCH models", PP: 2-6
- 41) Taewook, K; Ha Young, K; (2019). Forecasting stock prices with a feature fusion LSTM-CNN model using different representations of the same data. Technology Advancement Research
- 42) Xiaoa C, Chena N, Chuli Hue, Ke Wange, Jianya Gong, Zeqiang Chen; (2019) "Short and mid-term sea surface temperature prediction using time-series satellite data and LSTM-AdaBoost combination approach". Remote Sensing of Environment
- 43) Zhang T, Song S, Shugang Li, Li Ma, Shaobo Pan and Liyun Han; (2019) "Research on Gas Concentration Prediction Models Based on LSTM Multidimensional Time Series" Energies
- 44) Zhou, X; Pan, Z; Guyu Hu, Tang, S and Cheng, Z; (2018) "Stock market prediction on highfrequency data using generative adversarial nets." Mathematical Problems in Engineering: 1–11

-
- 1 Long Short-Term Memory
 - 2 Deep Learning
 - 3 Recurrent Neural Network
 - 4 Fundamental Analysis
 - 5 Technical Analysis
 - 6 Chartist
 - 7 Vanishing gradient
 - 8 gate
 - 9 Memory blocks
 - 10 Input gate
 - 11 Output gate
 - 12 Forget gate
 - 13 Cell state
 - 14 Multilayer Perceptron
 - 15 Convolutional Neural Network
 - 16 Neurons
 - 17 Batch Size
 - 18 Activation Function
 - 19 Epochs
 - 20 Min-Max normalization
 - 21 Mean Absolute Percentage Error
 - 22 Normalized Root Mean Square Error
 - 23 Over Fitting