





دانشگاه صنعتی شاهرود

دانشکده مهندسی صنایع و مدیریت

ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از شبکه عصبی

پایان نامه برای دریافت درجه کارشناسی ارشد
رشته مدیریت صنعتی گرایش تولید و عملیات

نگارنده:

علیرضا شجاعیان

استاد راهنما:

دکتر مجتبی غیائی

مهر ۱۴۰۰

خدایا اکنون نشانم ده که چگونه علم و دانش را، خردمندانه و عاشقانه به کار گیرم، راهی بیابم که در هر ذره ای که می‌نگرم جز جمال تو چیزی نبینم.

پروردگارا از اینکه توانی دادی تا از پایگاه دانش خویش دفاع کنم بسیار خرسندم و خواهان آنم تا توانی دهی تا حضورت را با تمام وجودم حس کنم که چه آرامشی است دانستن اینکه همیشه در کنارم هستی، حتی نزدیک‌تر از رگ گردن.

چشم به راه آن دمم، که سرافرازانه در پیشگاه تو از تز آدمیت دفاع کنم.

تقدیم به امام زمان (روحی و ارواحنا له الفدا). تقدیم به محمد رسول الله، فخر آدمیان،

تقدیم به حضرت امیر و فرزندان پاکش علیهم السلام، تقدیم به روح شهیدان.

تقدیم به استادان و معلمان عزیزم از ابتدای تحصیل تا به امروز، که به من درس مرام و

معرفت، درس حرمت و احترام، صبر و استقامت و امید آموختند.

تقدیم به کسی که حس با او بودن و با او زیستن امیدبخش ادامه راهم خواهد بود.

تقدیم به:

همسر عزیزم

تشکر و قدردانی:

به رسم ادب بر خود واجب می‌دانم که از، زحمات استاد راهنمای عزیز جناب آقای دکتر مجتبی غیاثی و کلیه اساتید و کارکنان عزیزی که در تمام مراحل این پایان نامه به هر شکلی راهنمایی‌ها و مساعدت‌هایشان روشن‌گر راهمان بوده تشکر و قدردانی کنیم. باشد که بتوانیم زحماتشان را به ثمر بنشانیم.

از مسئولین محترم آموزش گروه نیز تشکر ویژه داریم.

تعهد نامه

اینجانب **علیرضا شجاعیان** دانشجوی دوره کارشناسی ارشد رشته مدیریت صنعتی گرایش تولید و عملیات دانشگاه صنعتی شاهرود نویسنده پایان نامه با موضوع **ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از شبکه عصبی تحت راهنمایی دکتر مجتبی غیائی متعهد می-شوم:**

- تحقیقات در این پایان نامه توسط اینجانب انجام شده است و از صحت و اصالت برخوردار است.
- در استفاده از نتایج پژوهش های محققان دیگر به مرجع مورد استفاده استناد شده است.
- مطالب مندرج در پایان نامه تاکنون توسط خود یا فرد دیگری برای دریافت هیچ نوع مدرک یا امتیازی در هیچ جا ارائه نشده است.
- کلیه حقوق معنوی این اثر متعلق به دانشگاه صنعتی شاهرود می باشد و مقالات مستخرج با نام « دانشگاه صنعتی شاهرود » و یا « Shahrood University of Technology » به چاپ خواهد رسید.
- حقوق معنوی تمام افرادی که در به دست آمدن نتایج اصلی پایان نامه تأثیرگذار بوده اند در مقالات مستخرج از پایان نامه رعایت می گردد.
- در کلیه مراحل انجام این پایان نامه، در مواردی که از موجود زنده (یا بافتهای آنها) استفاده شده است ضوابط و اصول اخلاقی رعایت شده است.
- در کلیه مراحل انجام این پایان نامه، در مواردی که به حوزه اطلاعات شخصی افراد دسترسی یافته یا استفاده شده است اصل رازداری، ضوابط و اصول اخلاق انسانی رعایت شده است.

تاریخ: ۱۴۰۰/۰۷/۲۶

امضا دانشجو

مالکیت نتایج و حق نشر

کلیه حقوق معنوی این اثر و محصولات آن (مقالات مستخرج، کتاب، برنامه های رایانه ای، نرم افزار ها و تجهیزات ساخته شده است) متعلق به دانشگاه صنعتی شاهرود می باشد. این مطلب باید به نحو مقتضی در تولیدات علمی مربوطه ذکر شود. استفاده از اطلاعات و نتایج موجود در پایان نامه بدون ذکر مرجع مجاز نمی باشد.

چکیده

امروزه با توجه به رقابت بالای بازارهای جهانی و نوآوری در فن آوری، مسئله اندازه گیری کارایی سازمان ها تبدیل به یک مسئله جهانی شده است. یکی از مرسوم ترین روش های اندازه گیری کارایی، تحلیل پوششی داده ها است. ولی مشکلاتی مانند حساس بودن به مرز کارایی و عدم قدرت پیش بینی را دارد که یکی از روش های برطرف کردن این مشکلات ترکیب آن با شبکه عصبی مصنوعی است.

شبکه های عصبی مرز کارایی مقاوم تر و انعطاف پذیرتر نسبت به تحلیل پوششی داده ها دارد و از آن می توان در حل مسائل با مقیاس بزرگتر نیز استفاده کرد.

هدف این پژوهش ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از شبکه عصبی است. در این پژوهش سعی شده برای سری زمانی داده شده، پس از آماده کردن داده ها، مقادیر بهینه پارامترهای فضای فاز از جمله تاخیر زمان، بدست آورده شود، سپس با ایجاد یک ماتریس ورودی از داده های سری زمانی و ساختاری مناسب برای شبکه پیش بینی کننده، مدل سازی و پیش بینی سری های زمانی انجام گردد. در این راستا دو مدل پیشنهادی بر پایه روش های غیرخطی برای پیش بینی سری های زمانی ارائه شده است. مدل اول شبکه عصبی خودبرگشتی غیرخطی با ورودی های برونزاد و مدل دوم شبکه های عصبی، شبکه سیستم استنتاج عصبی - فازی سازگار است. به منظور داشتن معیاری برای مقایسه از میانگین مربعات خطا استفاده کرده ایم. در نهایت بررسی و ارزیابی نتایج، نشان دهنده ساختار مناسب مدل های مورد استفاده و استفاده از فضای فازی در افزایش دقت مدل سازی و پیش بینی سری های زمانی موثر می باشد و در عین حال عملکرد مدل شبکه عصبی - فازی تا حد قابل توجهی بهتر از مدل عصبی تاخیر زمانی می باشد. نتایج حاکی از آن است که شبکه های عصبی تاخیر زمانی و عصبی - فازی می توانند به عنوان ابزار های مدل سازی قابل اعتماد برای پیش بینی عملکرد مورد استفاده قرار گیرند.

واژه های کلیدی: کارایی، تحلیل پوششی داده ها، شبکه های عصبی مصنوعی، بورس اوراق بهادار، شبکه عصبی خودبرگشتی غیرخطی با ورودی های برونزاد

فهرست مطالب

فصل ۱: مقدمه	۱
۱-۱- مقدمه	۲
۲-۱- بیان مسئله	۴
۳-۱- ضرورت و اهمیت انجام تحقیق	۶
۴-۱- اهداف، فرضیات و یا سوالات تحقیق	۷
۵-۱- قلمرو تحقیق (موضوعی، مکانی و زمانی)	۸
۶-۱- اصطلاحات تخصصی پژوهش	۹
فصل ۲: روش شناسی و پیشینه پژوهش	۱۱
۱-۲- مقدمه	۱۲
۲-۲- تاریخچه شبکه های عصبی	۱۴
۳-۲- آشنایی با مدل نورون ها	۱۵
۴-۲- معرفی شبکه عصبی مصنوعی	۱۷
۵-۲- چرا از شبکه های عصبی استفاده می کنیم؟	۲۰
۱-۵-۲- مزایای شبکه های عصبی	۲۰
۲-۵-۲- معایب شبکه های عصبی	۲۱
۳-۵-۲- کاربرد شبکه های عصبی	۲۱
۶-۲- ساختار شبکه های عصبی مصنوعی	۲۲
۷-۲- انواع آموزش شبکه عصبی مصنوعی	۲۴
۱-۷-۲- وزن ثابت	۲۴
۲-۷-۲- آموزش بدون نظارت-یادگیری خود سامانده	۲۴
۳-۷-۲- آموزش تحت نظارت	۲۵
۴-۷-۲- آموزش تقویتی	۲۵
۸-۲- توابع تحریک مورد استفاده در شبکه های عصبی	۲۵
۹-۲- بایاس و ترشیلد	۲۹
۱۰-۲- مسائل مناسب برای یادگیری شبکه های عصبی	۳۰
۱۱-۲- شبکه های عصبی پرسپترون چند لایه	۳۰
۱۲-۲- خصوصیات شبکه های عصبی پرسپترون چند لایه	۳۲
۱-۱۲-۲- خروجی پرسپترون (یادگیری)	۳۲
۲-۱۲-۲- نقش تابع در خروجی شبکه	۳۳
۳-۱۲-۲- توانایی پرسپترون	۳۳
۴-۱۲-۲- توابعی که پرسپترون قادر به یادگیری آنها می باشد	۳۳
۵-۱۲-۲- آموزش پرسپترون	۳۴
۱-۵-۱۲-۲- قانون پرسپترون	۳۵

۳۵	۲-۱۲-۵-۲- قانون دلتا
۳۸	۲-۱۲-۶- شبکه های چند لایه
۳۹	۲-۱۲-۷- شبکه های پس انتشار
۴۲	۲-۱۲-۸- یادگیری تطبیقی
۴۲	۲-۱۲-۹- روش های تعیین ضرایب شبکه عصبی (روش های بهینه سازی)
۴۲	۲-۱۲-۹-۱- روش های کلاسیک
۴۳	۲-۱۲-۹-۲- روش های هوشمند
۴۴	۲-۱۲-۱۰- تعیین تعداد نوروں های لایه پنهان
۴۴	۲-۱۳- شبکه عصبی تاخیر زمانی
۴۶	۲-۱۴- سیستم استنتاج عصبی - فازی انطباقی (ANFIS)
۵۱	۲-۱۴-۱- معیارهای ارزیابی مدل های پیش بینی
۵۳	۲-۱۵- تحلیل پوششی داده ها
۵۳	۲-۱۵-۱- مفهوم تحلیل پوششی داده ها
۵۴	۲-۱۵-۲- مزایای تحلیل پوششی داده ها
۵۵	۲-۱۵-۳- معایب تحلیل پوششی داده ها
۵۵	۲-۱۵-۴- مدل های پایه ای تحلیل پوششی داده ها
۵۶	۲-۱۵-۵- مدل های BCC خروجی محور
۵۶	۲-۱۶- مدل ترکیبی شبکه عصبی و تحلیل پوششی داده ها
۵۸	۲-۱۷- پیشینه پژوهش
۵۹	۲-۱۷-۱- پیشینه داخلی
۶۱	۲-۱۷-۲- پیشینه خارجی

فصل ۳: تجزیه و تحلیل داده ها ۶۵

۶۶	۳-۱- مقدمه
۶۶	۳-۲- معیارهای مناسب برای مقایسه مدل های ترکیبی
۶۷	۳-۳- تعیین ورودی ها و خروجی های مناسب به منظور ارزیابی کارایی شرکت های بورس اوراق بهادار
۶۷	۳-۴- مطالعه موردی
۷۰	۳-۵- ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از تحلیل پوششی داده ها
۷۳	۳-۶- ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از شبکه عصبی
۷۳	۳-۶-۱- انتخاب مناسب ترین مدل ترکیبی تحلیل پوششی داده ها و شبکه های عصبی به منظور پیش بینی و ارزیابی کارایی
۷۴	۳-۶-۱-۱- پیش بینی کارایی توسط شبکه های عصبی بازگشتی به نام مدل های خودبرگشتی غیرخطی با ورودی های برونزاد

۳-۶-۱-۲- پیش بینی کارایی توسط شبکه های عصبی- فازی یا سیستم استنتاج عصبی-
فازی سازگار.....۸۲

فصل ۴: نتایج و پیشنهادات ۸۹

- ۴-۱- بحث و نتیجه گیری.....۹۰
- ۴-۱-۱- نتایج حاصل از شبکه های عصبی خودبرگشتی غیر خطی با ورودی های برونزاد
(NARX).....۹۰
- ۴-۱-۲- نتایج شبکه های عصبی سیستم استنتاج عصبی- فازی سازگار (ANFIS).....۹۱
- ۴-۲- جمع بندی و پیشنهادات.....۹۲
- ۴-۳- محدودیت های پژوهش.....۹۳

منابع ۹۵

فهرست اشکال

۱	فصل ۱: مقدمه
۱۱	فصل ۲: روش شناسی و پیشینه پژوهش
۱۶	شکل (۱-۲) یک نورون زیستی ساده.....
۱۹	شکل (۲-۲) یک شبکه عصبی ساده.....
۲۲	شکل (۳-۲) ساختار شبکه عصبی.....
۲۶	شکل (۴-۲) تابع تحریک خطی.....
۲۶	شکل (۵-۲) تابع تحریک hardlimit.....
۲۷	شکل (۶-۲) تابع تحریک لگاریتمی.....
۲۸	شکل (۷-۲) تابع تحریک tansig.....
۲۸	شکل (۸-۲) تابع تحریک شعاع مبنا.....
۲۸	شکل (۹-۲) تابع تحریک hardlimit متقارن.....
۲۹	شکل (۱۰-۲) تابع تحریک satlins.....
۳۱	شکل (۱۱-۲) شبکه پرسپترون با یک لایه پنهان.....
۳۲	شکل (۱۲-۲) شبکه پرسپترون.....
۳۳	شکل (۱۳-۲) توانایی پرسپترون.....
۳۴	شکل (۱۴-۲) توابع قابل یادگیری پرسپترون.....
۳۶	شکل (۱۵-۲) گرادیان نزولی.....
۳۸	شکل (۱۶-۲) شبکه دو لایه.....
۳۹	شکل (۱۷-۲) سلول واحد سیگموئید.....
۴۳	شکل (۱۸-۲) توابع آموزش.....
۴۶	شکل (۱۹-۲) ساختار نورون ها.....
۴۷	شکل (۲۰-۲) روال استدلال فازی در مدل سوگنوی درجه اول.....
۴۹	شکل (۲۱-۲) ساختار سیستم استنتاج عصبی - فازی انطباقی (ANFIS).....
۶۵	فصل ۳: تجزیه و تحلیل داده ها
۷۷	شکل (۱-۳) شبکه عصبی دو لایه با اختصاص ۷۰ درصد داده ها به آموزش.....
۷۸	شکل (۲-۳) عملکرد شبکه عصبی دو لایه با اختصاص ۷۰ درصد داده ها به آموزش.....
۷۹	شکل (۳-۳) نمودار رگرسیون و خطای مربوط به تمام داده ها.....
۷۹	شکل (۴-۳) نمودار رگرسیون و خطای مربوط به داده های آموزش.....
۸۰	شکل (۵-۳) نمودار رگرسیون و خطای مربوط به داده های اعتبار.....
۸۰	شکل (۶-۳) نمودار رگرسیون و خطای مربوط به داده های آزمایش.....
۸۳	شکل (۷-۳) ساختار شبکه عصبی سیستم استنتاج عصبی - فازی سازگار.....
۸۴	شکل (۸-۳) نمودار رگرسیون تمام داده ها.....

- شکل (۹-۳) نمودار خطای مربوط به تمام داده ها ۸۵
- شکل (۱۰-۳) نمودار خطای مربوط به داده های آموزش ۸۵
- شکل (۱۱-۳) نمودار خطای مربوط به داده های آزمایش ۸۶

فصل ۴: نتایج و پیشنهادات ۸۹

منابع ۹۵

فهرست جداول

فصل ۱: مقدمه	۱
فصل ۲: روش شناسی و پیشینه پژوهش	۱۱
جدول (۱-۲) خلاصه ای از مدل های شبکه عصبی با آموزش با ناظر	۵۲
فصل ۳: تجزیه و تحلیل داده ها	۶۵
جدول (۱-۳) داده های ورودی ۲۰ شرکت اول بورس اوراق بهادار	۶۸
جدول (۲-۳) داده های خروجی ۲۰ شرکت اول بورس اوراق بهادار	۶۹
جدول (۳-۳) محاسبه کارایی با استفاده از DEA از سال ۱۳۸۸ تا ۱۳۹۲	۷۱
جدول (۴-۳) محاسبه کارایی با استفاده از DEA از سال ۱۳۹۳ تا ۱۳۹۷	۷۲
جدول (۵-۳) محاسبه کارایی با استفاده از شبکه عصبی NARX	۸۱
جدول (۶-۳) محاسبه کارایی با استفاده از شبکه عصبی سیستم استنتاج عصبی - فازی سازگار	۸۷
جدول (۷-۳) مقایسه عملکرد انواع شبکه های عصبی	۸۸
فصل ۴: نتایج و پیشنهادات	۸۹
منابع	۹۵

فصل ۱:

مقدمه

۱-۱- مقدمه

با توجه به فضای رقابتی امروزه جهان، پیچیدگی محیط کسب و کار و افزایش انتظارات مشتریان، نیاز به آگاهی از نقاط قوت و ضعف سازمان و بهبود مستمر بهره‌وری به طور فزاینده‌ای آشکار شده است. بنابراین، یکی از دغدغه‌های اصلی سازمان‌های امروزی دستیابی به یک روش ارزیابی جامع، قابل اعتماد و انعطاف پذیر و استفاده از آن برای به دست آوردن اطلاعات دقیق و کافی از موقعیت فعلی آنها و نگاه به آینده تا از اشتباهات گذشته درس بیاموزند [۶].

اهمیت موضوع اندازه‌گیری عملکرد در سازمان‌ها آنقدر مهم تلقی می‌شود، که کارشناسان معتقدند "آنچه را که نمی‌توان اندازه‌گیری کرد نمی‌توان مدیریت کرد". بر این اساس، روش‌ها و تکنیک‌های زیادی در اندازه‌گیری عملکرد ارائه شده است، اما آنچه مهمتر است این است که یک نگاه سیستماتیک به مسئله عملکرد در سازمان داشته باشیم [۱].

کارشناسان و مدیران برای ارزشیابی عملکرد سازمان خود از معیارهای مختلفی مانند اثربخشی، کارایی^۱، کیفیت، سودآوری، بهره‌وری و ... استفاده می‌کنند [۱۲]. کارایی یکی از معیارهای اساسی برای ارزیابی عملکرد سازمان است و به سادگی نسبت خروجی یک مجموعه به ورودی آن را نشان می‌دهد. اگر مجموعه دارای یک ورودی و یک خروجی باشد، اندازه‌گیری عملکرد آن ساده است، اما با افزایش تعداد ورودی‌ها و خروجی‌ها، اندازه‌گیری عملکرد بسیار مشکل خواهد بود. در این راستا مدل تحلیل پوششی داده‌ها^۲ ارائه شد که قابلیت محاسبه و تحلیل کارایی واحدهای سازمانی را با توجه به ورودی‌ها و خروجی‌های مختلف دارد [۱۴]. در این شیوه با استفاده از برنامه ریزی خطی، محدودیت کارایی واحدهای مختلف به عنوان استاندارد عملکرد تعیین می‌شود و عملکرد واحدها نسبت به آنها به عنوان درجه‌ای از کارایی اندازه‌گیری و مشخص می‌شود. این روش واحدهای مورد مطالعه را به دو گروه واحدهای کارآمد و واحدهای ناکارآمد تقسیم می‌کند. واحدهای کارآمد واحدهایی هستند که دارای بازدهی برابر با یک هستند. واحدهای ناکارآمد را می‌توان با کسب امتیاز کارایی رتبه بندی کرد، اما واحدهایی که دارای نمره کارایی برابر یک هستند، نمی‌توان با استفاده از

^۱ Performance

^۲ Data Envelopment Analysis (DEA)

مدل های کلاسیک تحلیل پوششی داده ها رتبه بندی و پیش بینی کرد [۲]. لذا، باید برای افزایش وضوح و تفکیک پذیری تجزیه و تحلیل پوششی داده ها از روش دیگری استفاده نماییم. به تازگی از شبکه های عصبی مصنوعی^۱ به عنوان جایگزینی برای برآورد مرزهای کارآمد برای تصمیم گیری استفاده شده است [۱۹].

روش ارزیابی عملکرد شرکت های بورس اوراق بهادار با کمک گرفتن از روش های غیر پارامتریک بسیار حائز اهمیت است. تحلیل پوششی داده ها و تحلیل پوششی داده های شعاعی^۲ (DEA-R) با استراتژی های ساختن مرز تابع تولید به صورت قطعه ای خطی و با استفاده از داده های در دسترس شرکت های بورس را ارزیابی می کنند، و شبکه های عصبی به برآورد مرزهای کارایی کمک می کند. اگرچه روش تجزیه و تحلیل پوششی داده ها در تعیین حد عملکرد موفق بوده است، اما چندین معایب دارد. یکی از مشکلات اصلی در استفاده از تحلیل پوششی داده ها، عدم تفکیک تصمیم گیرندگان است. این ضعف اغلب به دلیل تعداد کم واحدها در مقایسه با تعداد ورودی ها و خروجی- های مدل است [۳۰]. در نتیجه، ارزیابی عملکرد با استفاده از تحلیل پوششی داده ها، به طور کلی ارزیابی عملکرد یک را به تعداد زیادی از واحدها اختصاص می دهد و برخی از ارزیابی عملکردها ممکن است یکسان یا نزدیک به یکدیگر باشند.

با این حال، محدودیت عملکرد DEA به اشکالات آماری و داده های پرت ناشی از خطاهای اندازه گیری یا سایر عوامل خارجی حساس است. در صورت سردرگمی آماری یا تحریف داده ها، ممکن است مرز کارایی به دست آمده جابجا شود و مسیر تحلیل های DEA را منحرف سازد [۳۰]. DEA روشی است که قابلیت و توانایی پیش بینی را ندارد. ما از شبکه های عصبی برای افزایش قدرت پیش بینی استفاده می کنیم. در این مورد، اطلاعات عمومی تعیین کننده است. این بدان معناست که شبکه عصبی محدودیت عملکرد را بر اساس همه اطلاعات و نه برخی اطلاعات زیاد یا خیلی کم می یابد [۲۸]. و انحرافات نتایج را منحرف نمی کند.

وجود این مشکلات به تازگی شبکه های عصبی مصنوعی را به جایگزین مناسبی برای برآورد مرزهای کارآمد برای تصمیم گیری تبدیل کرده است، زیرا عملکرد شبکه های عصبی به دلیل قدرت یادگیری و تعمیم پذیری به گونه ای است که در برابر داده های پرت و اغتشاشات حاصل از اندازه گیری

^۱ Artificial Neural Network (ANN)

^۲ Radial

غیردقیق داده‌ها انعطاف پذیرتر عمل می‌نماید [۲۰]. شبکه‌های عصبی همچنین عملکرد بالایی در برآورد توابع تولید دارند. آنها در محیط‌های غیرخطی بهتر کار می‌کنند و هنگام تخمین مرز بهره‌وری فرضیات کمی در مورد شکل عملکرد، تولید می‌کنند [۱۳]. با توجه به ثبات و انعطاف پذیری الگوریتم‌های مدل‌سازی، مدل‌های شبکه عصبی دارای پتانسیل بالایی برای طبقه‌بندی شرکت‌های فهرست شده هستند [۳۰].

مدل ترکیبی تحلیل پوششی داده‌ها و شبکه‌های عصبی مصنوعی برای ارزیابی کارایی شرکت‌های حاضر در بورس اوراق بهادار در این مطالعه استفاده شده است. فصل اول مسئله مورد مطالعه را تعریف می‌کند و نیاز و هدف تحقیق را نشان می‌دهد. فصل دوم روش تحقیق، نمونه‌گیری جامعه‌ای و ابزار جمع‌آوری داده‌ها را ارائه می‌دهد و فصل سوم اطلاعات را تجزیه و تحلیل می‌کند. در فصل آخر نتایج تحقیق توضیح داده شده و با ادبیات و پیشینه تحقیق مقایسه می‌شود. همچنین محدودیت‌های تحقیق را ذکر کرده و در پایان پیشنهادات عملی برای مطالعات آینده ارائه می‌دهد.

۱-۲- بیان مسئله

به سبب افزایش رقابت در بازارهای امروزی، جهانی شدن، نوآوری‌های تکنولوژیکی و حذف نظارت دولت، اندازه‌گیری کارایی در سطح واحد به یک موضوع جهانی تبدیل شده است.

از اساسی‌ترین اطلاعاتی که مبنای تصمیم‌گیری‌ها و قضاوت استفاده‌کنندگان از اطلاعات مالی را تشکیل می‌دهد کارایی است و پیش‌بینی درست کارایی می‌تواند نقش موثری در ایجاد تصمیم‌های درست داشته باشد، به همین دلیل پیش‌بینی کارایی به یکی از موضوعات مورد علاقه استفاده‌کنندگان از اطلاعات مالی تبدیل شده است.

سرمایه‌گذاران برای افزایش سرمایه خود در بازار بورس اوراق بهادار سرمایه‌گذاری می‌کنند. در این بین برخی به اهداف خود رسیده و برخی سرمایه خود را از دست می‌دهند. برای پیش‌بینی بهتر از آینده بازار بورس اوراق بهادار و تغییرات آن، کاهش ریسک سرمایه‌گذاری و یا افزایش بازده بیشتر، شناخت جنبه‌ها و زوایای مختلف آن اهمیت دارد [۸]؛ به همین دلیل محققان در تلاش برای یافتن معیار عملکردی هستند که به کمک آن بتوانند، کارایی و تغییرات آن را با نزدیک‌ترین تقریب پیش‌بینی کنند. چرا که معمولاً کارایی یک شرکت تأثیر مستقیمی بر بازده و ثروت سهام‌داران دارد و اگر تصمیم‌گیرندگان بازار اوراق بهادار به طریقی کارایی شرکت را پیش‌بینی کنند خواهند توانست

شرکت های با بازدهی بالا را شناسایی و ثروت خود را حداکثر کنند [۱۶]، سرمایه گذاران برای افزایش بازدهی سهام خود در پی فرصت هستند. با توجه به اینکه سرمایه گذاران دارایی های نقد خود را به اوراق بهادار تبدیل می کنند، عدم توجه به یکسری از عوامل نتایج مطلوبی را برای آنها در پی نخواهد داشت [۲۲].

اطلاعات خروجی سیستم حسابداری، وظیفه ارائه اطلاعات صحیح و مربوط در مورد ارزیابی عملکرد شرکت ها را بر عهده گرفته و از مهمترین پارامترها در تصمیم گیری های اقتصادی گردانندگان بازارهای مالی و سرمایه محسوب می شود و سرمایه گذاران می توانند به اطلاعات سیستم های حسابداری اتکا کنند [۹]؛ در واقع حسابداری به عنوان یک سیستم اطلاعاتی که دارای محصولاتی جهت دستیابی به یک سری از اهداف می باشد مطرح است که یکی از این اهداف، فراهم آوردن اطلاعات برای سرمایه گذاران و تحلیل گران برای کمک به آنها در پیش بینی کارایی و بازده سهام شرکت ها است و اگر اطلاعات حسابداری برای تبیین بازده سودمند باشد، در آن صورت تغییرات در داده های حسابداری باید سبب تغییر در بازده و کارایی سهام شرکت ها شود، حال این سرمایه گذاران می توانند با ایجاد پل ارتباطی بین کارایی شرکت ها و سایر اطلاعات حسابداری به پیش بینی بازده سهام بپردازند. منوط به اینکه اطلاعات حسابداری بر روی قیمت تاثیرگذار باشد یا به معنای دیگر بازار از لحاظ کارایی در سطح قوی قرار داشته باشد.

در این راستا شناسایی و معرفی اطلاعات حسابداری مرتبط جهت پیش بینی کارایی و همچنین استفاده از روش های کارای پیش بینی در جهت راهنمایی سرمایه گذاران و تحلیل گران مالی امری ضروری به نظر می رسد.

غالباً به دو روش اصلی پارامتریک و ناپارامتریک مطالعات ارزیابی عملکرد گروه بندی می شوند [۲۷]. متداول ترین روش پارامتری رویکرد مرزی تصادفی^۱ (SFA) است. متداول ترین روش غیر پارامتری، تحلیل پوششی داده ها است.

تحلیل پوششی داده ها یک روش غیر پارامتری برای ارزیابی عملکرد نسبی واحدهای تصمیم گیری^۲ (DMU) با چندین ورودی و خروجی است. دو مدل معروف DEA، مدل CCR^۳ با فرض بازده به

^۱ Stochastic Frontier Approach (SFA)

^۲ Decision Making Unit (DMU)

^۳ Charnes, Cooper and Rohdes (CCR)

مقیاس ثابت و مدل BCC^۱ با فرض بازده به مقیاس متغیر ساخته شده است [۲۶]. اگرچه روش تجزیه و تحلیل پوششی داده ها در تعریف مرز عملکرد موفق بوده است، اما چندین اشکال نیز دارد. یکی از مشکلات اصلی استفاده از تجزیه و تحلیل پوششی داده ها ضعف تفکیک پذیری و ناتوانی در پیش-بینی واحدهای تصمیم گیرنده است. این ضعف اغلب به دلیل تعداد کم واحدها در مقایسه با تعداد ورودی ها و خروجی های مدل است [۲۷]. این بدان معناست که در ارزیابی عملکرد با کمک تحلیل پوششی داده ها، تعداد زیادی نمره عملکرد یک به تعداد زیادی از واحدها اختصاص داده می شود. همچنین ممکن است برخی از نمرات کارایی یکسان یا نزدیک به هم شود.

همچنین DEA توانایی پیش بینی ندارد. ما از شبکه های عصبی برای افزایش قدرت پیش بینی استفاده می کنیم. در این مورد، اطلاعات عمومی تعیین کننده است [۳۰]. این بدان معناست که شبکه عصبی بر اساس همه اطلاعات و نه برخی اطلاعات بیش از حد یا بسیار کم، محدوده عملکردی را می یابد [۳۰].

در این پژوهش علاوه بر روش تحلیل پوششی داده از شبکه های عصبی مصنوعی به دلیل انعطاف پذیری بیشتر، قابلیت مدل سازی سیستم های غیرخطی، شناسایی الگو، قابل یادگیری بودن یعنی توانایی تنظیم وزن های شبکه و قابلیت تعمیم برای پیش بینی کارایی استفاده شده است و در نهایت پیش بینی ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از شبکه عصبی انجام می پذیرد.

۱-۳- ضرورت و اهمیت انجام تحقیق

یکی از مهمترین عوامل رشد و توسعه بنگاه های اقتصادی کارایی و بهره وری است، تا اندازه ای که رسیدن به سطح مطلوبی از آن، رمز ماندگاری بنگاه ها در محیط رقابتی کنونی است [۱۴]. در رشد اقتصادی هر کشوری، رشد کارایی و بهره وری بخش های مختلف کشور تاثیر گذار می باشد. ارتقای کارایی، به عنوان یکی از منابع مهم تامین رشد اقتصادی کشورها و افزایش رقابت پذیری بنگاه مورد توجه می باشد. به گونه ای که کشورهای پیشرفته و در حال توسعه موفق، بخش قابل ملاحظه ای از رشد اقتصادی خود را از این طریق به دست آورده اند [۲۱].

در شکل گیری انگیزش کارکنان و رسیدن به اهداف بلند مدت و کوتاه مدت موسسه، فایده مندی

^۱ Banker, Charnes, Cooper (BCC)

ارزیابی کارایی و همچنین نقش بازخوردی آن در تخصیص بهینه منابع روشن است، بنابراین بنگاه-های اقتصادی در تلاش هستند تا با ارزیابی کارایی، تصویر واضحی از منابع تحت اداره خود ارائه کنند. در این پژوهش با استفاده از شبکه عصبی و DEA الگوریتمی پیشنهاد می شود که : ۱- طبقه بندی شرکت های حاضر در بورس را رقم می زند. ۲- در ماهیت ورودی در تکنولوژی بازده به مقیاس ثابت و ناکاهشی، مقیاس کارایی با استفاده از مدل های پوششی را براساس هر طبقه با استفاده از شبکه-های عصبی پس انتشار محاسبه می کند. ۳- مقیاس کارایی را با آموزش شبکه عصبی و تکرار، تعیین می کند.

در DEA اگر داده ها، با شلوغی آماری همراه شود مرز بدست آمده از تجزیه و تحلیل ممکن است پنهان شود.

از DEA به سختی می توان برای پیش بینی عملکرد سایر واحد های تصمیم گیری استفاده نمود. در نتیجه شبکه عصبی جایگزین خوبی برای کمک به برآورد مرزهای کارایی برای تصمیم گیرندگان معرفی می شود.

۱-۴- اهداف، فرضیات و یا سوالات تحقیق

ارزیابی کارایی شرکت های پذیرفته شده در بورس هدف از این مطالعه است. با توجه به اینکه تحقیقات قبلی با هدف ارزیابی عملکرد با استفاده از تحلیل پوششی داده ها انجام شده است و اکثر تحقیقات محدود بوده اند و همچنین به دلیل تعداد زیاد شرکت ها برای ارزیابی عملکرد و ضعف تحلیل پوششی داده ها در تعیین دقیق رتبه بندی شرکت های کارآمد و مشکلات بیان شده در این تکنیک در بالا، ما از مدل ترکیبی تجزیه و تحلیل پوششی داده ها و شبکه های عصبی مصنوعی برای بدست آوردن و پیش بینی عملکرد استفاده می کنیم.

با مطالعه دقیق شبکه های عصبی و مدل اساسی تجزیه و تحلیل پوششی داده ها، این تحقیق به دنبال ارائه یک سیستم معادله جدید و حل آن با استفاده از شبکه های عصبی یا تحلیل پوششی داده ها برای ارزیابی کارایی واحدهای تصمیم گیرنده است. استفاده از شبکه های عصبی برای حل مدل اساسی تجزیه و تحلیل پوششی داده ها و همچنین استفاده از شبکه های عصبی برای ارزیابی عملکرد واحدهای تصمیم گیرنده و سپس به دست آوردن کارایی واحدهای تصمیم گیری با استفاده از

شبکه های عصبی.

در این پژوهش ۲۷۹ شرکت از بورس اوراق بهادار از بین سال های ۱۳۸۸ الی ۱۳۹۷ مورد بررسی قرار گرفته اند. ابتدا به کمک تحلیل پوششی داده ها ارزیابی عملکرد شرکت ها انجام می گیرد که در آن داده های ریسک، ضریب بتا و رتبه نقد شوندگی به عنوان ورودی و داده بازده به عنوان خروجی در نظر گرفته می شود. سپس با کمک شبکه عصبی به پیش بینی و ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار می پردازیم.

به طور کلی هدف تحقیق به صورت زیر بیان می شود:

۱- حل دستگاه معادلات خطی با استفاده از شبکه های عصبی ۲- حل دستگاه معادلات خطی با استفاده از تحلیل پوششی داده ها ۳- محاسبه کارایی شرکت های بورس اوراق بهادار با استفاده از تلفیق تحلیل پوششی داده ها و شبکه های عصبی ۴- آرایه الگوی مناسب برای واحد های تصمیم گیرنده با استفاده از تحلیل پوششی داده ها و شبکه های عصبی

پرسش هایی که در این پژوهش به دنبال پاسخ برای آنها می باشیم :

پرسش اصلی:

۱- ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از شبکه عصبی چگونه

خواهد بود؟

پرسش های فرعی:

۱- ورودی ها و خروجی های مناسب برای ارزیابی کارایی شرکت ها کدام است؟

۲- مدل های ترکیبی تحلیل پوششی داده ها و شبکه های عصبی کدام است؟

۳- معیارهای مناسب برای مقایسه مدل های ترکیبی کدام است؟

۴- مناسب ترین مدل ارزیابی کارایی شرکت های حاضر در بورس اوراق بهادار کدام است؟

۱-۵- قلمرو تحقیق (موضوعی، مکانی و زمانی)

در این پژوهش به ارزیابی کارایی شرکت های حاضر در سازمان بورس و اوراق بهادار از سال ۱۳۸۸ تا ۱۳۹۷ با ارائه یک مدل ترکیبی از تحلیل پوششی داده ها و شبکه های عصبی مصنوعی می پردازیم.

۱-۶- اصطلاحات تخصصی پژوهش

کارایی: کارایی عبارت است از نسبت بازده واقعی بدست آمده به بازدهی استاندارد و تعیین شده (مورد انتظار)، یا نسبت مقدار کاری که انجام می شود به مقدار کاری که باید انجام شود. برای رسیدن به کارایی صد در صد باید به وضعیت ایده آل توجه داشت و با فرض اینکه خروجی ایده آل همیشه بیشتر و مساوی خروجی واقعی است، نسبت جدید کارایی نیز، مقداری بین صفر و یک خواهد بود.

تحلیل پوششی داده ها: یک روش برنامه ریزی خطی است که هدف بنیادین آن، مقایسه و ارزیابی کارایی شماری از واحدهای تصمیم گیرنده همسان است.

شبکه های عصبی مصنوعی: نحوه عملکرد مغز انسان را تقلید می کنند و مدل های ریاضی آن بدون نیاز به داشتن مفروضاتی در مورد نوع روابط بین متغیرها، توانایی استخراج الگوهای از داده های مشاهده شده را دارند.

واحدهای تصمیم گیری: به واحدهایی که با استفاده از یک سازو کار مشابه و ورودی های یکسان، خروجی های یکسان تولید می کنند اطلاق می شود.

نسبت میان قیمت و درآمد (P/E):^۱ نسبت میان قیمت و درآمد هر سهم شرکت را، نسبت قیمت به درآمد یا نسبت P/E می نامند.

P/E خلاصه شده نسبت قیمت سهم (P) به درآمد هر سهم (Eps) است.

ضریب بتا: حاکی از میزان ریسکی است که یک سرمایه گذار با خرید سهام، نسبت به کل بازار متحمل می شود.

نحوه محاسبه ضریب بتا: در تفسیر ضریب بتای محاسبه شده برای یک سهم یا سبدی از مجموع سهام مختلف و یا شاخص یک صنعت، مواردی به شرح زیر قابل ذکر است:

- سهامی که ضریب بتای آن برابر با یک باشد، افزایش یا کاهش قیمت آن دقیقاً مطابق با حرکت بازار خواهد بود. در این حالت نوسانات بازدهی سهم منطبق با بازدهی بازار است.
- سهامی که دارای ضریب بتای بزرگتر از یک باشد، به اصطلاح سهم تهاجمی نامیده می شود و افزایش یا کاهش قیمت سهم، بیشتر از افزایش یا کاهش کل بازار است. از این رو نوسانات بازدهی سهم از نوسانات بازار، بیشتر و ریسک بیشتری را به همراه خواهد داشت.

^۱ Price/ Earning Per Share

- اگر ضریب بتا سهم کوچکتر از یک و بزرگتر از صفر باشد، به اصطلاح این سهم را تدافعی می‌نامند و افزایش یا کاهش قیمت سهم کوچکتر از روند کلی بازار خواهد بود. لذا نوساناتی کمتر از نوسانات بازار را تجربه می‌کند و به آن‌ها دارایی کم ریسک گفته می‌شود.
 - سهامی که ضریب بتای آن مساوی صفر باشد، نشان می‌دهد حرکت قیمت سهم هیچ هم بستگی با حرکت بازار و کلیت بازار ندارد و با نوسانات بازار تغییر نمی‌کند.
 - سهم با ضریب بتای کوچکتر از صفر، نشان می‌دهد حرکت قیمت سهم خلاف جهت روند کلی بازار است. به بیان دیگر اگر سهمی بتای منفی داشته باشد، رفتار آن سهم درست عکس رفتار بازار خواهد بود.
- بنابراین برای محاسبه عددی ضریب بتا باید کوواریانس^۱ بین بازدهی دارایی و بازدهی بازار را بر واریانس^۲ بازار تقسیم نماییم.

^۱ Covariance

^۲ Variance

فصل ۲:

روش شناسی و پیشینه پژوهش

این فصل علاوه بر معرفی شبکه های عصبی مصنوعی و ارائه پیشینه تاریخی آنها، انواع مختلف شبکه های عصبی، به ویژه شبکه های پس انتشار و فازی عصبی را توضیح می دهد. در سال های اخیر ما شاهد حرکت مداوم از تحقیقات صرفاً نظری به تحقیقات کاربردی بوده ایم، به ویژه در زمینه پردازش اطلاعات برای مسائلی که برای آن ها راه حلی موجود نیست و یا به راحتی قابل حل نیستند. علاقه به توسعه نظری سیستم های پویای هوشمند براساس داده های تجربی در حال افزایش است. شبکه های عصبی مصنوعی یکی از این سیستم های پویا هستند که با پردازش داده های آزمایشی دانش یا قوانین مخفی داده ها را به ساختار شبکه منتقل می کنند. به همین دلیل است که این سیستم ها هوشمند نامیده می شوند. زیرا آنها قوانین کلی را بر اساس محاسبات مبتنی بر داده ها یا مثال های عددی می آموزند. این سیستم ها سعی می کنند ساختار مغز انسان را مدل کنند [۱۷].

در اینجا این سوال مطرح می شود که شبکه عصبی چیست و چه کاربردی دارد، اگر بگوییم شبکه های عصبی مصنوعی مانند مغز انسان عمل می کنند، اغراق آمیز خواهد بود. هرچه دانشمندان بیشتر مغز انسان را کاوش و یاد بگیرند، بیشتر متوجه می شوند که مغز انسان غیرقابل دسترسی است. در واقع، اطلاعات زیادی در مورد مغز و ساختار سیستم عصبی انسان وجود دارد. اما پیاده سازی ساختاری با پیچیدگی مغز انسان بر اساس اطلاعات و فناوری موجود امروزه غیرممکن است. با این حال، یک شبکه عصبی مصنوعی یک ایده پردازش اطلاعات است که از سیستم عصبی بیولوژیکی الهام گرفته و مانند مغز اطلاعات را پردازش می کند. عنصر اساسی این ایده، ساختار جدید سیستم پردازش اطلاعات است. این سیستم شامل تعداد زیادی عناصر پردازشی بسیار به هم پیوسته است که برای حل یک مشکل با هم کار می کنند. به هر یک از این عناصر فوق پردازشی نورون گفته می شود. شبکه های عصبی، چه از نظر تجزیه و تحلیل ساختاری و چه از نظر پیاده سازی سخت افزار، از نظر کمی و کیفی و قابلیت در حال رشد و تکامل هستند و تکنیک های مختلف محاسبات عصبی همچنان در حال افزایش است. فعالیت های علمی و کاربردی در مسائل مهندسی مانند سیستم های کنترل، پردازش سیگنال و تشخیص الگو گسترش یافته است. مغز به عنوان یک سیستم پردازش اطلاعات با ساختاری موازی و کاملاً پیچیده دو درصد وزن بدن را تشکیل می دهد و بیش از بیست درصد از کل اکسیژن بدن را برای خواندن، تنفس، حرکت، تفکر و کاوش و کلیه اقدامات آگاهانه و بسیاری از

رفتارهای ناخودآگاه استفاده می کند. نورون هایی که می توانند به عنوان عناصر یک برنامه رایانه ای یا شاید به عنوان تراشه های نیمه هادی تلقی شوند. لازم به ذکر است که شبکه های عصبی مصنوعی متشکل از این نورون ها، اگرچه بسیار سریع (یک میلیون بار سریعتر) از نورون های بیولوژیکی هستند، اما تنها بخشی از ظرفیت بالای نورون های بیولوژیکی را دارند. شبکه های عصبی رویکرد متفاوتی نسبت به رایانه های معمولی برای حل مشکلات دارند. رایانه های سنتی از یک مسیر الگوریتمی استفاده می کنند، به این معنی که کامپیوتر یک سری دستورالعمل ها را برای حل یک مشکل دنبال می کند. بدون اطلاع از مراحل خاصی که یک کامپیوتر باید انجام دهد، کامپیوتر نمی تواند مشکل را حل کند. این واقعیت توانایی رایانه های معمولی را برای حل مشکلاتی که ما می توانیم درک کنیم و حل کنیم محدود می کند. اما اگر کامپیوترها بتوانند کارهایی را انجام دهند که ما دقیقاً نمی دانیم چگونه انجام دهیم، بسیار مفید خواهند بود. یک شبکه عصبی اطلاعات را به روشی مشابه مغز انسان پردازش می کند. آنها شامل بسیاری از عناصر پردازشی (سلول های عصبی) هستند که به شدت به هم متصل هستند. این عناصر به طور موازی برای حل یک مشکل خاص کار می کنند. شبکه های عصبی با مثال کار می کنند و نمی توانند برای یک کار خاص برنامه ریزی شوند. نمونه ها باید با دقت انتخاب شوند وگرنه زمان مفید هدر می رود یا بدتر، ممکن است شبکه به درستی کار نکند. مزیت شبکه عصبی این است که می داند چگونه مشکل را حل کند و پاسخ به آن غیرقابل پیش بینی است. از طرف دیگر رایانه های معمولی برای حل یک مشکل مسیر خاصی را در پیش می گیرند. راه حل مشکل باید از قبل شناخته شده و به طور مختصر و واضح شرح داده شود. این دستورات سپس به زبان های برنامه نویسی سطح بالا و سپس به کدی که کامپیوتر می تواند درک کند، ترجمه می شود. به طور کلی، این ماشین ها قابل پیش بینی هستند و اگر مشکلی پیش بیاید به دلیل خرابی سخت افزار یا نرم افزار است. شبکه های عصبی و رایانه های معمولی با یکدیگر رقابت نمی کنند، بلکه مکمل یکدیگر هستند. وظایفی وجود دارد که بیشتر مناسب روش های الگوریتمی هستند، مانند عملیات محاسباتی و وظایفی نیز وجود دارد که بیشتر مناسب شبکه های عصبی هستند. حتی فراتر از آن، مسائلی وجود دارد که برای دستیابی به حداکثر عملکرد به سیستمی نیاز دارد که هر دو روش را ترکیب کند (معمولاً از رایانه های معمولی برای نظارت بر شبکه های عصبی استفاده می شود). شبکه های عصبی معجزه نمی کنند، اما اگر از آنها عاقلانه استفاده شود، نتایج شگفت انگیزی به بار می آورد [۱۷].

۲-۲- تاریخچه شبکه های عصبی

برخی از زمینه های شبکه های عصبی را می توان در اوایل قرن ۲۰ و اواخر قرن ۱۹ جستجو کرد. در این مدت، کارهای اساسی در فیزیک روانشناسی و نرووفیزیولوژی توسط دانشمندانی مانند هرمن فون هلمهلتز^۱، ایوان پاولف^۲، ارنست ماخ^۳ انجام شد. این کار اولیه به طور کلی بر نظریه های کلی یادگیری، بینایی و شرط بندی تأکید داشت و به مدل های ریاضی خاص عملکرد عصبی هیچ اشاره ای نکرد. دیدگاه جدید شبکه های عصبی در قرن بیستم زمانی آغاز شد که وارن مک کلوت و والتر پیتز^۴ نشان دادند که شبکه های عصبی می توانند هر تابع حسابی را محاسبه کنند. می توان کار این افراد را به عنوان نقطه شروع زمینه شبکه های عصبی مصنوعی با دونالد هاب ادامه داد. او فردی بود که شرط بندی کلاسیک پیشنهاد شده توسط پاول را به عنوان ویژگی های نورون ها معرفی کرد و سپس مکانیزمی را برای یادگیری نورون های بیولوژیکی پیشنهاد کرد. اولین کاربرد عملی شبکه های عصبی در اواخر دهه ۱۹۵۰ هنگامی اتفاق افتاد که فرانک روزنبلات^۵ شبکه ای را ایجاد کرد که می توانست الگوها را در سال ۱۹۵۸ تشخیص دهد. در آن زمان بود که برنارد ویدرو^۶ شبکه عصبی تطبیقی خطی آدالاین^۷ را در سال ۱۹۶۰ با یک قانون یادگیری جدید به نام شبکه پرسپترون^۸ از نظر ساختار معرفی کرد. هر شبکه، پرسپترون و آدالاین، محدودیتی برای طبقه بندی الگوهای متمایز خطی داشتند. توسعه شبکه های عصبی تا دهه ۱۹۷۰ ادامه داشت. در سال ۱۹۷۲ تئو کوهونن و جیمز اندرسون^۹ به طور مستقل و ناآگاهانه شبکه های عصبی جدیدی را معرفی کردند که می توانند به عنوان عناصر ذخیره سازی عمل کنند. در دهه ۱۹۸۰، زمانی که فناوری ریزپردازنده در حال افزایش بود، تحقیقات در مورد شبکه های عصبی افزایش یافت و ایده های جدید زیادی پدید آمد. ایده های جدید و فناوری بالا برای احیای شبکه های عصبی، کافی به نظر می رسید.

۱ Hermann Von Helmholtz

۲ Ivan pavlov

۳ Ernst Mach

۴ Warren McCulloch and Walter Pitts

۵ Frank Rosenblatt

۶ Bernard Widrow

۷ Adaline

۸ Perceptron

۹ James Anderson

با این تولد دوباره شبکه های عصبی، دو رویکرد جدید را می توان در نظر گرفت. از مکانیسم تصادفی برای توضیح نحوه عملکرد انواع شبکه های بازخورد استفاده کنید که می تواند برای ذخیره اطلاعات استفاده شود. این ایده در سال ۱۹۸۲ توسط جان هاپفیلد^۱، فیزیکدان آمریکایی، مورد بحث قرار گرفت. دومین ایده مهم که کلید توسعه شبکه های عصبی در دهه ۸۰ شد، الگوریتم «پس انتشار خطا»^۲ می باشد که توسط دیوید راملهارت و جیمز مک لند^۳ در سال ۱۹۸۶ مطرح گردید. با بروز این دو ایده شبکه های عصبی کاربردهای زیادی در رشته های مختلف علوم پیدا کرده اند. شبکه های عصبی در هر دو جهت توسعه نظری و عملی در حال رشد می باشند، اما این روند رشد، آهسته و مطمئن نبوده است؛ دوره هایی بسیار سریع و دوره هایی کند مشاهده شده است. بیشتر پیشرفت ها در شبکه های عصبی مربوط به ساختارهای جدید و روش های جدید یادگیری است. در نتیجه، شبکه های عصبی نه به عنوان پاسخی برای هر مشکلی، بلکه به عنوان یک ابزار علمی که می تواند برای راه حل های خاص و مناسب مورد استفاده قرار گیرد، از جایگاه مهمی برخوردار خواهد بود. لازم به ذکر است که اطلاعات موجود در مورد نحوه عملکرد مغز بسیار محدود است و مهمترین تحولات در شبکه های عصبی در آینده مورد بحث قرار خواهد گرفت. وقتی که اطلاعات بیشتری در مورد نحوه عملکرد مغز و سلول های عصبی در دسترس قرار گیرد [۱۷].

۳-۲- آشنایی با مدل نورون^۴ ها


نورون طبیعی: نورون کوچک ترین واحد پردازش اطلاعات است، که اساس عملکرد شبکه های عصبی را تشکیل می دهد. شکل یک نورون طبیعی در شکل (۲-۱) نمایش داده شده است.

^۱ John Hopfeld

^۲ Error Back – Propagation (BP)

^۳ Daivid Rummelhart and James mcland

^۴ Neuron



شکل (۱-۲) یک نورون زیستی ساده [۱۱].

سه قسمت اصلی هر نورون طبیعی متشکل از: - بدنه سلول^۱ - دندريت^۲ - آکسون^۳ می باشد. دندريت ها به عنوان مناطق دریافت سیگنال های الکتریکی، شبکه های تشکیل یافته از الیاف های سلولی هستند که دارای سطح نامنظم و شاخه های انشعابی بی شمار می باشند. دندريت ها سیگنال های الکتریکی را به هسته سلول منتقل می کنند. بدنه سلول انرژی مورد نیاز برای فعالیت نورون را تأمین می کند و به سیگنال های دریافت شده واکنش نشان می دهد، که با یک عمل ساده مدل سازی شده و با مقدار آستانه مقایسه می شود. برخلاف دندريت ها، آکسون ها سطح صاف تری دارند و شاخه های کمتری دارند. آکسون طولانی تر است و سیگنال های الکتروشیمیایی دریافت شده از هسته سلول را به سایر نورون ها منتقل می کند. اتصال آکسون از یک سلول به دندريت سلول های دیگر سیناپس^۴ نامیده می شود. سیناپس ها ارتباط ما بین نورون ها را ایجاد می کنند. فضای بین آکسون ها و دندريت ها را فضای سیناپسی می نامند. در واقع دندريت ها، ورودی نورون ها و آکسون ها، خروجی و فضای سیناپسی محل اتصال این دو است. وقتی یک سیگنال عصبی از آکسون به سمت نورون ها و دیگر عناصر بدن مانند عضلات حرکت می کند، نورون ها ولتاژ پایینی (از طریق سیگنال های ورودی عصبی) از هر یک از گره های ورودی خود دریافت می کنند و آنها را با هم جمع می کنند. هنگامی که این مقدار به یک آستانه می رسد، نورون شلیک می کند و ولتاژ خروجی را در محور خود ارسال می کند. این کشش به دندريت های آکسون متصل می رسد و باعث ایجاد یکسری فعل و انفعالات شیمیایی در اتصالات سیناپسی می شود که سایر نورون ها می توانند آنها را مشتعل کنند.

۱ Cell body

۲ Dendrite

۳ Axon

۴ Synapse

تمام فعالیت های مغزی انسان توسط این آتش کردن ها انجام می شود. حافظه کوتاه مدت انسان از جرقه های الکتریکی آنی تشکیل شده و حافظه بلند مدت به صورت تغییرات الکتروشیمیایی در اتصالات سیناپسی ذخیره می شود که عموماً منجر به تغییرات یونی می شود. اعتقاد بر این است که مغز انسان تقریباً از تعداد 10^{11} نورون تشکیل شده است که هر نورون به طور متوسط با 10^4 نورون دیگر ارتباط برقرار می کند. سرعت جابجایی نورون ها در حدود ۳ الی ۱۰ ثانیه است و فرد قادر است تصویر انسان را در ۰/۱ ثانیه تشخیص دهد. این قدرت فوق العاده باید از پردازش موازی که بر روی تعداد زیادی نورون توزیع شده است، بدست آید [۲۴].

۲-۴- معرفی شبکه عصبی مصنوعی

شبکه عصبی مصنوعی الهام گرفته از یک الگوی پردازش اطلاعات که از روش های سیستم عصبی بیولوژیکی مانند پردازش اطلاعات مغز، بهره گرفته است. اگر چه شبکه های عصبی مصنوعی از مدل مغز گرفته شده اند، اما زمانی استفاده می شوند که هیچ فرضی در مورد شکل عملکرد وجود نداشته باشد. به این ترتیب شبکه های عصبی مبتنی بر داده ها هستند، و نه براساس مدل. عنصر کلیدی این مدل، ساختاری جدید سیستم پردازش اطلاعات است که شامل تعداد زیادی عناصر پردازش به هم پیوسته (نورون ها) است که برای حل مشکلات خاص کار می کنند. شبکه های عصبی مصنوعی برای کاربردهای خاصی مانند تشخیص الگو، تقریب عملکرد، طبقه بندی داده ها و غیره در زمینه های مختلف علم استفاده می شود.

به طور معمول شبکه های عصبی مصنوعی در سه لایه نورون مرتب گردیده است. این ساختارهای چندگانه ورودی، لایه های مخفی و لایه های خروجی نامیده می شوند. لایه های ورودی، که نورون ها هستند (گره یا واحد پردازش نیز نامیده می شوند)، ورودی های مدل را نشان می دهند. لایه های پنهان، ورودی ها را با وزن ها ترکیب می کنند تا در طول فرایند یادگیری سازگار شوند. لایه خروجی برآوردی را برای شبکه ارائه می دهد. پرسپترون چند لایه به عنوان اساس شبکه عصبی مصنوعی در این مطالعه استفاده شد.

از شبکه های عصبی با توانایی قابل توجه در استنباط معانی از داده های پیچیده یا مبهم، می توان برای استخراج الگوها و شناسایی روش هایی استفاده کرد که دانستن آنها برای انسان و سایر تکنسین-

های کامپیوتر بسیار دشوار است. یک شبکه عصبی آموزش دیده می تواند به عنوان یک متخصص در دسته اطلاعاتی که برای تجزیه و تحلیل به آن داده شده است، در نظر گرفته شود. از این متخصص می توان برای برآورد موقعیت های مورد نظر جدید و پاسخ به سوالات (در صورت وجود) استفاده کرد. از دیگر قابلیت های شبکه های عصبی می توان به موارد زیر اشاره کرد:

یادگیری تطبیقی: توانایی یادگیری نحوه انجام وظایف بر اساس اطلاعات ارائه شده برای تمرین و تجربیات مقدماتی.

خود سازماندهی: یک شبکه عصبی مصنوعی می تواند اطلاعاتی را که در طول دوره یادگیری دریافت می کند، سازماندهی یا ارائه دهد.

تحمل خطا بدون وقفه در رمزگذاری داده ها: خرابی جزئی شبکه منجر به تخریب عملکرد مربوطه می شود، اگرچه برخی از قابلیت های شبکه حتی با آسیب زیاد نیز دست نخورده باقی می ماند [۱۷].

در شبکه های عصبی، با کمک دانش برنامه نویسی، یک ساختار داده طراحی می شود که می تواند مانند یک نورون عمل کند. به این ساختار داده گره گفته می شود. سپس با ایجاد شبکه ای بین این گره ها و اعمال الگوریتم آموزشی بر روی آن، شبکه را آموزش می دهند. در این حافظه یا شبکه عصبی، گره ها دارای دو حالت فعال (روشن یا ۱) و غیرفعال (خاموش یا ۰) هستند و هر لبه (سیناپس یا اتصال بین گره ها) دارای وزن است. لبه های مثبت وزن، گره غیرفعال بعدی را تحریک یا فعال می کند و لبه های منفی وزن، گره متصل بعدی (در صورت فعال بودن) را غیرفعال یا مهار می کند.

شبکه های عصبی مصنوعی در واقع یک سیستم داده پردازای اطلاعات هستند که دارای ویژگی اجزائی خاصی مانند شبکه های عصبی انسانی هستند. شبکه های عصبی مصنوعی برای تعمیم مدل های ریاضی شبکه عصبی انسان بر اساس فرضیه های زیر توسعه یافته اند.

- داده پردازای اطلاعات در اجزای ساده ایی به نام نورون صورت می گیرد.
- اطلاعات بین نورون ها از طریق ارتباط بین آنها صورت می گیرد.
- هریک از این رابطه ها دارای وزن مختص به خود هستند که در اطلاعات انتقال یافته از یک نورون به یک نورون دیگر ضرب می شوند.
- هریک از نورون ها یک تابع تحریک^۱ را که معمولاً غیرخطی است به ورودی هایش (جمع


^۱ Activation Function

اطلاعات وزن دار شده) اعمال می نمایند تا مقدار خروجی از این نورون ها مشخص گردد.

هریک از پارمترهای زیر مشخص کننده خصوصیات یک شبکه عصبی است:

- ساختار شبکه: طریقه ارتباط بین نورون ها را نشان می دهد.
- آموزش شبکه: تعیین مقادیر وزن های رابط نورون ها می باشد.
- تابع تحریک

به عنوان مثال یک شبکه عصبی ساده در شکل (۲-۲) نشان داده شده است.



شکل (۲-۲) یک شبکه عصبی ساده

الهام از طبیعت

- بر اساس مطالعات انجام شده شبکه های عصبی مصنوعی مقدار بسیار زیاد الهام گرفته از سیستم های یادگیری طبیعی است که در آن مجموعه پیچیده ای از نورون های به هم پیوسته در یادگیری نقش دارند.
- تصور می شود که مغز انسان از تعداد 10^{11} نورون تشکیل شده باشد که هر یک تقریباً به 10^4 نورون دیگر متصل است، هر کدام دارای عملکردهای ورودی و خروجی هستند که مغز انسان را به ماهیچه ها متصل می کند یا سیگنال هایی از یک اندام حساس دارد که به مغز منتقل می شود.
- امکان دارد شبکه های عصبی شامل چندین تا چند هزار نورون باشد، اندازه شبکه بستگی به پیچیدگی مشکل دارد [۱۱].

۲-۵- چرا از شبکه های عصبی استفاده می کنیم؟

شبکه های عصبی با توانایی قابل توجه خود در استنتاج نتایج از داده های پیچیده می توانند در استخراج الگوها و شناسایی گرایش های مختلفی که برای انسان ها و کامپیوتر شناسایی آنها بسیار دشوار است استفاده شوند (قابلیت بکارگیری به عنوان یک متخصص).

۲-۵-۱- مزایای شبکه های عصبی

یادگیری تطبیقی :

توانایی یادگیری اینکه چگونه وظایف خود را بر اساس اطلاعات داده شده به آن و یا تجارب اولیه انجام دهد، در واقع اصلاح شبکه را می گویند.

خود سازماندهی :

یک شبکه عصبی مصنوعی به صورت خودکار سازماندهی و ارائه داده هایی که در طول آموزش دریافت کرده را انجام می دهد. نرون ها با قاعده یادگیری سازگار شده و پاسخ به ورودی تغییر می یابد.

عملگرهای بی درنگ :

محاسبات در شبکه عصبی مصنوعی می تواند به صورت موازی و به وسیله سخت افزارهای مخصوصی که طراحی و ساخت آن برای دریافت نتایج بهینه که از قابلیت های شبکه عصبی مصنوعی است، انجام شود.

تحمل خطا :

با ایجاد خرابی در شبکه، مقداری از کارایی کاهش می یابد ولی برخی امکانات آن با وجود مشکلات بزرگ همچنان حفظ می شود.

دسته بندی :

شبکه های عصبی قادر به دسته بندی ورودی ها برای دریافت خروجی مناسب می باشند.

تعمیم دهی :

این خاصیت شبکه را قادر می سازد تا تنها با برخورد با تعداد محدودی نمونه، یک قانون کلی از آن را به دست آورده، نتایج این آموخته ها را به موارد مشاهده از قبل نیز تعمیم دهد. توانایی که در صورت نبود آن سامانه باید بی نهایت واقعیت ها و روابط را به خاطر بسپارد.

پایداری - انعطاف پذیری :

یک شبکه عصبی هم به حد کافی پایدار است تا اطلاعات فراگرفته خود را حفظ کند و هم قابلیت انعطاف و تطبیق را دارد و بدون از دست دادن اطلاعات قبلی می تواند موارد جدید را بپذیرد.

۲-۵-۲- معایب شبکه های عصبی

- قواعد یا دستورات مشخصی برای طراحی شبکه جهت یک کاربرد اختیاری وجود ندارد.
- دقت نتایج بستگی زیادی به اندازه مجموعه آموزش دارد.
- آموزش شبکه ممکن است مشکل یا حتی غیر ممکن باشد.
- پیش بینی عملکرد آینده شبکه (عمومیت یافتن آن) به سادگی امکان پذیر نیست.
- در مورد مسایل مدل سازی، نمی توان صرفا با استفاده از شبکه عصبی به فیزیک مسئله پی برد.


۲-۵-۳- کاربرد شبکه های عصبی

طیف گسترده ای از برنامه ها در شبکه های عصبی مصنوعی وجود دارند، مانند: کنترل هواپیماهای بدون سرنشین، سیستم های تجزیه و تحلیل خطر، تجزیه و تحلیل کیفیت رایانه، تجزیه و تحلیل کیفیت جوش، آزمایش اورژانس، اکتشاف نفت و گاز، سیستم های تشخیص ترمز کامیون، برآورد خطر وام، تشخیص طیفی، تشخیص مواد مخدر، فرآیندهای کنترل صنعتی، مدیریت خطا، تشخیص صدا،

تشخیص هیپاتیت، بازیابی اطلاعات از راه دور، تشخیص مین های زیر دریایی، اشیاء سه بعدی و دست خط و تشخیص چهره و غیره به طور کلی، کاربردهای شبکه های عصبی را می توان به شرح زیر طبقه بندی کرد: الگوهای شلوغ، خوشه بندی، طبقه بندی، شناسایی، بازسازی الگو، تعمیم (به دست آوردن پاسخ صحیح به محرک ورودی که قبلاً در شبکه آموزش ندیده است)، بهینه سازی. امروزه از شبکه های عصبی در کاربردهای گوناگونی مانند مسائل مربوط به تشخیص الگو استفاده می شود که شامل مواردی مانند تشخیص خط، تشخیص گفتار، پردازش تصویر و موارد مشابه و همچنین مسائل طبقه بندی مانند طبقه بندی متن یا تصویر می شود. شبکه های عصبی مصنوعی به طور فزاینده ای در کنترل یا مدل سازی سیستم هایی که دارای ساختار داخلی ناشناخته یا بسیار پیچیده هستند مورد استفاده قرار می گیرد. به عنوان مثال، می توان از یک شبکه عصبی برای کنترل ورودی موتور استفاده کرد، در این صورت خود شبکه عصبی عملکرد کنترل را یاد می گیرد [۱۱].

۲-۶- ساختار شبکه های عصبی مصنوعی

ساختار شبکه شامل موقعیت نسبی سلول ها در شبکه (تعداد، گروه بندی و نوع اتصالات) است. ساختار، سیستم اتصال سخت افزاری نوروں ها به یکدیگر است که همراه با نرم افزار مربوطه (روش ریاضی جریان اطلاعات و محاسبه وزن ها) نوع عملکرد شبکه عصبی را تعیین می کند. یک لایه ورودی در این ساختار وجود دارد که اطلاعات را دریافت می کند. تعدادی لایه مخفی وجود دارد که اطلاعات را از لایه های قبلی دریافت می کنند، و در نهایت یک لایه خروجی وجود دارد که نتیجه محاسبات به آنجا می رود و پاسخ ها در آنها قرار می گیرد. شکل (۲-۳)



شکل (۲-۳) ساختار شبکه عصبی

لایه ورودی

دریافت اطلاعات خامی که به شبکه تغذیه شده است.

لایه های پنهان

تعیین عملکرد توسط ورودی ها و وزن ارتباط بین آنها و لایه های پنهان در این لایه ها ارائه می شود. وزن بین واحدهای ورودی و پنهان تعیین می کند که یک واحد پنهان چه زمانی باید فعال شود.

لایه خروجی

اساس عملکرد واحد خروجی، بستگی به فعالیت واحد پنهان و وزن ارتباط بین واحد پنهان و خروجی دارد.

بیشترین مورد استفاده از شبکه های تک لایه و چند لایه ای که سازماندهی تک لایه که در آن تمام واحدها به یک لایه اتصال دارند، است و پتانسیل محاسباتی بیشتری نسبت به سازماندهی های چند لایه دارد. شماره گذاری در شبکه های چند لایه واحدها به وسیله لایه ها انجام می شوند (به جای دنبال کردن شماره گذاری سراسری) هر دو لایه از یک شبکه به وسیله وزن ها و در واقع اتصالات، با هم ارتباط می یابند.

در شبکه های عصبی چند نوع اتصال و یا پیوند وزنی وجود دارد:

پیشرو^۱:

دارای یک یا چند لایه مخفی با تابع تحریک غیرخطی می باشد که به شبکه اجازه می دهد توانایی یادگیری رابطه خطی و غیرخطی را بین ورودی ها و خروجی ها بدهد. بیشترین پیوندها از این نوع است که در آن سیگنال ها تنها در یک جهت حرکت می کنند. از ورودی به خروجی هیچ بازخوردی (حلقه) وجود ندارد. خروجی هر لایه بر همان لایه تاثیری ندارد.

پسرو^۲:

داده ها از گره های لایه بالا به گره های لایه پایین بازخورانده می شوند.

جانبی:

خروجی گره های هر لایه به عنوان ورودی گره های همان لایه استفاده می شوند.

^۱ Feed Forward

^۲ Back Ward

۲-۲- انواع آموزش شبکه عصبی مصنوعی

۲-۲-۱- وزن ثابت

آموزشی در کار نیست و مقادیر وزن‌ها به هنگام نمی‌شود.

کاربرد:

- بهینه سازی اطلاعات (کاهش حجم، تفکیک پذیری و فشردگی سازی)
- حافظه‌های تناظری

۲-۲-۲- آموزش بدون نظارت^۱- یادگیری خود سامانده

تصحیح وزن‌ها فقط بر اساس ورودی‌ها انجام می‌شود و هیچ خروجی دلخواهی برای مقایسه با خروجی شبکه با آن و تعیین مقدار خطا وجود ندارد. به روز شدن وزن‌ها فقط بر اساس اطلاعات الگوی ورودی می‌باشد. نتیجه استخراج ویژگی‌های الگوهای ورودی بر اساس استراتژی خوشه بندی یا طبقه بندی و شناسایی شباهت‌ها (تشکیل گروه‌ها با الگوی مشابه) است، بدون اینکه خروجی یا کلاس‌های مربوط به الگوهای ورودی از قبل مشخص باشد. این یادگیری معمولاً بر اساس بهترین تمرین است. شبکه بدون نظارت وزن خود را بر اساس خروجی حاصل شده از ورودی تغییر می‌دهد تا در برخورد بعدی پاسخ مناسبی را برای این ورودی داشته باشد. در نتیجه، شبکه نحوه پاسخ به ورودی را می‌آموزد. اساساً، هدف استفاده از تکنیک نورون غالب برای انتخاب نورونی است که بیشترین تحریک اولیه را دارد. بنابراین، در شبکه‌های غالب، یافتن نورون غالب یکی از مهمترین وظایف است.

^۱ Unsupervised

۲-۷-۳- آموزش تحت نظارت^۱

برای هر دسته از الگوهای ورودی، خروجی های مربوطه به شبکه نشان داده می شود و وزن ها تغییر می کنند تا زمانی که تفاوت بین خروجی های شبکه برای الگوهای آموزشی خروجی های مورد نظر در یک خطای قابل قبول باشد. در این روش ها یا ارتباطی بین خروجی ها به وزن ها وجود دارد، یا خلاء از لایه خروجی به ورودی به عقب توزیع می شود و وزن ها اصلاح می شوند. هدف طراحی شبکه ای است که ابتدا با استفاده از داده های آموزشی موجود آموزش می بیند و سپس کلاس خود را با ارائه بردار ورودی به شبکه که شبکه ممکن است قبلاً یاد نگرفته یا ممکن است نشنیده باشد، مشخص کند. چنین شبکه هایی به طور گسترده ای برای کارهای تشخیص الگو استفاده می شوند.

۲-۷-۴- آموزش تقویتی^۲

کیفیت عملکرد سیستم گام به گام با گذشت زمان بهبود می یابد. هیچ الگوی آموزشی وجود ندارد، اما از سیگنالی به نام خوب یا بد برای بیان رفتار سیستم (حالت بین یادگیری با سرپرست و بدون سرپرست) استفاده می شود [۱۱].

۲-۸- توابع تحریک مورد استفاده در شبکه های عصبی


براساس آنچه که به آن پرداخته شد، عملیات اصلی یک شبکه عصبی شامل مجموع ورودی های وزنی و اعمال تابع تحریک در این مجموع برای تعیین خروجی شبکه است. برای نورون های خروجی، این تابع یک تابع واحد است. این بدان معنی است که خروجی نورون برابر ورودی آن است. شکل (۲-۴) عموماً برای همه سلول های عصبی در یک لایه محرک یکسان اعمال می شود، اگرچه چنین شرایطی عموماً مورد نیاز نیست. در بیشتر موارد از یک تابع غیرخطی استفاده می شود. در مقایسه با قابلیت-

^۱ Supervised

^۲ Reinforcement

های محدود یک شبکه تک لایه، یک تابع تحریک خطی برای حداکثر استفاده از شبکه های چند لایه مورد نیاز است (زیرا که ارسال اطلاعات از دو یا چند لایه که در آنها نورون ها با تحریک خطی عمل می کنند به همان نتیجه ای منتهی می گردد که با یک شبکه یک لایه میسر است).
تابع تحریک یک تابع خطی یا غیرخطی است. تابع تحریک برای تعیین خواص نورون ها به منظور حل مشکلات مختلف استفاده می شود. توابع تحریک متداول در شبکه های عصبی شامل:


تابع تحریک خطی^۱



شکل (۴-۲) تابع تحریک خطی

نورون هایی که از این تابع تحریک استفاده می کنند برای تقریب خطی در فیلترینگ خطی به کار می روند. این تابع همان مقدار ورودی را به عنوان خروجی بر می گرداند.

تابع تحریک Hard limit



شکل (۵-۲) تابع تحریک hard limit

^۱ purelin


این تابع تحریک در صورتی که $n < 0$ باشد، خروجی صفر و در صورتی که $n \geq 0$ باشد، خروجی یک را تولید می کند. از این نوع تابع تحریک برای دسته بندی کردن ورودی ها به دو کلاس محدود استفاده می شود. این تابع تحریک عمدتاً در نورون های سازنده شبکه های پرسپترون دارای کاربرد است. شکل (۲-۵).

تابع تحریک لگاریتمی

از این تابع تحریک در شبکه های پس انتشار^۱ استفاده می شود. این تابع تحریک مقادیر ورودی را در محدوده $-\infty$ تا $+\infty$ دریافت کرده و بر مبنای فرمول زیر خروجی بین ۱ و ۰ تولید می نماید. شکل (۲-۶).

$$a = \frac{1}{1 + e^n}$$

(۱-۲)




$$a = \text{logsig}(n)$$

شکل (۲-۶) تابع تحریک لگاریتمی

در ادامه لیست سایر توابع تحریک موجود در جعبه ابزار متلب آماده است.


تابع تحریک Tan sigmoid

از این تابع تحریک عمدتاً در شبکه های پس انتشار استفاده می شود. علت اصلی استفاده از این تابع به واسطه ارتباط ساده بین مقدار تابع در یک نقطه و مقدار مشتق تابع در آن نقطه است که در آموزش شبکه برای مینیمم نمودن خطا به کار گرفته می شود. شکل (۲-۷).




شکل (۷-۲) تابع تحریک tansig

تابع تحریک شعاع مبنا^۱




شکل (۸-۲) تابع تحریک شعاع مبنا

تابع تحریک Hard limit متقارن



شکل (۹-۲) تابع تحریک hard limit متقارن

تابع تحریک Satlins



شکل (۱۰-۲) تابع تحریک satlins

۹-۲- بایاس^۱ و ترشیلد^۲

بایاس همانند وزن روی ارتباط یک نورون که پاسخ تحریک آن یک می باشد عمل می نماید. افزایش بایاس موجب افزایش ورودی به نورون می گردد. به عنوان مثال در یک تابع تحریک پله ای اگر چنانچه بایاس در نظر گرفته شده باشد، پاسخ تحریک به صورت:

$$f(\text{net}) = \begin{cases} 1 & \text{if } \text{net} \geq 0 \\ -1 & \text{if } \text{net} < 0 \end{cases} \quad (۲-۲)$$

بطوریکه

$$\text{net} = b + \sum_i x_i w_i \quad (۳-۲)$$

البته می توان بایاس را در نظر نگرفت اما در مقابل یک مقدار مشخص ثابتی (ترشیلد) را همیشه در نورون در نظر گرفت، در آن صورت پاسخ تابع تحریک به صورت زیر خواهد بود:

^۱ Bias

^۲ Threshold

$$f(net) = \begin{cases} 1 & \text{if } net \geq \theta \\ -1 & \text{if } net < \theta \end{cases} \quad (۴-۲)$$

$$net = \sum_i x_i w_i \quad (۵-۲)$$

بنابراین بایاس فاکتور مهمی است که عملکرد سیستم را بالا می برد [۱۱].


۲-۱۰- مسائل مناسب برای یادگیری شبکه های عصبی

در داده های آموزش خطایی وجود داشته باشد. مواردی که نمونه ها با مقادیر زیادی زوج، ویژگی- مقدار نشان داده شده باشند. مقادیر پیوسته را برای تابع هدف داشته باشد. زمان کافی برای یادگیری وجود داشته باشید. این روش در مقایسه با روش های دیگر نظیر درخت تصمیم نیاز به زمان بیشتری برای یادگیری دارد. نیازی به تفسیر تابع هدف نباشد، زیرا تفسیر وزن های آموخته شده توسط شبکه دشوار است [۱۱].

۲-۱۱- شبکه های عصبی پرسپترون چند لایه^۱

واحد محاسباتی پرسپترون ساخته شده از یک نوع واحد شبکه عصبی است. پرسپترون بردارهای ورودی ها را با مقادیر واقعی می گیرد و ترکیبی خطی از این ورودی ها را محاسبه می کند. اگر مقدار از آستانه بیشتر باشد، خروجی پرسپترون برابر ۱ و در غیر این صورت برابر ۰-۱ است. شبکه پرسپترون پاسخ ها را رمزگذاری می کند و خروجی بدون هیچ گونه بازخورد محاسبه می شود. شبکه های پرسپترون از یک لایه ورودی، تعدادی لایه پنهان و یک لایه خروجی تشکیل شده است. شکل (۲-۱۱) یک شبکه پرسپترون با یک لایه مخفی را نشان می دهد.

^۱ Multi layer Perceptron (MLP)



شکل (۱۱-۲) شبکه پرسپترون با یک لایه پنهان


در شکل (۱۱-۲) لایه x لایه ورودی، لایه z لایه پنهان و لایه y لایه خروجی می باشد. در این شبکه ها شرایط زیر وجود دارد:

- نورون های هر لایه تنها به نورون های لایه بعدی متصل می باشند.
- هر نورون به تمامی نورون های لایه بعد متصل است.
- نورون های لایه ورودی عملی را انجام نمی دهند و اوزان ها ثابت و برابر یک می باشد. این نورون ها فاقد تابع فشرده سازی می باشند.

تعداد لایه های مخفی در شبکه های پرسپترون چند لایه، می تواند هر عددی باشد. البته، در اکثر برنامه ها، یک لایه مخفی کافی است. گاهی اوقات دو لایه مخفی یادگیری شبکه را آسان تر می کند. فرانک روزنبلات، با اتصال این نورون ها به روش ساده، پرسپترون را ایجاد کرد و برای اولین بار این مدل را در رایانه های دیجیتال شبیه سازی کرد و آنها را به طور رسمی تجزیه و تحلیل کرد:

- پرسپترون برداری از ورودی ها را دریافت می کند.
- ترکیب خطی این ورودی ها را محاسبه می کند.
- اگر حاصل از یک مقدار آستانه بیشتر بود تحریک می کند (خروجی پرسپترون برابر با یک

می شود). شکل (۱۲-۲)



شکل (۱۲-۲) شبکه پرسپترون

سیگنال های ورودی x_1 تا x_n معادل سیگنال های عصبی ورودی و وزن های w_1 تا w_n معادل مقادیر اتصالات سیناپسی ورودی های نورون می باشند که جمعا ورودی های نورون را تشکیل داده است [۱۷].

۱۲-۲- خصوصیات شبکه های عصبی پرسپترون چند لایه

۱-۱۲-۲- خروجی پرسپترون (یادگیری)

خروجی پرسپترون توسط رابطه (۶-۲) مشخص می شود:

$$y_i = \text{ActivationFunction}\left(\sum_{j=1}^n x_j w_{ij}\right) \quad (6-2)$$

$$\begin{cases} 1 & \text{if } w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n > 0 \\ -1 & \text{otherwise} \end{cases}$$

بنابراین یادگیری پرسپترون عبارت است از:


- پیدا کردن مقادیر درستی برای w که مقادیر وزن می باشد.
- بنابراین فضای فرضی H در یادگیری پرسپترون عبارت است از مجموعه تمام مقادیر حقیقی ممکن برای بردارهای وزن.

۲-۱۲-۲- نقش تابع در خروجی شبکه

این که کدام یک از توابع تحریک را به کار ببریم تا خطای کمتری ایجاد شود و عملکرد شبکه افزایش یابد.

۲-۱۲-۳- توانائی پرسپترون

در نظر گرفتن پرسپترون به صورت یک سطح تصمیم ابر صفحه ای^۱ در فضای n بعدی نمونه ها می-تواند باشد. پرسپترون برای نمونه های یک طرف صفحه مقدار ۱ و برای مقادیر طرف دیگر مقدار ۰-وجود می آورد. شکل (۲-۱۳)



شکل (۲-۱۳) توانائی پرسپترون

۲-۱۲-۴- توابعی که پرسپترون قادر به یادگیری آنها می باشد


یک پرسپترون فقط قادر است مثال هائی را یاد بگیرد که بصورت خطی جداپذیر باشند. اینگونه مثال-ها مواردی هستند که بطور کامل توسط یک صفحه قابل جدا سازی می باشند. مانند شکل (۲-۱۴) که مشاهده می کنید.

یک پرسپترون می تواند توابع ترکیب عطفی^۲ و ترکیب فصلی^۳ را به خوبی نشان دهد.

^۱ hyperplane

^۲ AND

^۳ OR



شکل (۲-۴) توابع قابل یادگیری پرسپترون

۲-۱۲-۵- آموزش پرسپترون

چگونه وزن های یک پرسپترون واحد را یاد بگیریم به نحوی که پرسپترون برای مثال های آموزشی مقادیر صحیح را ایجاد نماید؟

دو راه مختلف:

- قانون پرسپترون
- قانون دلتا^۱

الگوریتم یادگیری پرسپترون:

- مقادیری تصادفی به وزن ها نسبت می دهیم.
- پرسپترون را به تک تک مثال های آموزشی اعمال می کنیم. اگر مثال غلط ارزیابی شود، مقادیر وزن های پرسپترون را تصحیح می کنیم (*).
- آیا تمامی مثال های آموزشی درست ارزیابی می شوند:
- بله ← پایان الگوریتم
- خیر ← به مرحله * بر می گردیم.

^۱ Delta Rule

۲-۱۲-۵-۱- قانون پرسپترون

برای یک مثال آموزشی $X = (x_1, x_2, \dots, x_n)$ در هر مرحله، وزن ها بر اساس قانون پرسپترون بصورت زیر تغییر می کند:

$$w_i = w_i + \Delta w_i \quad (۷-۲)$$

که در آن

$$\Delta w_i = \eta (t - o) x_i \quad (۸-۲)$$

t : target output

o : output generated by the perceptron

η : constant called the learning rate (e.g., 0.1)

اثبات شده است که برای یک مجموعه مثال جداپذیر خطی این روش همگرا شده و پرسپترون قادر به جدا سازی صحیح مثال ها خواهد شد.

۲-۱۲-۵-۲- قانون دلتا

زمانی که نمونه ها بصورت خطی قابل تفکیک نباشند، قانون پرسپترون همگرا نخواهد شد. قانون دلتا برای غلبه بر این مشکل استفاده می شود. ایده اصلی این قانون استفاده از گرادیان نزولی^۱ برای جستجوی فضای فرضیه های وزن احتمالی است. این قانون اساسی، روش پس انتشار^۲ است که برای آموزش شبکه با چندین نورون به هم پیوسته استفاده می شود.

^۱ Gradient Descent (GD)

^۲ Back Propagation (BP)

همچنین مبنایی برای انواع الگوریتم های یادگیری است که باید فضای فرضی شامل فرضیه های مختلف مداوم را کشف کنند.


برای درک بهتر این روش، آن را روی پرسپترون آستانه اعمال می کنیم. در اینجا لازم است ابتدا خطای آموزش را تعریف کنیم. این یک تعریف رایج است:

$$E = \frac{1}{2} \sum_i (t_i - o_i)^2 \quad (9-2)$$

که این مجموع برای تمام مثال های آموزشی انجام می شود.

الگوریتم گرادیان نزولی

بسته به نحوه تعریف E سطح خطا یک سهمی خواهد بود. ما به دنبال وزن هایی هستیم که حداقل خطا را داشته باشند. الگوریتم گرادیان نزولی در فضای وزن جستجو می شود تا خطا به حداقل برسد. این الگوریتم از یک مقدار دلخواه برای بردار وزن شروع می شود و وزن ها را در هر مرحله به گونه ای تغییر می دهد که خطا را در جهت کاهش شیب منحنی (۲-۱۵) کاهش دهد.



شکل (۲-۱۵) گرادیان نزولی

بدست آوردن قانون گرادیان نزولی

- ایده اصلی: گرادیان همواره در جهت افزایش شیب E عمل می کند.
- گرادیان E نسبت به بردار وزن w بصورت زیر تعریف می شود:

$$\nabla E(W) = [E'/w_0, E'/w_1, \dots, E'/w_n] \quad (10-2)$$

که در آن $\nabla E(W)$ یک بردار و E' مشتق جزئی نسبت به هر وزن می باشد. برای یک مثال آموزشی $X = (x_1, x_2, \dots, x_n)$ در هر مرحله وزن ها بر اساس قانون دلتا بصورت رابطه (۱۱-۲) تغییر می کند:

$$w_i = w_i + \Delta w_i \quad (11-2)$$

Where $\Delta w_i = -\eta E'(W)/w_i$
 η : learning rate (e.g., 0.1)

علامت منفی نشان دهنده حرکت در جهت کاهش شیب است. با مشتق گیری جزئی از رابطه خطا می توان بسادگی گرادیان را محاسبه نمود:

$$E'(w)/w_i = \sum_i (t_i - O_i) (-x_i) \quad (12-2)$$

لذا وزن ها طبق رابطه زیر تغییر خواهند نمود:

$$\Delta w_i = \eta \sum_i (t_i - O_i) (-x_i) \quad (13-2)$$

خلاصه یادگیری قانون دلتا

الگوریتم یادگیری با استفاده از قانون دلتا بصورت زیر می باشد:

- به وزن ها مقدار تصادفی نسبت دهید.
- تا رسیدن به شرایط توقف مراحل زیر را ادامه دهید.
- هر وزن W_i را با مقدار صفر عددی اولیه کنید.
- برای هر مثال: وزن W_i را بصورت رابطه (۱۴-۲) تغییر دهید:

$$\nabla w_i = \nabla w_i + \eta(t_i - O_i)(x_i) \quad (۱۴-۲)$$

مقدار w_i را بصورت رابطه (۱۵-۲) تغییر دهید:

$$w_i = w_i + \Delta w_i \quad (۱۵-۲)$$


تا خطا بسیار کوچک شود.

مشکلات روش گرادیان نزولی:

- ممکن است همگرا شدن به یک مقدار مینیمم زمان زیادی لازم داشته باشد.
- اگر در سطح خطا چندین مینیمم محلی وجود داشته باشد، تضمینی وجود ندارد که الگوریتم مینیمم مطلق را پیدا بکند.
- در ضمن این روش وقتی قابل استفاده است که:
- فضای فرضیه دارای فرضیه های پارامتریک پیوسته باشد.
- رابطه خطا قابل مشتق گیری باشد [۱۱].


۲-۱۲-۶- شبکه های چند لایه

برخلاف پرسپترون ها، از شبکه های چند لایه می توان برای یادگیری مشکلات غیر خطی و همچنین مشکلات تصمیم گیری های متعدد استفاده کرد. شکل (۱۶-۲).



شکل (۱۶-۲) شبکه دو لایه

برای اینکه بتوانیم فضای تصمیم گیری را بصورت غیرخطی از هم جدا بکنیم، لازم است تا هر سلول واحد را بصورت یک تابع غیرخطی تعریف نمائیم. مثالی از چنین سلولی می تواند یک واحد سیگموئید باشد که در شکل (۲-۱۷) نشان داده شده است:



شکل (۲-۱۷) سلول واحد سیگموئید

خروجی این سلول واحد را می توان بصورت رابطه (۲-۱۶) بیان نمود:

$$O(x_1, x_2, \dots, x_n) = \sigma(WX) \quad (2-16)$$

where : $\sigma(WX) = 1 / (1 + e^{-WX})$

تابع σ ، تابع سیگموئید یا لجستیک نامیده می شود. این تابع دارای خاصیت زیر است:

$$d\sigma(y)/dy = \sigma(y)(1 - \sigma(y)) \quad (2-17)$$

۲-۱۲-۷- شبکه های پس انتشار

متداول ترین روش آموزشی نظارتی الگوریتم پس انتشار خطا است. یادگیری این الگوریتم بر اساس قانون تصحیح خطا است که می تواند به عنوان تعمیم الگوریتم مرسوم به حداقل مربعات متوسط در نظر گرفته شود. یادگیری با این روش (پس انتشار) دارای دو مرحله است: مرحله پیشروی و مرحله بازگشت. در مرحله پیشروی، ورودی ها به صورت لایه به لایه در شبکه پیش می روند و در پایان مجموعه ای از خروجی ها به عنوان پاسخ واقعی شبکه بدست می آیند. در این مرحله، وزن اتصال ثابت

است. در مرحله بازگشت، وزن اتصال با توجه به قانون تصحیح خطا، تغییر می کند. تفاوت بین پاسخ واقعی شبکه و پاسخ مورد انتظار، خطا نامیده می شود، در سراسر شبکه پخش می شود. در طرف مقابل اتصال آنها به گونه ای تغییر می کنند که پاسخ واقعی شبکه به پاسخ مورد نظر نزدیکتر است. از روش پس انتشار برای یادگیری وزن شبکه های چند لایه استفاده می شود. در این روش، با استفاده از توابع تحریک غیرخطی و گرادیان نزولی، سعی می کنیم مربع خطا بین خروجی های شبکه و تابع هدف را به حداقل برسانیم.

خطا بصورت رابطه (۲-۱۸) تعریف می شود:

$$E(\vec{W}) \equiv \frac{1}{2} \sum_{d \in D} \sum_{k \in \text{outputs}} (t_{kd} - o_{kd})^2 \quad (2-18)$$

مراد از outputs خروجی های مجموعه واحد های لایه خروجی و t_{kd} و o_{kd} مقدار هدف و خروجی متناظر با k امین واحد خروجی و مثال آموزشی d است. در این روش فضای فرضیه مورد نظر، فضای گسترده ای است که با تمام مقادیر ممکن برای وزن ها تعریف شده است. روش گرادیان نزولی سعی می کند با به حداقل رساندن خطا به یک فرضیه مناسب دست یابد. اما هیچ تضمینی وجود ندارد که این الگوریتم به حداقل مطلق برسد.

الگوریتم پس انتشار

۱. شبکه ای با n_{in} گره ورودی، n_{hidden} گره مخفی، و n_{out} گره خروجی ایجاد کنید.

۲. همه وزن ها را با یک مقدار تصادفی کوچک عدد دهی کنید.

۳. تا رسیدن به شرط پایانی (کوچک شدن خطا) مراحل زیر را انجام دهید:

برای هر x متعلق به مثال های آموزشی:

۱. X را به سمت جلو در شبکه انتشار دهید.

۲. خطای E را به سمت عقب در شبکه انتشار دهید.

تنظیم اوزان مهمترین قسمت پس از محاسبه خطای پیش بینی است به طوری که برای اولین بار که وارد سیستم شده اید، وزن ها از آخرین لایه به لایه اول تغییر می کند تا خطای پیش بینی کاهش یابد. در واقع BP سرشکن کردن خطا بر روی گره های یک لایه و لایه بعدی است. پس از این

اطلاعات، نمونه دوم در اختیار شبکه قرار می گیرد. از آنجا با همان وزن ها، نمونه جدید مجدداً خطایی ایجاد می کند، دوباره از روش پراکندگی معکوس استفاده می شود و وزن ها را به گونه ای تغییر می - دهد که حداقل خطا را (هم برای این نمونه و هم برای نمونه قبلی) ایجاد کند. به طوری که پس از خواندن تعداد کافی نمونه در ورودی شبکه، به اصطلاح شبکه همگرا^۱ می شود (یعنی میزان خطا به کمترین مقدار خود می رسد). این به معنی موفقیت در مرحله یادگیری است و شبکه آماده استفاده برای مرحله پیش بینی است.

شرط خاتمه

معمولاً الگوریتم BP پیش از خاتمه، هزاران بار با استفاده همان داده های آموزشی تکرار می گردد. شروط مختلفی را می توان برای خاتمه الگوریتم بکار برد:

- توقف بعد از تکرار به دفعات معین.
- توقف وقتی که خطا از یک مقدار تعیین شده کمتر شود.
- توقف وقتی که خطا در مثال های مجموعه تائید، از قاعده خاصی پیروی نماید.

توجه به این نکته اهمیت دارد که اگر تعداد نورون ها و لایه پنهان مورد استفاده، بیش از حد معمول باشد، سیستم به جای تجزیه و تحلیل داده ها، آنها را حفظ می کند و اصطلاحاً دچار بیش برآزشی^۲ می شود. در این حالت، مدل بدست آمده قادر خواهد بود داده های مشابه مورد استفاده در مرحله یادگیری را به طور دقیق پیش بینی کند، اما اگر از داده های جدیدی که در مرحله آموزش استفاده نشده است استفاده شود، سیستم، عملکرد بسیار بد و خطای پیش بینی زیاد خواهد بود. برای جلوگیری از این پدیده، از روش اعتبارسنجی متقاطع استفاده می شود. در این روش، مجموعه داده های اولیه به سه دسته آموزش^۳، آزمایش^۴ و اعتبار^۵ تقسیم بندی می شود. اعتبار شبکه همزمان با آموزش در هر دور اندازه گیری می شود و به محض افزایش خطای داده های اعتباری، آموزش شبکه قطع می شود. همچنین اگر تعداد تکرارها کم باشد، خطا خواهیم داشت و اگر زیاد باشد، برآزش بیشتری در مشکل وجود خواهد داشت.

^۱ Converge

^۲ Over Fitting

^۳ Train

^۴ Test

^۵ Validation

داده های آموزش

داده هایی که مقدار آنها معلوم و در حین فرآیند آموزش استفاده می شوند.

داده های اعتبار

داده هایی که مقدار آنها نامعلوم و در حین فرآیند آموزش استفاده می شوند.

داده های آزمایش

داده هایی که مقدار آنها نامعلوم و پس از فرآیند آموزش استفاده می شوند.

۲-۱۲-۸- یادگیری تطبیقی

بردارهای ورودی یک به یک به شبکه اعمال می شوند و عملیات بروز رسانی در هر مرحله انجام می - شود و ما یک سیستم سازگار داریم.

۲-۱۲-۹- روش های تعیین ضرایب شبکه عصبی (روش های بهینه سازی)

۲-۱۲-۹-۱- روش های کلاسیک

این متدها بر طبق گرادیان نزولی، پس انتشار خطا و الگوریتم های یادگیری تطبیقی است که برخی از آنها هرسه الگوریتم فوق را دارند و برخی تنها یک الگوریتم ها دارند. نام برخی از آنها در شکل (۵-۸) تهیه شده است.

Training Functions

trainb	Batch training with weight and bias learning rules
trainbfg	BFGS quasi-Newton backpropagation
trainbfgc	BFGS quasi-Newton backpropagation for use with NN model reference adaptive controller
trainbr	Bayesian regularization
trainbuwb	Batch unsupervised weight/bias training
trainc	Cyclical order incremental update
traincgb	Powell-Beale conjugate gradient backpropagation
traincgf	Fletcher-Powell conjugate gradient backpropagation
traincgp	Polak-Ribière conjugate gradient backpropagation
traingd	Gradient descent backpropagation
traingda	Gradient descent with adaptive learning rule backpropagation
traingdm	Gradient descent with momentum backpropagation
traingdx	Gradient descent with momentum and adaptive learning rule backpropagation
trainlm	Levenberg-Marquardt backpropagation
trainoss	One step secant backpropagation
trainr	Random order incremental training with learning functions
trainrp	Resilient backpropagation (Rprop)
trains	Sequential order incremental training with learning functions
trainscg	Scaled conjugate gradient backpropagation

شکل (۲-۱۸) توابع آموزش

عملکرد Levenberg-Marquardt(lm) یکی از بهترین و قدرتمندترین عملکردهای آموزشی است که از هر سه الگوریتم گرادیان نزولی، پس انتشار خطا و یادگیری تطبیقی به صورت همزمان استفاده می کند، که منجر به عملکرد بالای شبکه عصبی می شود و به عنوان trainlm در شبکه استفاده می-شود. این تابع تکامل یافته سایر توابع است.

۲-۹-۱۲-۲ روش های هوشمند

این روش به کمک یکی از الگوریتم های ژنتیک، ازدحام ذرات، فاخته و غیره شبکه را آموزش می-دهد، که هر کدام از آنها مراحل و الگوریتم مربوط به خود را دارند.

۲-۱۲-۱۰- تعیین تعداد نورون های لایه پنهان

اگر به شبکه مقدار کمی نورون بدهیم، خطای شبکه نیز افزایش می یابد و در واقع تعداد نورون ها در شبکه عصبی نیز مهم می باشد، زیرا اگر تعداد بیش از حد نورون به شبکه عصبی بدهیم، شبکه دچار بیش برآزشی می گردد. بنابراین برای آموزش یک شبکه عصبی دو لایه، تعداد نورون های لایه دوم برابر با تعداد خروجی می باشد، تعیین تعداد لایه اول مهم می باشد که سعی شود تا حد امکان از فرمول (۲-۱۹) تبعیت کنید که حد بالای تعداد نورون های لایه اول را می دهد:

$$n_1 \leq \frac{k(n_i + n_o) - n_o}{n_i + n_o + 1} \quad (۲-۱۹)$$

n_1 تعداد نورون های لایه اول

n_i تعداد داده های ورودی

n_o تعداد داده های خروجی

k تعداد کل نمونه ها [۱۱].

۲-۱۳- شبکه عصبی تأخیر زمانی^۱:

آنها نوعی شبکه عصبی چندلایه هستند که توانایی رویارویی با طبیعت دینامیکی داده های نمونه ای و سیگنال های ورودی را دارا می باشد. شبکه های عصبی چند لایه دارای ویژگی های زیر هستند:

۱- دارای چندین لایه است و در هر لایه ارتباطات کافی بین نورون ها وجود دارد تا شبکه توانایی یادگیری سطوح تصمیم گیری غیرخطی پیچیده را داشته باشد.

۲- رفتار شبکه نسبت به انتقال زمانی ویژگی های نمونه ها حساس می باشد.


۳- فرایند یادگیری در شبکه نسبت به زمان دقیق نمونه های ورودی حساس است.

شبکه تأخیر زمان (TDNN) اولین بار توسط ویبل در سال ۱۹۸۸ مورد استفاده قرار گرفت و به همان

^۱ Time delay neural network (TDNN)

شکل باقی ماند و شامل سه لایه است که وزن آنها با سلول های تأخیر زمانی جفت شده است. عملکرد محرک هرسلول TDNN تابع سیگموئید است و آنها ورودی های وزنی $N^*(D+1)$ را دارند. در مورد این شبکه، هنگام طراحی شبکه های عصبی و به ویژه شبکه های عصبی با تأخیر زمانی، طراح با مشکل انتخاب شبکه مناسب برای طراحی خود روبرو می شود. در کل، شبکه ای با کمترین پیچیدگی و پارامترها، که دقیق ترین الگوهای ورودی را مشخص می کند، شبکه مناسب نامیده می شود. از نظر تئوری، مشکلی که می تواند توسط یک شبکه معین حل شود، توسط شبکه های بزرگتر نیز قابل حل است. ولی به خاطر عدم وجود جواب یگانه برای وزن های بهینه الگوریتم های یادگیری برای شبکه بزرگتر معمولاً وزن های مخالف صفر را نتیجه می دهند از این رو برای تشخیص آن یک شبکه با اندازه کوچکتر برای حل مسئله مورد نظر وجود دارد با اشکال مواجه می کند. اگر تعداد سلول های عصبی یا نورون ها را در لایه های شبکه که در یک مشکل خاص استفاده می شوند کاهش دهیم، شبکه نمی تواند یاد بگیرد زیرا تعداد صفحات بالا، و بنابراین حجم مورد نیاز برای تقسیم فضای ورودی به کلاس های مختلف، زیاد نیست همچنین به دلیل افزایش حجم محاسبات و در نتیجه طول دوره آموزش شبکه نامناسب است. همچنین، از آنجا که آموزش شبکه بر اساس مجموعه ای محدود از الگوهای آموزشی است اگر شبکه خیلی بزرگ باشد سعی در حفظ کردن دقیق الگو های تربیتی می نماید و این امر موجب کاسته شدن از قدرت تعمیم و درون یابی شبکه جهت تشخیص الگوهای جدید و خارج از مجموعه تربیتی می گردد از این رو یک تعداد بحرانی برای لایه های پنهان وجود دارد که برای هر کاربرد خاص باید پیدا شود. تعداد نورون های لایه پنهان با شبیه سازی شبکه های مختلف و اندازه گیری میزان دقت و درون یابی این شبکه ها روی الگو هایی که در مجموعه آموزشی آنها نبوده است. تعداد نورون های لایه خروجی شبکه و یا به عبارت دیگر نوع کد گذاری در خروجی نیز باید برای حل یک مسئله خاص مناسب باشد. بهترین روش کدینگ کردن کلاس های خروجی، استفاده از بردار های مقدماتی است [۵].

نمونه ای از ساختار نورون های آن را در شکل (۲-۱۹) مشاهده می کنیم.



شکل (۱۹-۲) ساختار نورون ها

۲-۱۴- سیستم استنتاج عصبی - فازی انطباقی (ANFIS) ^۱

سیستم های استنتاج فازی، یک چارچوب محاسباتی پرتعداد بر مبنای مفهوم مجموعه های فازی، قواعد if-then و استدلال فازی هستند. ساختار اساسی سیستم های استنتاج فازی از سه بخش مفهومی تشکیل می شود. قسمت نخست قوانین است که شامل مجموعه ای از قوانین فازی است. قسمت دوم پایگاه داده است، که در آن توابع عضویت استفاده شده در قوانین فازی تعریف شده است. در نهایت، قسمت سوم مکانیزم استنباط است که توسط آن روش استنتاج، با کمک قوانین و حقایق موجود، برای دستیابی به خروجی معقول انجام می شود. سه نوع سیستم استنتاج فازی که کاربردهای گسترده ای دارند، عبارتند از: مدل های فازی ممدانی ^۲، مدل های فازی سوگنو ^۳ و مدل های فازی تسوکاموتو ^۴.

تفاوت بین این سیستم ها، در نتیجه قواعد فازی و در نتیجه روال محاسبه مجموع و غیرفازی سازی در آنها می باشد [۴]. در این مطالعه، از آنجا که از استنباط فازی سوگنو استفاده می شود، توضیح در مورد این سیستم کافی است.

قواعد if-then (اگر - آنگاه): برای فرموله کردن دستورات شرطی منطق فازی، مورد استفاده قرار

^۱ Adaptive Neuro-Fuzzy Inference System (ANFIS)

^۲ Mamdani Fuzzy Models

^۳ Sugeno Fuzzy Models


^۴ Tsukamoto Fuzzy Models

می گیرند.

غیرفازی سازی: روالی است که طی آن یک مجموعه فازی به یک مقدار عددی تبدیل می شود. مدل فازی سوگنو که به عنوان مدل فازی TSK، نیز شناخته می شود (توسط تاکاگی، سوگنو و کانگ^۱، پیشنهاد شد)، تلاشی برای توسعه یک سیستم روشمند در راستای ایجاد قواعد فازی با توجه به مجموعه داده های ورودی- خروجی می باشد. یک قاعده در مدل فازی سوگنو دارای شکل کلی رابطه (۲۰-۲) است:

$$\text{If } x \text{ is } A \text{ and } y \text{ is } B \text{ then } z = f(x, y) \quad (20-2)$$

در فرمل (۲۰-۲) A و B مجموعه های فازی و $z = f(x, y)$ یک تابع در قسمت نتیجه قاعده (قانون) می باشد. معمولاً $f(x, y)$ یک چند جمله ای با متغیرهای x و y است. اگر $f(x, y)$ چند جمله ای درجه یک باشد، از سیستم استنتاج فازی، تحت عنوان مدل فازی سوگنوی درجه اول و اگر $f(x, y)$ ثابت باشد، از سیستم، تحت عنوان مدل فازی سوگنوی درجه صفر، یاد می شود. شکل (۲۰-۲)، روال استدلال فازی را در مدل سوگنوی درجه اول نشان می دهد [۴].



شکل (۲۰-۲) روال استدلال فازی در مدل سوگنوی درجه اول

از آنجا که هر قاعده دارای خروجی عددی است، خروجی نهایی با محاسبه میانگین وزنی، محاسبه می شود. در عمل، گاهی عملگر میانگین وزنی، با عملگر جمع وزن دار شده

^۱ Takagi, Sugeno and Kang

$(w_1 z_1 + w_2 z_2 = z)$ ، جایگزین می شود. بنابراین، باز هم از حجم محاسبات، به خصوص در مرحله آموزش سیستم استنتاج فازی، کاسته می شود [۴]. از نظر مفهومی، مدل سازی فازی در دو مرحله وابسته به هم انجام می شود. مرحله اول، تشخیص ساختار سطح^۱ است، که شامل مراحل زیر می-باشد:

- تعیین متغیرهای مرتبط ورودی و خروجی
- انتخاب نوع سیستم استنتاج فازی
- تعیین ترتیب معادلات قسمت نتیجه
- طراحی مجموعه ای از قواعد if-then فازی.

برای انجام این مراحل، تنها بر دانش خود از سیستم هدف تکیه خواهیم داشت. این دانش از طریق دریافت اطلاعات از افراد متخصص و آشنا با سیستم هدف و یا با انجام آزمایش-خطا، تکمیل می-شود. پس از مرحله اول از مدل سازی فازی، قوانین توصیف کننده ی رفتار سیستم هدف با اصطلاحات زبان شناختی، کم و بیش ارائه شده است. معنای این اصطلاحات زبانی در مرحله دوم مشخص می شود. این مرحله شناسایی ساختار عمقی^۲ نامیده می شود که طی آن توابع عضویت هر اصطلاح زبانی و ضرایب خروجی چند جمله ای در مدل سوگنو تعیین می شود. این مرحله شامل مراحل زیر است:

- ۱- انتخاب یک خانواده مناسب از توابع عضویت پارامتری
 - ۲- استفاده از تخصص افراد متخصص در ارتباط با سیستم هدف برای تعیین پارامترهای توابع عضویت
 - ۳- تنظیم پارامترهای توابع عضویت با استفاده از تکنیک های بهینه سازی و رگرسیون [۴].
- ساختار ANFIS، دو مجموعه داده ی آموزش پذیر دارد: پارامترهای تابع عضویت اولیه (مقدم) و پارامترهای چندجمله ای (تالی یا نتیجه). ساختار ANFIS، از یک الگوریتم گرادیان نزولی، برای بهینه سازی پارامترهای اولیه و از یک الگوریتم حداقل مربعات^۳، برای حل پارامترهای نتیجه، استفاده می-کند. هر قانون در ساختار ANFIS، به شکل رابطه ی (۲-۲۱)، است:

^۱ Surface Structure

^۲ Deep Structure


^۳ Least squares algorithm

$$\text{IF } x_1 \text{ is } A_{1,j} \text{ AND } x_2 \text{ is } A_{2,j} \text{ AND } \dots \text{ AND } x_n \text{ is } A_{n,j} \quad (21-2)$$

$$\text{THEN } y = c_0 + c_1 x_1 + c_2 x_2 + \dots + c_n x_n$$

در رابطه ی (۲۱-۲)، $A_{i,j}$ ، زامین عبارت زبان شناختی i آمین متغیر ورودی x_i ، است. n تعداد ورودی ها و y خروجی مدل و c_i ، پارامترهای نتیجه، که در فرایند آموزش تعیین شده اند، هستند. از آنجا که هر قاعده خروجی مشخصی دارد (برخلاف خروجی فازی)، کل خروجی از طریق میانگین وزنی بدست می آید. در ساختار ANFIS از نوع سوگنو، لایه های متوالی، برای وظایف مختلفی همانند، ایجاد یک فرایند تصفیه تدریجی مدل، اختصاص می یابند. فرآیند یادگیری از یک فرایند جلوگذر^۱ و یک فرایند عقب گذر^۲، تشکیل شده است.

در طول فرایند جلوگذر، پارامترهای اولیه ثابت شده و پارامترهای نتیجه با استفاده از الگوریتم حداقل مربعات بهینه می شوند. فرایند عقب گذر از یک الگوریتم گرادیان نزولی برای تغییر پارامترهای اولیه توابع عضویت برای متغیرهای ورودی استفاده می کند. خروجی به عنوان یک میانگین وزنی پارامترهای نتیجه، محاسبه می شود. هر خطای خروجی از الگوریتم پس از انتشار برای تنظیم پارامترهای قبلی استفاده می کند. شکل (۲۱-۲) ساختار سیستم استنتاج عصبی- فازی تطبیقی، را نشان می دهد. در این سیستم، گره های^۳ دایره ای، نشان دهنده گره های ثابت و گره های مربعی، نشان دهنده گره هایی اند که در آنها پارامترها، توان یادگیری دارند (گره های تطبیقی). همانطور که در شکل (۲۱-۲) نشان داده شده است، سیستم ANFIS دارای پنج لایه است:



شکل (۲۱-۲) ساختار سیستم استنتاج عصبی- فازی انطباقی (ANFIS)

^۱ Forward pass

^۲ Backward pass

^۳ Nodes

لایه اول (لایه ورودی و خروجی توابع عضویت): در این لایه ی خروجی هر گره عبارت است از:

$$O_{\lambda,i} = \mu_{B_{i-r}}(y) \text{ for } i=3,4 \quad O_{\lambda,i} = \mu_{A_i}(x) \text{ for } i=1,2 \quad (22-2)$$

در رابطه ی (۲۲-۲)، $Q_{i,1}(x)$ ضرورتاً درجه عضویتی برای x و y است.

لایه دوم (لایه قوانین): همه گره ها در این لایه ثابت اند. این لایه، قدرت هر قاعده را با استفاده از ضرب جبری، همانند رابطه ی (۲۳-۲)، ارائه می کند:

$$w_i = \prod \mu_{A_j}(x_j), i=1,2 \quad j=1, \dots, n \quad (23-2)$$

در این لایه، هر گره از حاصل ضرب مقادیر ورودی در لایه قبلی، به دست می آید. ارزش به دست آمده، نشان دهنده ی قدرت اجرایی i امین قاعده، جایی که متغیر x_j ارزش زبان شناختی A_i را دارد، می باشد.

$$\bar{w} = \frac{w_i}{\sum w_i} \quad (24-2)$$

در رابطه ی (۲۴-۲)، w_i قدرت اجرایی i امین قاعده می باشد. تعداد گره های این لایه همانند لایه قبلی است. این لایه قدرت اجرایی قاعده را برای مجموع قواعد قدرت اجرایی، محاسبه می کند. لایه چهارم (لایه انطباقی): هر گره در این لایه، یک تابع خطی است و ضرایب این تابع از طریق ترکیبی از تقریب حداقل مربعات و پس انتشار، تعدیل می شود.

$$\bar{w}_i f_i = \bar{w}_i (c_0 + c_1 x_1 + c_2 x_2 + \dots + c_n x_n) \quad (25-2)$$

لایه پنجم (لایه خروجی): نتایج این لایه به عنوان مجموعی از خروجی گره های لایه قبلی، به دست آمده است.

$$\sum_i \bar{w}_i f_i = \frac{\sum w_i f_i}{\sum w_i} \quad (26-2)$$

در رابطه (۲۶-۲)، $\bar{w}_{if_i}$ خروجی گره i ام در لایه قبلی است. خروجی کلی، خطی است. اگرچه پارامترها، از لحاظ منطقی، غیرخطی اند [۴].

۲-۱۴-۱- معیارهای ارزیابی مدل های پیش بینی

معیارهای گوناگونی برای سنجش قدرت پیش بینی روش های محاسبات نرم وجود دارد. در این پژوهش، به ۳ معیار اشاره شده است. این معیارها به صورت روابط زیر می باشند:

ضریب تعیین (R^2):

$$R^2 = \frac{\sum (\hat{y}_t - \bar{y})^2}{\sum (y_t - \bar{y})^2} \quad (27-2)$$

میانگین مربع خطای پیش بینی:

$$MSE = \frac{\sum (y_t - \hat{y}_t)^2}{n} \quad (28-2)$$

اطلاعات هنان – کوین^۱:

$$HIC = \log(SSR) + \frac{k \log(\log(n))}{n} \quad (29-2)$$

در روابط (۲۷-۲) تا (۲۹-۲)، y_t قیمت واقعی، $\hat{y}_t$ قیمت پیش بینی شده، n تعداد مشاهدات، $\bar{y}$ میانگین مشاهدات، SSR مجموع مربعات و یا اختلاف میان y و $\hat{y}$ ، k تعداد پارامترهای استفاده شده در تخمین یا آموزش مدل، می باشند [۴].

^۱ Hannan-Quinn Information Criterion

جدول (۱-۲) خلاصه ای از مدل های شبکه های عصبی با آموزش با ناظر [۱۵].

ردیف	مدل	برخی از مشخصات مدل
۱	آدالاین و مادالاین	مدل های مادالاین از چندین مدل آدالاین که به صورت موازی متصل شده اند تشکیل شده است. تنها یک نورون در سطح میانی شبکه دارد. ورودی ها دارای دو ارزش ۱ و -۱ هستند. وزن ها به صورت + یا - علامت گذاری شده اند.
۲	پس انتشار بازخورد	یک یا چند لایه پنهان از نورون های سیگموئید و در پی آن یک لایه خروجی از نورون های خطی دارد. وزن ها در طول فاز آموزش شبکه محاسبه می شود. روش معکوس در محاسبه وزن ها از نظر بیولوژیکی منطقی نیست. گستردگی در محاسبات باعث کاهش سرعت آموزش می شود.
۳	پرسپترون (MLP)	از پرکاربردترین آرایش های شبکه های عصبی در طراحی کنترل کننده ها و شناسایی سیستم ها یک ترکیب استاندارد از ورودی ها، واحدهای میانی و خروجی هاست. پردازش از هر لایه به تمام واحدهای لایه بعد. مشکل کمینه محلی دارد. روش مستقیمی برای پیدا کردن ساختار نهایی برای فرایند مدل سازی این شبکه وجود ندارد. استاندارد پرسپترون چندلایه، راه حل هایی غیر قابل پیش بینی از نظر طبقه بندی داده ها فراهم می کند.
۴	دستگاه کنترل کننده رفتار مغز CMAC	شبیه الگوریتم پس انتشار خطا سرعت بالاتر (از الگوریتم کمترین میانگین مربعات ویدور استفاده می کند). خروجی ها و ورودی های آن مقادیر دو ارزشی هستند ۰ و ۱
۵	احتمالی (PNN) ^۱	یک نمونه طبقه بندی کننده است که در یک لحظه مرزهای بهینه بین طبقات را تقریب می زند. دولایه پنهان دارد که بر اساس یک رابطه طبقه طبقه به هم مربوط اند. در طی آموزش، این شبکه الگوهای آموزشی را با تخمین توزیع های احتمالی طبقات به کار می برد. به هر ورودی جدید با توجه به میانگین وزن دار شده، نزدیکترین مثال های آموزشی طبقه بندی می شود.
۶	هاپ فیلد	مطابقت با ماهیت غیر همزمانی مدل های بیولوژیکی دارای اتصالات درونی کامل و یک شبکه تصادفی و ناهمزمان، در تضاد با پرسپترون شبکه کاملاً متصل خود پیوند، متشکل از یک لایه نورونی شامل ورودی های دو ارزشی (دوتایی ۰ و ۱ و یا دوقطبی ۱ و -۱).
۷	تاخیر زمانی (TDNN)	یک خط انتقال کنترل شده (به عبارت دیگر یک ثبات انتقالی) به همراه پرسپترون چندلایه استفاده می کند. (ورودی های آن خروجی های ثابت انتقالی اند). خروجی آن وابستگی موقت و محدودی به ورودی دارد. زمانی که خروجی از طریق یک واحد تاخیر به ورودی پسخورد داده می شود، شبکه برابر با یک فیلتر با پاسخ ضربه ای بی نهایت می باشد.

^۱ Probabilistic Neural network

۸	پس انتشار آبخاری پیشرو	نورون های هر لایه به نورون های تمامی لایه های قبلی ارتباط دارد. معماری دینامیک شبکه توانایی تخمین هر تابعی با تعداد نقاط ناپیوستگی محدود اتصالات از پیچیدگی لازم برخوردارند سرعت نسبتاً مطلوب.
---	---------------------------	--

۲-۱۵- تحلیل پوششی داده ها

۲-۱۵-۱- مفهوم تحلیل پوششی داده ها

تجزیه و تحلیل پوششی داده ها یک روش ریاضی مبتنی بر برنامه ریزی خطی برای بدست آوردن کارایی نسبی واحدهای تصمیم گیری (DMU) با چندین ورودی و خروجی بدون نیاز به ادغام آنها است که برای اولین بار آن را چارنز^۱، رودرز و کوپر در سای ۱۹۸۷ ارائه نمودند. این روش برای کارایی نسبی واحدهای تصمیم گیری که وظایف یکسانی انجام می دهند، به کار می رود، مانند سنجش و مقایسه کارایی نسبی واحدهای سازمانی نظیر ادارات دولتی یک وزارت خانه، شعب بانک ها و موارد مشابه که در آن واحدهای تصمیم گیری همگنی وجود دارد. همچنین این روش به طور گسترده در الگوبرداری، بهبود مستمر و تحلیل استراتژیک به کار می رود [۱۵].

تجزیه و تحلیل پوششی داده ها به عنوان یک روش غیر پارامتری قادر است کارایی نسبی واحدهای تصمیم گیر را بر اساس نسبت متوازن چندین ورودی و خروجی بدون هیچ گونه پیش فرضی در مورد عملکرد تولید و در صورتی که سازمان دارای چندین خروجی یا واحد متفاوت باشد، اندازه گیری کند. این روش در ارزیابی کارایی مشکلی ندارد. مزیت اصلی این مدل نسبت به روش های پارامتری این است که اگر چندین ورودی و چند خروجی وجود داشته باشد، به طوری که هیچ شاخصی برای تبدیل آنها وجود ندارد، در عین حال هیچ توافق کلی در مورد وزن یا اهمیت آنها وجود نداشته باشد، کاربرد دارد. از سوی دیگر، مدیران یا مدل های حاوی شاخص های بهره وری جزئی معمولاً سعی می کنند کارایی و بهره وری را اندازه گیری کنند، اما در نظر گرفتن جداگانه شاخص ها و نادیده گرفتن رابطه

^۱ Charnes

بین آنها، تصویر ناقصی از موضوع مورد مطالعه ایجاد می کند. این مشکل با استفاده از روش تحلیل پوششی داده ها حل می شود [۱۵].

واژه «نسبی»^۱ یک کلمه کلیدی در تعریف تجزیه و تحلیل پوششی داده ها است، زیرا یک واحد تصمیم گیری ممکن است به عنوان یک واحد کارآمد توسط مجموعه ای از داده های سایر DMU ها شناخته شود، در حالی که در مقایسه با مجموعه داده های دیگر، ناکارآمد تشخیص داده شود. نقطه شروع برای استفاده از تجزیه و تحلیل پوششی داده ها، ایجاد نسبت سازگاری از مجموع وزنی خروجی ها به مجموع وزنی ورودی ها برای هر واحد تصمیم گیری است [۷].

مدل های تحلیل پوششی داده ها در حقیقت فضایی محدب ایجاد می کنند که شامل تمام واحدهای مورد ارزیابی است. از این رو به آنها «مدل های پوششی» گفته می شود. در چنین مدل هایی، آن واحدهایی که در مرز نهایی فضای محدب واقع شده و مرز این فضا را تشکیل می دهند، واحدهای کارآمد هستند و سایر واحدهایی که در داخل فضای محدب قرار دارند، واحدهای ناکارآمد هستند. مدل های تجزیه و تحلیل پوششی داده های اساسی تنها واحدهای ناکارآمد را با نمره کارایی بین صفر تا یک رتبه بندی می کنند [۱۰].

۲-۱۵-۲- مزایای تحلیل پوششی داده ها

موارد زیر را می توان از جمله مزایای تحلیل پوششی داده ها دانست [۱۸]:

- ۱- می توان از عهده ی ورودی ها و خروجی های چندگانه در هنگام سنجش کارایی نسبی واحدهای تصمیم گیری برآمد.
- ۲- نیاز به تعیین تابع تولیدی که ورودی ها را به خروجی تبدیل می کند، نیست.
- ۳- می توان ورودی ها و خروجی های را که واحدهای سنجش گوناگونی دارند در مدل وارد کرد.

^۱ Relative

۲-۱۵-۳- معایب تحلیل پوششی داده ها

موارد زیر را می توان از جمله معایب تحلیل پوششی داده ها دانست [۱۸]:

- ۱- این تکنیک برای برآورد کارایی نسبی مناسب است؛ یعنی می تواند مشخص کند که واحد نسبت به سایر واحدها چگونه عمل می کند ولی نسبت به عملکرد بهینه از نظر تئوری، مقایسه ای را ممکن نمی سازد.
- ۲- چون در حالت استاندارد، باید برای هر واحد تصمیم گیری یک برنامه خطی جداگانه تهیه شود، حل مسائل بزرگ، حتی به کمک نرم افزار، کار مشکلی است.
- ۳- چون روشی است که مبتنی بر نقطه حدی است، خطای اندازه گیری ورودی ها یا خروجی ها می تواند انحراف زیادی را در پاسخ ها به بار آورد.

۲-۱۵-۴- مدل های پایه ای تحلیل پوششی داده ها

در مجموع، تقسیم بندی مدل های تحلیل پوششی داده ها در دو گروه ورودی محور و خروجی محور می باشد. مدل های مبتنی بر ورودی مدل هایی هستند که از ورودی های کمتری برای بدست آوردن مقدار یکسان خروجی بدون تغییر خروجی استفاده می کنند و مدل های خروجی محور مدل هایی هستند که بدون تغییر ورودی، خروجی بیشتری تولید می کنند [۳].

در تجزیه و تحلیل پوششی داده ها، دو نوع استراتژی برای بهبود عملکرد واحدها وجود دارد:

- ۱- کاهش ورودی ها بدون کاهش خروجی ها تا رسیدن به یک واحد در حد کارایی. این نگرش را ماهیت ورودی بهبود عملکرد یا اندازه گیری عملکرد با ماهیت ورودی می نامند.
- ۲- افزایش خروجی ها برای رسیدن به واحد در حد کارایی، بدون جذب ورودی های بیشتر. این نگرش را ماهیت خروجی بهبود عملکرد یا اندازه گیری عملکرد با ماهیت خروجی محور می نامند [۱۵].

نوعی دیگر از طبقه بندی DEA بر مبنای نوع بازگشت به مقیاس آن می باشد که به دو نوع اصلی تقسیم می شود: الف) بازده به مقیاس ثابت (CRS). ب) بازده به مقیاس متغیر (VRS یا BBC) بازده به مقیاس ثابت فرض می کند که خروجی ها همیشه متناسب با ورودی ها افزایش می یابند،

ولی در بازده به مقیاس متغیر این تناسب نیاز نیست که این به معنای آن است که افزایش در مقدار خروجی، بیشتر یا کمتر از نسبت افزایش در مقدار ورودی است. مدل های CCR و BCC را مدل های شعاعی DEA نیز می نامند. این مدل ها ابتدا نیاز به یک جهت گیری دارند که می تواند «جهت گیری ورودی» و «جهت گیری خروجی» باشد [۱۵]. بنابراین هر یک از این دو مدل، به دو صورت خروجی محور و ورودی محور مطرح می شوند.

در ادامه مدل های BCC خروجی محور آورده شده است.

۲-۱۵-۵- مدل های BCC خروجی محور

$$\text{Max } \theta$$

$$\text{s.t. } x_{i0} \geq \sum_{j=1}^n \lambda_j x_{ij} \quad i=1, \dots, m$$

$$\theta y_{r0} \leq \sum_{j=1}^n \lambda_j y_{rj} \quad r=1, \dots, s$$

$$\sum_{j=1}^n \lambda_j = 1 \quad (2-30)$$

$$\lambda_j \geq 0 \quad j=1, \dots, n$$

که داده های رابطه ی (۲-۳۰) به صورت زیر می باشد:

θ : مقدار کارایی واحد تصمیم گیرنده

y : مقدار خروجی

λ : وزن خروجی ها و ورودی ها

x : مقدار ورودی ها

۲-۱۶- مدل ترکیبی شبکه عصبی و تحلیل پوششی داده ها

در این مطالعه، با آشنایی با مفاهیم اساسی شبکه های عصبی و تحلیل پوششی داده ها، به دنبال ارزیابی کارایی شرکت های بورسی هستیم. با ترکیب شبکه های عصبی و تجزیه و تحلیل پوششی داده ها، الگوریتمی برای ارزیابی کارایی شرکت ها ارائه می شود. به طور کلی، استفاده از شبکه های

عصبی و تجزیه و تحلیل پوششی داده ها زمانی اهمیت زیادی دارد که داده های ورودی و خروجی زیاد باشد و مدل های خطی با ارزیابی ها و محاسبات عملکرد مطابقت نداشته باشند. بنابراین، می-توان سطح کارایی را محاسبه کرد، بهترین محصول را انتخاب کرد و کارایی را پیش بینی کرد و سپس آنها را با ادغام DEA و شبکه های عصبی رتبه بندی کرد. در این پایان نامه، ما از DEA برای ارزیابی شرکت های بورسی و از شبکه های عصبی برای پیش بینی مقیاس عملکرد استفاده کرده ایم. در خاتمه مرز ساخته شده توسط شبکه های عصبی، برای پیش بینی و تقریب توابع غیر خطی کارایی استفاده می شود.

می توان با ترکیب DEA و شبکه های عصبی بر برخی از محدودیت های ایجاد شده توسط مدل های DEA غلبه کرد. نتایج نشان می دهد که مدل های پایه DEA توانایی پیش بینی و تجزیه و تحلیل عملکرد را ندارند، بنابراین از شبکه های عصبی استفاده شد. مشاهده شده است که شبکه های عصبی دارای قدرت بالایی در یادگیری الگوهای عملکردی هستند، اما باید توجه داشت که شبکه باید به درستی آموزش ببیند. استفاده از شبکه های عصبی و ادغام آن با DEA می تواند در مواردی مورد استفاده قرار گیرد که مدل های اولیه قادر به تشخیص واحدها نیستند. در مقایسه با روش های ریاضی و ترکیبی تجزیه و تحلیل عملکرد، شبکه عصبی نتایج قابل قبولی را ارائه می دهد. با مقایسه DEA و شبکه عصبی می توان دریافت که شبکه های عصبی نسبت به DEA به فرضیات کمتری در مورد الگوها و عملکردها نیاز دارند و در عین حال انعطاف پذیری بیشتری نیز دارند. شبکه های عصبی مرزی نیز عملکرد قوی تر و انعطاف پذیرتری نسبت به DEA نشان می دهند و می توانند برای حل مشکلات در مقیاس بزرگتر مورد استفاده قرار گیرند. مزیت این است که نیازی به حل یک مدل ریاضی برای هر تصمیم گیرنده نیست.

نتایج تحقیقات بیانگر این است که اولاً، هموارسازی داده ها می تواند پیش بینی انجام شده را بهبود ببخشد و ثانياً، مدل شبکه ی عصبی- فازی با توجه به میزان کم خطا، دارای همگرایی سریع و توانایی تقریب بالایی است و برای پیش بینی کارایی مناسب است.

یافته ها و نتایج تحقیقات نشان داده اند، رفتار سری های زمانی قیمت سهام شرکت ها و شاخص های موجود در بازار سهام تصادفی نیست اما این فرایند غیر تصادفی دارای پیچیدگی های زیادی است و وقتی از شبکه های عصبی برای پیش بینی استفاده می شود، در طراحی مدل شبکه عصبی نیاز به استفاده از متناسب با تعداد لایه ها و نوروں های میانی متناسب می باشیم.

براساس معیار های ارزیابی شبکه عصبی می توان چنین نتیجه گرفت که شبکه عصبی توانایی پیش-بینی روند کارایی شرکت های بورس اوراق بهادار را دارد و این امر تایید دیگری بر توانایی شبکه عصبی در پیش بینی های حوزه مالی می باشد.

از آنجا که برای مقایسه مدل های ترکیبی معیار خطای پایین، مناسب تشخیص داده شد، در این پژوهش خطای هر مدل با استفاده از شبکه های عصبی و با استفاده از تابع MSE برآورد شد.

تمرکز اصلی مطالعه حاضر بر ارزیابی عملکرد و پیش بینی سبد شرکت های بورس اوراق بهادار در بازه زمانی سال های ۱۳۸۸ تا ۱۳۹۷ است. برای ارزیابی عملکرد شرکت های بررسی شده از رتبه نقد شوندگی، ریسک، ضریب بتا و بازده سالانه شرکت ها استفاده شد. برای پیش بینی ارزیابی عملکرد شرکت ها از شبکه های عصبی خودبرگشتی غیرخطی با ورودی های برونزاد^۱ (NARX) و شبکه های عصبی سیستم استنتاج عصبی- فازی سازگار (ANFIS) استفاده شد.

مدل پیشنهادی در این تحقیق شامل دو قسمت است: پیش پردازش و پردازش. بخش پیش پردازش شامل قرار دادن داده ها و انتخاب ویژگی است. بخش پردازش همان پیش بینی کننده ای است که در اینجا روش هوشمند شبکه های عصبی فازی است.

از آنجا که شبکه های عصبی فازی قادر به آموزش هستند در الگوریتم پیشنهادی می توانند قوانین فازی را به طور خودکار بدست آورند. این شبکه از انعطاف پذیری بالایی برخوردار است به طوری که با تغییر تعداد ورودی ها و خروجی ها، این شبکه قابلیت تعمیم را دارد. با افزایش تعداد ورودی ها و افزایش تعداد توابع عضویت، تعداد پارامترهای آن به صورت نمایی افزایش می یابد.

۲-۱۷- پیشینه پژوهش

رویکرد که اخیرا در برخی از مطالعات پیشنهاد شده، تخمین مرز کارایی با استفاده از شبکه های عصبی مصنوعی است. شبکه های عصبی به دلایلی مانند دقت بالا در برآورد توابع تولید، توانایی کار در محیط های غیر خطی و پیش فرض های کوچک در مورد شکل عملکرد تولید توجه خاصی را به خود جلب کرده اند [۲۹].

در این پژوهش به مطالعاتی که با استفاده از روش ترکیبی DEA-ANN به ارزیابی کارایی پرداخته اند اشاره می شود.

^۱ Nonlinear autoregressive with exogenous inputs (NARX)

۲-۱۷-۱- پیشینه داخلی

در سال ۱۳۸۷ عزیزاده صانع ارزیابی کارایی سیستم بانکی با استفاده از روش تجزیه و تحلیل پوششی داده ها که توسط بانک صادرات ایران مورد بررسی قرار گرفت، را ارزیابی کرد. در سال ۱۳۸۴، یوسفی حاجی آبادی با استفاده از تحلیل پوششی داده ها، کارایی فنی شعب بانک مسکن را برآورد و ارزیابی کرد.

کارایی ۸۵ شعبه بانک تجارت در استان مازندران محاسبه و با استفاده از شبکه های عصبی و تحلیل پوششی داده ها مقایسه شده است [۱۳]. انتخاب و ارزیابی تأمین کنندگان فرآیندهای تصمیم گیری تصادفی مهمی هستند که به دیدگاه های متفاوتی نیاز دارند. کشف ترکیبی جدید از شبکه عصبی و تحلیل پوششی داده ها، هدف ارزیابی تأمین کنندگان تحت اطلاعات ناقص از معیارهای ارزیابی بود. در سال (۱۳۸۵) مهرگان و همکاران، با استفاده از مدل ترکیبی شبکه های عصبی و تحلیل پوششی داده ها، کارایی فنی پالایشگاه های نفت کشور را مورد تجزیه و تحلیل قرار داد. آنها در تحقیقات خود، بهره وری فنی پالایشگاه های نفت کشور را با استفاده از مدل ترکیبی شبکه های عصبی و تجزیه و تحلیل پوششی داده ها (DEA-Neuro) مورد تجزیه و تحلیل قرار دادند. آنها کارایی هر پالایشگاه را با سه ورودی اندازه گیری کردند: خوراک، تعداد پرسنل و انرژی مصرفی و از شش خروجی بنزین، نفت گاز، نفت سفید، گاز مایع، نفت کوره و سایر محصولات استفاده نمودند. مدل شعاعی^۱ برای تعیین کارایی پالایشگاه ها مورد استفاده قرار گرفت و مشاهده شد که DEA قادر به تشخیص کارایی پالایشگاه ها از یکدیگر نیست، چراکه تعداد واحدهای تصمیم گیرنده کمتر از تعداد ورودی ها و خروجی ها است. برای حل این مشکل، سال های مختلف به عنوان DMU های مختلف استفاده شده است، به طوری که تعداد پالایشگاه های در نظر گرفته شده ۹ واحد است. که با توجه به داده های ۳ ساله، به ۲۷ واحد افزایش می یابد، اما مشاهده شد که با محاسبه کارایی پالایشگاه ها در سال های مختلف، مشکل مدل های اولیه DEA هنوز ادامه دارد. بر این اساس از توپولوژی و الگوریتم یادگیری متفاوت استفاده شد. نتایج این مطالعه نشان داد که شبکه های عصبی قدرت بالایی در یادگیری الگوی کارایی دارند و از شبکه های عصبی و ادغام آن با DEA در مواردی که مدل های اصلی توانایی تفکیک پذیری و تشخیص واحدها را ندارند استفاده کرد، همچنین در مقایسه با روش های ریاضی و

^۱ Radial models

تحلیل کارایی ترکیبی، شبکه های عصبی نتایج قابل قبول تری ارائه می دهند.

در سال (۱۳۸۹) پدرام در تحقیقی عملکرد شعب بانک ها را با رویکرد تحلیل پوششی داده های عصبی- فازی مقایسه کرده است. در این تحقیق از روش DEA برای ارزیابی کارایی شعب درجه یک بانک تجارت از منظر سود استفاده شده است. همچنین، برای افزایش وضوح و افزایش قدرت پیش-بینی، از مدل ترکیبی ANN و DEA در دو حالت قطعی و فازی استفاده شده است. نتایج این مطالعه نشان می دهد که ANN های مشخص و فازی به دلیل استحکام و انعطاف پذیری الگوریتم های مدل سازی، پتانسیل بالایی برای برآورد نتایج روش DEA دارند. همچنین نشان داده شده است که بین نتایج تحلیل عصبی و تحلیل عصبی فازی تفاوت معنی داری وجود ندارد، اما نمرات به دست آمده از DEA فازی به دلیل اهمیت متفاوت با سه رویکرد دیگر تفاوت معنی داری دارد.

ارزیابی کارایی شعب بانک اقتصاد نوین با ترکیبی از روش شبکه عصبی و تحلیل پوششی داده ها توسط محرابیان و همکاران (۱۳۹۰) انجام گرفته است. اجلی و صفری (۱۳۹۰) به ارزیابی عملکرد و کارایی شرکت های گاز استانی با استفاده از مدل ترکیبی شبکه های عصبی پیش بینی کننده و تحلیل پوششی داده ها پرداختند.

اسکندری، غلامی و شفيعی (۱۳۹۱) در مطالعه ای در ارزیابی کارایی نسبی شعب مختلف یک بانک به طراحی یک مدل ترکیبی از DEA و شبکه های عصبی پرداختند. بررسی عملکرد شبکه های عصبی مصنوعی در پیش بینی کارایی سرمایه فکری شرکت های پذیرفته شده در بورس اوراق بهادار تهران توسط فاضل یزدی و همکاران (۱۳۹۲) انجام گرفته است.

طراحی مدل ارزیابی عملکرد و پیش بینی عملکرد بانک ها حاضر در بورس با شبکه عصبی مصنوعی و تکنیک DEA در بازه سال ۹۰ تا ۹۶ توسط محبی و همکاران (۱۳۹۸) صورت پذیرفت.

نتایج نشان می دهد که قدرت پیش بینی شبکه عصبی آموزش دیده تحت مجموعه ای از داده های آموزش "کارآمد" قوی تر از پیش بینی عملکرد یک شبکه آموزش دیده در زیر مجموعه ای از داده های "ناکارآمد" است.

۲-۱۷-۲- پیشینه خارجی

فارل^۱ در سال ۱۹۵۷ ابتدا کارایی یک واحد تولیدی را با استفاده از روش غیر پارامتری اندازه گیری کرد. محققانی مانند چارنز و همکارانش دیدگاه فارل را بیشتر توسعه دادند و یک مدل تحلیلی برای پوشش داده ها ارائه کردند. با توجه به فناوری های جدید و رقابت در بازار خدمات مالی، تجزیه و تحلیل عملکرد بانک ها و شرکت ها امروزه مورد توجه بسیاری از مدیران قرار گرفته است. بر این اساس، اخیراً تحقیقات زیادی برای ارزیابی کارایی بانک ها انجام شده است.

کارایی نسبی یک شعبه بانک بریتانیا در یک مطالعه تجربی با استفاده از تحلیل پوششی داده ها توسط دراک و هاگروفت^۲ در ۱۹۹۴ مورد بررسی قرار گرفت. طراحی یک سیستم جامع ارزیابی عملکرد فنی برای ۳۳ صنعت تحت پوشش با استفاده از مدل تحلیل پوششی داده ها توسط شرمن و لاندینو^۳ در سال ۱۹۹۵. پارکان^۴ در سال ۱۹۸۷، ۳۵ شعبه یک بانک در کانادا را در این زمینه ارزیابی کرد.

برای ارزیابی و تحلیل کارایی بانک ها در تحقیقات فوق از تحلیل پوششی داده ها استفاده و بهره گرفته شده است. یکی از مشکلات اصلی استفاده از تحلیل پوششی داده ها عدم وضوح و عدم ناتوانی در پیش بینی برای واحد های تصمیم گیری است. به دلیل شباهت های بین تحلیل پوششی داده ها و شبکه های عصبی مصنوعی و همچنین قابلیت های برتر شبکه های عصبی مصنوعی که در بخش های بعدی ذکر می شود، اخیراً ثابت شده است که شبکه های عصبی مصنوعی جایگزین مناسبی برای برآورد مرزهای کارآمد در تولید هستند. تحقیقات زیادی در این زمینه انجام شده است، مشاهده شده است که شبکه های عصبی مصنوعی ابزار خوبی برای تقریب بسیاری از مشکلات غیر پارامتری و غیر خطی هستند که توسط جین و ناگ^۵ در سال ۱۹۹۵ و شاولیک، مونی و تاوول^۶ در سال ۱۹۹۱ مورد بررسی قرار گرفت.

۱ Farell

۲ Drake and Hakruft

۳ Sherman and Landina

۴ Parkan

۵ Jean & Nag

۶ Shavlik , Moni and Towel

در سال ۱۹۹۷ کارایی مترو لندن با استفاده از داده های سری زمانی مورد تجزیه و تحلیل قرار گرفت و نتیجه گرفته شد که نتایج شبکه عصبی با حداقل مربعات معمولی^۱ تصحیح شده و تحلیل پوششی داده ها بسیار مشابه است. در سال ۲۰۰۰، از شبکه های عصبی برای برآورد توابع هزینه استفاده شد و در سال ۲۰۰۴ نیز سانتین^۲ از یک شبکه عصبی برای شبیه سازی یک تابع تولید غیرخطی استفاده کرد و نتایج آن را با تحلیل پوششی داده ها مقایسه کرد. سانتین، ۲۰۰۷ نمای مرز ضخیم شبکه های عصبی را ارائه کرد و آن را با تحلیل پوششی داده ها مقایسه کرد. ارزیابی عملکرد ۷۲ اداره شهری در اسپانیا توسط دلگادو^۳ در ۲۰۰۵ با استفاده از مدل اساسی تحلیل پوششی داده ها و شبکه های عصبی، شبکه های عصبی را به عنوان ابزاری برای اندازه گیری کارایی مطرح کرده است. علاوه بر این، ۲۵۰ شعبه بانک در کانادا توسط آتناسوپولوس و کورام^۴ در سال ۱۹۹۶ مورد ارزیابی قرار گرفت و نتایج شبکه های عصبی با مدل اصلی تحلیل پوششی داده ها مقایسه شد. ترکیبی از شبکه عصبی و تحلیل پوششی داده ها برای ارزیابی تامین کنندگان تحت اطلاعات ناقص توسط سلیمی و بیرکتر^۵ در ۲۰۰۷ پیشنهاد شد. ارزیابی عملکرد ۱۴۲ بانک بزرگ در کشور کانادا با استفاده از روش تجزیه و تحلیل پوششی داده ها و شبکه های عصبی ترکیبی انجام شده است [۳۰].

مصطفی در سال ۲۰۰۷ عملکرد بانک های عربی را با استفاده از روش های مشابه ارزیابی کرد. با استفاده از ترکیبی از تحلیل پوششی داده ها و شبکه عصبی، یک الگوریتم جدید برای پوشش برخی از نقاط ضعف مدل تحلیل پوششی داده ها پیشنهاد شده است [۲۵].

در سال ۲۰۰۳ وانگ^۶ در بررسی های خود نشان داد که شبکه های عصبی به بهبود مدل در یافتن داده های پنهان موجود در کل مجموعه داده کمک می کند. ایده ترکیب شبکه عصبی و تجزیه و تحلیل پوششی داده ها برای طبقه بندی یا پیش بینی ابتدا توسط آتناسوپولوس و کوراما (۱۹۹۶) مطرح شد. آنها تجزیه و تحلیل پوششی داده ها را به عنوان یک روش پیش پردازش برشمردند که شیوه های یادگیری را در مطالعه پیش بینی تعداد کارکنان برای مراقبت های بهداشتی صنعت نشان داد. در این تحقیق، پس از انتخاب نمونه ها، روش شبکه های عصبی به عنوان ابزاری برای یادگیری

^۱ Ordinary Least Squares (COLS)

^۲ Santin

^۳ Delgado

^۴ Athanassopoulos and Curram

^۵ Celebi and Bayraktar

^۶ Wang

مدل پیش بینی غیرخطی آموزش داده می شود. به گفته کاستا و مارکلو^۱ (۱۹۹۷) شبکه های عصبی با استفاده از روش حداقل مربعات معمولی مقایسه شده اند و بر این اساس، برنامه تجزیه و تحلیل پوششی داده ها برای تجزیه و تحلیل عملکرد شبکه های مخفی لندن اصلاح شده است. یافته های آنها نشان می دهد که واحدهای تصمیم گیری در شبکه های عصبی به دلیل تأثیر مثبت کارایی در مقیاس متغیر، در برابر نقاط متراکم بهتر عمل می کنند. فلسیگ، کاستنز، و ترل^۲ (۲۰۰۰) برآورد هزینه با شبکه های عصبی را آزمایش کردند. آنها همچنین چند مدل را نشان دادند که مشکلات همگرایی را در یادگیری شبکه های عصبی حل می کند. پندهارکر و راجر^۳ (۲۰۰۳) از تحلیل پوششی داده ها به عنوان یک رویکرد برای غربالگری داده ها برای ایجاد زیرمجموعه ای از نمونه آموزش تقریباً یکنواخت استفاده کردند که این ویژگی کلیدی برای برخی از مشکلات پیش بینی است.

امروزنژاد و همکاران (۲۰۱۵) با یک رویکرد از شبکه عصبی به ارزیابی کارایی مجموعه داده های مقیاس بزرگ با داده های منفی پرداختند. یکپارچه سازی تحلیل پوششی داده معکوس و شبکه عصبی برای حفظ مقادیر کارایی توسط صانعی و همکاران (۲۰۱۷) بررسی شد. پندهارکار (۲۰۱۸) به بررسی مدل های تحلیل پوششی داده ها برای طبقه بندی احتمالی پرداخت، که در آن از مدل ترکیبی DEA و شبکه عصبی احتمالی استفاده می کند.

تحت عنوان دو الگوی غیرپارامتری، شباهت های زیادی بین مدل های شبکه عصبی مصنوعی و تحلیل پوششی داده ها وجود دارد [۲۳]، به عنوان مثال:

نه تجزیه و تحلیل پوششی داده ها و نه شبکه های عصبی مصنوعی هیچ فرضی در مورد شکل عملکردی که ورودی را به خروجی پیوند می دهد، ندارند.

تجزیه و تحلیل پوششی داده ها به دنبال تعیین وزنی است که کارایی صنعتی را به حداکثر برساند. شبکه های عصبی به دنبال وزن هایی هستند که از طریق داده های آموزشی بیشترین بهره را از مشاهدات ببرند.

^۱ Costa and Markellos

^۲ Flisyg , Kastnz and Terrell

^۳ Pendharkar and Rodger

فصل ۳:

تجزیه و تحلیل داده ها

رویکردهای مورد استفاده و مدل های طراحی شده در این تحقیق در فصل دوم، مورد مطالعه قرار گرفت. در این فصل، مدل های ترکیبی طراحی شده با تجزیه و تحلیل پوششی داده ها و شبکه های عصبی مصنوعی پیاده سازی و تجزیه و تحلیل می شوند و به سوالات تحقیق مطرح شده در فصل اول پاسخ داده می شود.

۳-۱- مقدمه

در این تحقیق با الهام از روش های شبکه عصبی و با استفاده از مدل های DEA، مقیاس کارایی محاسبه شده است. به طور کلی، ادغام مدل های DEA و شبکه های عصبی از این منظر که دارای توانایی منحصر به فرد برای داده های نسبی است، مهم است. ایده این تحقیق به شرح زیر است:

- ۱- مقیاس کارایی واحدهای تصمیم گیرنده را در DEA محاسبه می کنیم.
 - ۲- با استفاده از شبکه های عصبی، واحدهای طبقه بندی شده آموزش، ارزیابی مجدد می شوند و مقیاس کارایی بر اساس آن مشخص می شود.
- در بخش دوم مدل هایی از DEA ارائه می شود و در بخش سوم الگوریتم شبکه های عصبی و DEA پیشنهاد می شود.

۳-۲- معیارهای مناسب برای مقایسه مدل های ترکیبی

با استفاده از ادبیات موضوعی و مرور مطالعات قبلی، معیارهای مقایسه مدل های ترکیبی، معیارهایی مانند وضوح مدل و میزان خطای مدل شناسایی و تعیین شد. هدف از این مطالعه ارزیابی کارایی شرکت های پذیرفته شده در بورس اوراق بهادار با استفاده از تکنیک های ترکیبی ANN و DEA بود. با توجه به اینکه نتایج ارزیابی عملکرد با استفاده از DEA دارای وضوح پایین بوده و قدرت تفکیک پذیری در ارزیابی عملکرد بسیار مهم است، بنابراین یکی از معیارهای مقایسه مدل ترکیبی وضوح است، همچنین مدلی با خطای کمتر پاسخ بهینه بهتری را دریافت می کند. بنابراین، یکی دیگر از معیارهای مقایسه، خطای مدل است.

۳-۳- تعیین ورودی ها و خروجی های مناسب به منظور ارزیابی کارایی شرکت های بورس اوراق بهادار

در این پژوهش ۹ شاخص کمی انتخاب شد. سپس در مورد اینکه کدام شاخص ها در ارزیابی کارایی ورودی و کدام خروجی هستند، تحقیق شد.

داده هایی که ما در اختیار داریم : ۱- قیمت پایانی روزانه هر سهم ۲- بازده ۳- ریسک ۴- نسبت قیمت به درآمد هر سهم (p/e) ۵- ارزش معاملات ۶- تعداد دفعات معامله ۷- حجم معاملات ۸- رتبه نقدشوندگی ۹- ضریب بتا

با توجه به مطالعات انجام شده در تلاشیم که داده های ورودی را کمتر کنیم و داده های خروجی را افزایش دهیم بنابراین با توجه به نظر خبرگان بورسی و تحقیقات قبلی مبنی بر تکراری نبودن داده ها ماهیت ورودی ها و خروجی ها به شرح زیر می باشد:

داده های ورودی: رتبه نقدشوندگی، ریسک، ضریب بتا

داده های خروجی: بازده

۳-۴- مطالعه موردی

در این بخش با در نظر گرفتن ۲۷۹ شرکت حاضر در بورس اوراق بهادار ایران از سال های ۱۳۸۸ الی ۱۳۹۷ و با ورودی های رتبه نقدشوندگی، ریسک و ضریب بتا و خروجی بازده و با توجه به ساختار بورس اوراق بهادار و استفاده از مدل DEA مقیاس کارایی را برای تمام ۲۷۹ شرکت محاسبه می-کنیم. از آنجا که امکان ارائه تمام ورودی ها و خروجی های ۲۷۹ شرکت در اینجا امکان پذیر نیست، در زیر داده های ۲۰ شرکت ابتدایی بورس به ترتیب حروف الفبا با داده های ورودی برای سال ۱۳۸۸ و ۱۳۸۹ مشخص شده که در جدول (۳-۱) نمایش داده شده است.

جدول (۱-۳) داده های ورودی ۲۰ شرکت اول بورس اوراق بهادار

داده های مربوط به سال ۱۳۸۹				داده های مربوط به سال ۱۳۸۸			
ضریب بتا	ریسک	رتبه نقد شونددگی	۲۰ شرکت اول	ضریب بتا	ریسک	رتبه نقد شونددگی	۲۰ شرکت اول
۰/۶۱	۳/۲۴	۲۰۷	۱	۰/۵۲	۵/۶۵	۲۳۵	۱
۰/۴۰	۱/۸۸	۹۹	۲	۰/۴۰	۱/۶۰	۴۶	۲
۱/۰۸	۱/۴۹	۴۴	۳	۰/۳۸	۲/۰۸	۴۹	۳
-۰/۹۲	۲/۵۹	۲۲۱	۴	-۰/۵۹	۱/۵۰	۲۱۵	۴
۰/۶۰	۱/۴۴	۲۰۲	۵	۱/۲۹	۳/۱۴	۱۴۹	۵
۱/۱۳	۱/۹۷	۹۰	۶	۱/۹۳	۲/۴۷	۱۴۴	۶
۰/۰۸	۱/۷۴	۱۶۷	۷	۰/۲۳	۲/۴۷	۱۱۷	۷
۰/۶۹	۱/۶۵	۱۸	۸	-۰/۰۹	۲/۰۱	۸	۸
۲/۱۴	۲/۴۲	۲۷	۹	-۰/۰۸	۱/۴۰	۹۸	۹
۲/۱۷	۲/۴۵	۲۶	۱۰	۰/۵۰	۲/۱۰	۱۷	۱۰
۰/۲۳	۲/۰۴	۱۶۴	۱۱	-۰/۰۹	۲/۴۳	۱۶۰	۱۱
-۱/۲۵	۷/۶۰	۲۴۸	۱۲	۰/۲۴	۵/۵۴	۲۰۴	۱۲
۱/۲۱	۴/۲۳	۱۵۳	۱۳	-۲۲/۲۰	۵۹/۲۶	۲۶۰	۱۳
-۰/۱۹	۰/۶۰	۲۴۱	۱۴	-۰/۴۴	۱/۷۲	۲۲۳	۱۴
۰/۴۸	۲/۹۷	۱۳۷	۱۵	۰/۹۷	۳/۲۵	۱۳۳	۱۵
۱/۲۴	۱/۹۴	۱۲۰	۱۶	۰/۳۴	۲/۶۶	۵۹	۱۶
۲/۶۷	۲/۷۶	۲۳	۱۷	۳/۱۰	۸/۸۶	۳۳	۱۷
-۰/۳۸	۰/۸۹	۲۳۶	۱۸	-۰/۲۱	۳/۰۵	۱۸۵	۱۸
-۰/۱۰	۳/۲۱	۲۷۴	۱۹	-۰/۲۷	۴/۲۵	۲۵۸	۱۹
۰/۴۱	۱/۲۹	۲۲۵	۲۰	-۲/۷۰	۸,۴	۱۹۸	۲۰

داده های خروجی مربوط به ۲۰ شرکت اول از ۲۷۹ شرکت بورس نیز فقط برای سال های ۱۳۸۸ و ۱۳۸۹ در جدول (۲-۳) نمایش داده شده است.

جدول (۲-۳) داده های خروجی ۲۰ شرکت اول بورس اوراق بهادار

بازده سال ۱۳۸۹	بازده سال ۱۳۸۸	۲۰ شرکت اول
۰/۴۶	-۰/۴۰	۱
۰/۲۸	۰/۴۰	۲
۰/۱۶	۰/۱۸	۳
۰/۲۴	۰/۰۰	۴
۰/۲۴	۰/۶۳	۵
۰/۳۳	۰/۱۸	۶
۰/۰۱	۰/۷۴	۷
۰/۲۹	۰/۱۴	۸
۰/۶۴	-۰/۰۵	۹
-۰/۰۲	۰/۲۱	۱۰
۰/۳۲	۰/۴۵	۱۱
۱/۰۸	-۰/۶۰	۱۲
۰/۶۸	۷/۴۸	۱۳
-۰/۲۲	-۰/۴۵	۱۴
۰/۲۵	۰/۰۳	۱۵
۰/۰۱	۰/۳۵	۱۶
۰/۱۳	۰/۸۸	۱۷
-۰/۳۸	-۰/۱۶	۱۸
-۰/۵۳	-۰/۸۰	۱۹
۰/۲۲	-۱/۳۱	۲۰

به همین صورت داده های ورودی و خروجی برای سال های ۱۳۹۰ تا ۱۳۹۷ برای تمامی ۲۷۹ شرکت موجود بوده و در محاسبات استفاده شده است.

۳-۵- ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از تحلیل پوششی داده ها

ابتدا ۲۷۹ شرکت حاضر در بورس اوراق بهادار با سه ورودی ریسک، ضریب بتا و رتبه نقد شوندگی و یک خروجی بازده با استفاده از DEA ارزیابی شده اند که نتایج حاصل از آن در جدول (۳-۳) برای سال های ۱۳۸۸ تا ۱۳۹۲ و جدول (۴-۳) برای سال های ۱۳۹۳ تا ۱۳۹۷ برای ۲۰ شرکت اول بورس نشان داده شده است. سپس با استفاده از داده های جدول (۳-۳) و (۴-۳) به پیش بینی کارایی شرکت های بورسی در شبکه عصبی پرداخته ایم.

با توجه به اینکه نمایش داده ها برای ۲۷۹ شرکت بورسی امکان پذیر نبود، داده ها محاسبه شده کارایی به روش DEA را فقط برای ۲۰ شرکت اول، در جدول (۳-۳) و (۴-۳) نشان داده ایم.

جدول (۳-۳) محاسبه کارایی با استفاده از DEA از سال ۱۳۸۸ تا سال ۱۳۹۲

کارایی حاصل از DEA					
سال ۱۳۹۲	سال ۱۳۹۱	سال ۱۳۹۰	سال ۱۳۸۹	سال ۱۳۸۸	۲۰ شرکت اول
۰/۴۳۳۳۷۳	۰/۵۰۳۹۹۶	۰/۲۵۸۲۱۲	۰/۶۹۰۹۶۷	۱	۱
۰/۵۸۰۶۳	۰/۶۴۲۱۳۹	۰/۳۷۵۲۹۸	۰/۷۸۸۰۵۵	۰/۶۴۱۰۵۶	۲
۰/۶۴۴۵۴۵	۰/۵۱۴۶۴۷	۰/۱۸۶۹۰۲	۰/۷۲۷۹۲۱	۰/۵۴۴۲۹	۳
۰/۲۹۴۲۹۶	۰/۵۰۶۶۳۲	۰/۲۶۳۱۱۱	۰/۶۳۲۳۹	۰/۴۴۶۹۴۵	۴
۰/۵۲۹۱۳۴	۰/۹۱۹۵۸۴	۰/۳۰۸۲۴۷	۰/۷۱۷۷۱۴	۰/۲۵۰۷۹۴	۵
۰/۳۷۰۴۹۱	۰/۶۸۷۵۵۷	۰/۲۰۷۴۶	۰/۷۹۴۹۶۴	۰/۴۱۵۶۱۸	۶
۰/۲۴۴۲۱۶	۰/۵۴۸۶۵۷	۰/۲۱۸۳۲۱	۰/۵۹۰۱۰۸	۰/۴۵۳۴۵۷	۷
۰/۴۴۱۲۱۵	۰/۸۴۶۲۶۶	۰/۶۱۲۰۰۳	۰/۸۳۰۱۷۷	۰/۷۵۳۸۲۶	۸
۰/۳۹۹۱۱۲	۰/۳۸۹۸۳۲	۰/۱۷۲۵۴۹	۱	۰/۵۸۱۴۱۱	۹
۰/۵۱۲۸۹۶	۰/۳۷۲۸۲۷	۰/۱۶۶۶	۰/۵۹۱۶۳۸	۰/۶۳۵۶۶	۱۰
۰/۳۹۶۷۱۶	۰/۶۳۹۵۳۵	۰/۲۲۳۷۷۱	۰/۷۳۹۰۳۴	۰/۷۷۰۸۳۷	۱۱
۰/۶۶۳۸۲۹	۰/۷۱۲۶۹۱	۰/۲۰۴۴۹۲	۰/۶۸۰۳۸۹	۰/۷۵۴۸۳۳	۱۲
۰/۴۱۳۵۶۹	۰/۸۸۵۶۴۷	۰/۲۱۳۷۹۸	۰/۸۳۴۳۲۸	۰/۷۸۵۷۴۴	۱۳
۰/۴۷۶۰۳	۰/۴۹۰۱۸۹	۰/۳۰۸۲۲۳	۰/۶۵۹۹۸۷	۰/۶۶۳۹۰۸	۱۴
۰/۵۲۲۵۱۸	۰/۶۳۸۳۰۶	۰/۳۵۵۷۴۱	۰/۷۰۲۲۳۸	۰/۲۷۳۱۸۶	۱۵
۰/۵۷۹۲۳۶	۰/۳۶۵۰۷۴	۰/۱۵۳۶۲۱	۰/۵۸۳۵۴۶	۰/۳۶۲۱۷۸	۱۶
۰/۷۰۴۶۸۴	۰/۸۲۹۷۷	۰/۵۴۲۰۵۷	۰/۷۰۳۵۱۶	۰/۳۳۸۶۸۹	۱۷
۱	۰/۷۵۰۰۹۷	۰/۲۰۷۱۵۱	۰/۵۴۴۸۶۱	۰/۳۸۴۶۲۱	۱۸
۰/۴۰۹۵۲۱	۰/۵۴۱۸۸۱	۱	۰/۶۷۸۷۶۵	۰/۳۷۹۷۹۹	۱۹
۱	۱	۰/۲۹۴۳۸۸	۰/۶۸۱۱۱۶	۰/۲۵۱۵۵	۲۰

جدول (۳-۴) محاسبه کارایی با استفاده از DEA از سال ۱۳۹۳ تا سال ۱۳۹۷

کارایی حاصل از DEA					
سال ۱۳۹۷	سال ۱۳۹۶	سال ۱۳۹۵	سال ۱۳۹۴	سال ۱۳۹۳	۲۰ شرکت اول
۰/۴۶۶۳۱۲	۰/۶۰۳۵۰۱	۰/۷۰۲۲۴۶	۰/۷۰۸۸۷۵	۰/۳۵۶۶۴۲	۱
۰/۵۳۱۹۶	۰/۷۷۰۸۳۷	۰/۷۱۰۱۴	۱	۰/۵۶۴۶۷۴	۲
۱	۰/۸۶۲۱۱۴	۰/۴۰۷۲۹۹	۰/۷۰۲۷۵	۰/۳۷۳۱۹۳	۳
۰/۵۰۷۲۸۸	۰/۲۵۹۸	۰/۳۷۰۳۴	۰/۶۳۰۲۲۳	۰/۳۴۰۰۵۳	۴
۰/۴۴۵۱۶۳	۰/۶۸۲۴۶۶	۰/۵۸۱۰۱	۰/۵۲۷۵۱۴	۰/۲۴۸۰۰۹	۵
۰/۵۳۳۷۴۱	۰/۱۹۱۲۳۴	۰/۵۲۰۱۲۲	۰/۷۵۴۶۱۳	۰/۳۸۸۱۳۶	۶
۰/۵۰۸۷۲۸	۰/۲۶۲۹۸۶	۰/۴۰۶۵۴۷	۰/۶۲۱۳۷۵	۰/۴۷۹۵۶۶	۷
۰/۶۳۷۰۶۷	۰/۷۸۵۲۲۲	۰/۶۶۰۲۴۱	۱	۱	۸
۰/۶۷۱۵۱۲	۰/۴۷۱۹۹	۰/۳۷۱۸۴۵	۰/۹۰۲۹۱۹	۰/۵۵۹۰۷۳	۹
۰/۴۳۶۳۴۹	۰/۳۴۴۹۱۹	۰/۲۹۴۴۴	۰/۹۱۹۹۱۸	۰/۳۸۴۳۹۷	۱۰
۰/۴۸۱۰۲۴	۰/۳۹۳۲۴۸	۰/۵۵۴۲۴	۰/۶۸۷۸۶۹	۰/۳۱۹۸۸۳	۱۱
۰/۴۱۴۷۳۹	۰/۶۱۳۹۰۶	۰/۶۲۵۵۶۸	۰/۶۲۶۶۵۵	۰/۳۶۳۸۱۴	۱۲
۰/۶۰۳۰۵۷	۰/۳۰۹۷۵	۰/۴۰۲۶۶	۰/۵۰۸۲۳۱	۰/۴۰۰۱۴۱	۱۳
۰/۵۰۴۴۳۶	۰/۳۷۷۴۷۳	۰/۵۱۳۴۵۷	۰/۶۰۱۲۶۳	۰/۳۶۷۱۲	۱۴
۰/۵۶۹۳	۰/۳۱۱۸۱۳	۰/۴۲۹۰۳۲	۰/۶۳۶۰۱۷	۰/۳۰۲۱۹۷	۱۵
۰/۳۱۹۶۶۷	۰/۴۶۱۲۲۲	۰/۳۸۱۷۱۸	۰/۴۸۸۹۸۶	۰/۱۸۱۰۹۴	۱۶
۰/۸۳۱۴۳	۰/۳۳۸۰۹۲	۰/۳۸۸۷۸۸	۰/۸۸۸۴۳۹	۰/۳۹۹۱۰۷	۱۷
۰/۳۶۹۴۰۳	۰/۴۵۱۰۹۴	۰/۴۰۰۱۸۲	۰/۴۵۱۴۱۹	۰/۶۱۹۳۰۹	۱۸
۰/۴۵۷۹۹۲	۰/۲۵۱۵۵	۰/۵۷۸۶۳۹	۰/۵۴۴۶۴	۰/۲۰۴۵۳۸	۱۹
۰/۴۵۵۶۵۴	۰/۸۱۸۶۲۱	۰/۸۴۵۶۹۸	۰/۶۴۱۱۳۴	۰/۲۷۱۸۱۴	۲۰

به همین صورت داده های ورودی برای سال های ۱۳۹۰ تا ۱۳۹۷ برای تمامی ۲۷۹ شرکت موجود بوده و در محاسبات استفاده شده است. حال با استفاده از داده های جدول (۳-۳) و (۴-۳) به ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از شبکه عصبی می پردازیم.

۳-۶- ارزیابی عملکرد شرکت های حاضر در بورس اوراق بهادار با استفاده از شبکه عصبی

به دلیل مشکلات و ناتوانی در پیش بینی کارایی در مدل DEA در این مطالعه، ما تصمیم گرفتیم از شبکه های عصبی و توانایی آنها در پیش بینی و تقریب روابط و توابع غیرخطی استفاده و به تجزیه و تحلیل کارایی پردازیم. ابتدا، از طبقه بندی مدل های شبکه های عصبی مدل هایی با الگوریتم آموزش با ناظر انتخاب شد، به طوری که کارایی مدل DEA به عنوان آموزش به شبکه های عصبی داده شد. پس از تکرارهای متوالی با خطای قابل قبول، شبکه الگوی عملکرد واحدها را می آموزد و یک نگاشت غیرخطی بین ورودی ها و خروجی ها ایجاد می کند. خروجی شبکه، عددی است که شبکه عصبی با توجه به منطقی که در طول آموزش به دست آورده است، به عنوان کارایی ارائه می-دهد. در بخش شبکه های عصبی مدل های مختلف شبکه های عصبی برای ارزیابی انتخاب شدند، ارزیابی کارایی ۲۷۹ شرکت بورس اوراق بهادار با استفاده از مدل های ترکیبی به کمک نرم افزار متلب محاسبه شد.

۳-۶-۱- انتخاب مناسب ترین مدل ترکیبی تحلیل پوششی داده ها و شبکه های عصبی به منظور پیش بینی و ارزیابی کارایی

با کمک گرفتن از مبانی نظری موضوع و مرور مطالعات قبلی، معیارهای مقایسه مدل های ترکیبی، معیارهایی مانند وضوح مدل، خطای مدل و قدرت پیش بینی مشخص و تعیین شد. با توجه به این که نتایج ارزیابی کارایی با استفاده از DEA قدرت پیش بینی برای آینده را ندارد، لذا از شبکه عصبی برای پیش بینی کارایی استفاده شد. برای مبحث پیش بینی از شبکه های عصبی بازگشتی با پیش-

بینی سری های زمانی استفاده شده است که دو نوع آن که عملکرد بهتری دارد انتخاب شده اند. میزان خطای مدل توسط نرم افزار متلب در هر مدل با استفاده از تابع خطای جذر میانگین مربعات (MSE) محاسبه شده است که در حقیقت تفاوت میان مقدار پیش بینی شده توسط مدل با مقدار واقعی آموزش داده شده به شبکه های عصبی مصنوعی است.

۳-۶-۱-۱- پیش بینی کارایی توسط شبکه های عصبی بازگشتی به نام مدل های خودبرگشتی غیرخطی با ورودی های برونزاد

مدل های خودبرگشتی غیرخطی موسوم به شبکه های عصبی بازگشتی با ورودی های برونزاد (NARX) حساسیت کمتری به وابستگی های دراز مدت دارند و می توان میرا شدن گرادیان خطا را در آنها به تاخیر انداخت. در این تحقیق، از شبکه NARX برای پیش بینی سری های زمانی با وابستگی های طولانی مدت استفاده شده است. مقایسه نتایج این شبکه با نتایج شبکه های بازگشتی ساده، مانند المن، توانایی یادگیری NARX و فراگیرتر شدنش را تایید می کند.

شبکه عصبی و روابط آن به طور جامع در فصل دوم توضیح داده شده است. در این فصل، نحوه ایجاد یک شبکه عصبی و نحوه عملکرد آن را مورد بحث قرار خواهیم داد.

برای ایجاد یک شبکه عصبی، اولین قدم تهیه جفت های ورودی-خروجی است. ما از خروجی روش DEA، که کارآمد است، برای ایجاد شبکه عصبی استفاده می کنیم تا بتوانیم مدل خوبی از پیش بینی را بدست آوریم. در واقع استفاده از شبکه عصبی با توجه به سرعت ارائه راه حل ها در صورت آموزش دقیق می تواند بسیار موثر باشد.

ورودی و خروجی های ما کارایی می باشد که به شبکه داده می شود. ما در اینجا داده های ۱۰ ساله از ۲۷۹ شرکت بورسی از سال ۱۳۸۸ تا ۱۳۹۷ را داریم که کارایی برای هر ۱۰ سال و تمام ۲۷۹ شرکت به وسیله DEA محاسبه شد و با انتخاب داده ها ۹ سال اول به عنوان ورودی و سال آخر به عنوان خروجی و با اختصاص این زوج ها به داده های آموزش، اعتبار و آزمایش به ایجاد شبکه و آموزش آن می پردازیم. ایجاد شبکه یعنی اینکه از چه نوع شبکه ای استفاده شود، که ما از شبکه عصبی NARX استفاده می کنیم و همچنین تعیین داده های مورد نیاز این شبکه مانند ورودی ها، خروجی ها و تعداد لایه ها و غیره که باید مشخص شود. برای آموزش شبکه هم از توابع آموزشی که در فصل دوم و

شکل (۲-۱۸) نشان داده شده است استفاده می کنیم.

فرق مهم در شبکه های عصبی NARX با سایر شبکه های عصبی در ورودی هاست. در این نوع از شبکه های عصبی هم ورودی ها تاخیری و هم خروجی ها تاخیری است.

داده های ورودی و خروجی در شبکه عصبی NARX باید مرتب شوند. داده های ورودی به این صورت است که کارایی سال ها ۱۳۸۸ تا ۱۳۹۶ را به گونه ای مرتب می کنیم که شبکه برای یک شرکت بتواند داده های این ۹ سال را کنار یکدیگر قرار دهد و این روند برای تمامی ۲۷۹ شرکت تکرار می شود. داده های خروجی هم که مربوط به سال ۱۳۹۷ می باشد به گونه ای طبق برنامه نویسی در نرم افزار متلب مرتب می شوند که شبکه عصبی داده مربوط به همان شرکت را شناسایی کند.

نهایتا بعد از اینکه شکل شبکه انتخاب گشت، روند تربیت آغاز شده و زوج های ورودی- خروجی انتخاب می شوند. در این صورت روند تا رسیدن به هدف نهایی تکرار می شود.

پیش بینی کارایی شرکت های پذیرفته شده در بورس هدف نهایی در این مطالعه، برای سال ۱۳۹۸ با کمترین میزان خطا است.

شبکه عصبی دارای روشی تکراری است به طوری که تا زمانی که آموزش به محدوده خاصی نرسد این مراحل به پایان نرسیده است و آن تحقق یکی از شرایط خاتمه شبکه عصبی است که می تواند تعداد تکرار، رسیدن به خطای مورد نظر، تعداد شکست های داده های اعتبار و یا گرادیان نزولی باشد. به طور کلی، با تعیین چنین خطای قابل قبولی، کاربر با شرط نهایی مواجه می شود که به موجب آن آموزش شبکه به دست می آید.

خلاصه ای از موارد فوق در زیر آورده شده است. برای هر جفت ورودی- خروجی، روش آموزش در مراحل زیر خلاصه می شود:

۱- ورودی را داخل شبکه انتشار دهید.

۲- خروجی حاصل از شبکه را با خروجی مطلوب مقایسه کنید.

۳- خطای خروجی دریافتی را برآورد نموده، در صورتی که خطای مزبور از خطای قابل قبول کوچکتر باشد وارد مرحله ۵ شوید.

۴- خطا را برای اصلاح شبکه به کار بگیرید و سپس وارد مرحله ۵ شوید.

۵- پایان آموزش.

۶- حداکثر خطای زوج های ورودی و خروجی را ثبت نمایید.

سرانجام، از این نوع آموزش شبکه، می توان دریافت که چگونه هر جفت ورودی- خروجی با یکدیگر ارتباط برقرار می کند، و در نهایت شبکه حاصله می تواند پاسخی مطمئن برای مشکل مورد تحلیل باشد.

ما از تابع trainlm برای آموزش شبکه استفاده کرده ایم و با تغییر درصد داده های آموزش، اعتبار و آزمایش که به طور تصادفی به هر کدام اختصاص داده شده است، و سپس با تغییر تعداد لایه ها بهترین عملکرد سیستم انتخاب شد. آنچه به طور قاطع می توان نتیجه گرفت این است که هرچه داده های آموزشی بیشتر باشد، دقت مدل ایجاد شده نیز بیشتر است. برای اندازه گیری دقت، از روش میانگین مربعات خطا^۱ استفاده می کنیم که با استفاده از فرمول زیر محاسبه می شود و به طور کلی در شبکه عصبی، هدف به حداقل رساندن خطا است.

$$MSE = \frac{1}{N} \sum_{i=1}^N e_i^2 \quad (۱-۳)$$

$$e = y - \hat{y}$$

N تعداد کل داده ها.

y مقدار اولیه.


$\hat{y}$ مقدار ایجاد شده از طریق شبکه عصبی.

بنابراین، پس از آموزش و بدست آوردن خروجی از طریق شبکه عصبی میزان خطا را اندازه گیری می کنیم. ما همچنین میزان خطا و پراکندگی را جداگانه برای داده ها آموزش، اعتبار سنجی و آزمایش ترسیم می کنیم و درباره عملکرد شبکه عصبی بحث می کنیم. ما شبکه های عصبی زیادی را برای این کار آموزش داده ایم و شبکه های عصبی که بهترین عملکرد را داشته اند در این فصل ارائه شده است.

^۱ Mean Square Error


پیش بینی کارایی با یک شبکه دو لایه و اختصاص هفتاد درصد داده ها به آموزش

در اینجا ما ۷۰٪ از داده ها را به آموزش اختصاص دادیم و ۳۰٪ دیگر را به طور یکسان به اعتبارسنجی و آزمایش داده ها اختصاص دادیم، با استفاده از یک شبکه دو لایه با ۱۰ نورون لایه پنهان، که این تعداد را از طریق آموزش های مکرر و رسیدن به نتیجه مطلوب که همان میزان خطای 10^{-4} که مورد نظر می باشد، کارایی را بدست آورده ایم. توجه شود که تعداد نورون های لایه آخر همیشه برابر با تعداد خروجی مسئله می باشد. تابع تحریک برای لایه اول tansig و برای لایه دوم تابع تحریک خطی است. که نتایج زیر برای شبکه بدست آمد که در شکل های (۱-۳) و (۲-۳) قابل مشاهده است.




شکل (۱-۳) شبکه عصبی دو لایه با اختصاص ۷۰ درصد داده ها به آموزش

هر عاملی که در بخش پیش رفتن^۱ شکل (۱-۳) کامل شود عامل توقف برنامه می باشد. بنابراین همان طور که در شکل (۱-۳) مشخص شده عامل توقف شبکه، تعداد تکرارها است و نمودار عملکرد شبکه هم در شکل (۲-۳) نشان داده شده است که میزان خطا را کاهش می دهد.




شکل (۲-۳) عملکرد شبکه عصبی دو لایه با اختصاص ۷۰ درصد داده ها به آموزش


همان گونه که در تصویر (۲-۳) دیده می شود عملکرد شبکه تا 10^{-2} برای داده های آموزش که مهمترین داده برای ما می باشد، کاهش یافته که این یعنی شبکه به میزان خوبی توانسته مدلی برای پیش بینی را ارائه کند. نمودارهای مربوط به داده های آموزش، اعتبار و آزمایش نیز به صورت شکل-های (۳-۳)، (۴-۳)، (۵-۳) و (۶-۳) می باشد که در هر کدام میزان خطا و پراکندگی داده ها مشخص شده اند که در صفحات بعد قابل مشاهده هستند.




شکل (۳-۳) نمودار رگرسیون و خطای مربوط به تمام داده ها



شکل (۴-۳) نمودارهای رگرسیون و خطای مربوط به داده های آموزش



شکل (۵-۳) نمودارهای رگرسیون و خطای مربوط به داده های اعتبار



شکل (۶-۳) نمودارهای رگرسیون و خطای مربوط به داده های آزمایش

همانطور که از شکل های فوق مشهود است، داده های انتخاب شده برای آموزش، اعتبار و آزمایش از پراکندگی خوبی برخوردار هستند و خطا نیز به میزان قابل توجه ای کاهش یافته است. بنابراین با توجه به نمودارهای رسم شده شبکه موفق به آموزش شده و مدلی بدست آمده که توانایی پیش بینی کارایی شرکت های بورسی را دارد که برای ۲۰ شرکت اول بورسی در جدول (۳-۵) آورده شده است.

جدول (۳-۵) محاسبه کارایی با استفاده از شبکه عصبی NARE

کارایی حاصل از DEA				کارایی حاصل از NARX
۲۰ شرکت اول	سال ۱۳۹۵	سال ۱۳۹۶	سال ۱۳۹۷	سال ۱۳۹۸
۱	۰/۷۰۲۲۴۶	۰/۶۰۳۵۰۱	۰/۴۶۶۳۱۲	۰/۴۴۱۴
۲	۰/۷۱۰۱۴	۰/۷۷۰۸۳۷	۰/۵۳۱۹۶	۰/۶۰۸۱
۳	۰/۴۰۷۲۹۹	۰/۸۶۲۱۱۴	۱	۰/۶۴۷۸
۴	۰/۳۷۰۳۴	۰/۲۵۹۸	۰/۵۰۷۲۸۸	۰/۴۸۴۲
۵	۰/۵۸۱۰۱	۰/۶۸۲۴۶۶	۰/۴۴۵۱۶۳	۰/۵۳۸۱
۶	۰/۵۲۰۱۲۲	۰/۱۹۱۲۳۴	۰/۵۳۳۷۴۱	۰/۵۱۶۵
۷	۰/۴۰۶۵۴۷	۰/۲۶۲۹۸۶	۰/۵۰۸۷۲۸	۰/۴۸۹۶
۸	۰/۶۶۰۲۴۱	۰/۷۸۵۲۲۲	۰/۶۳۷۰۶۷	۰/۵۸۵۲
۹	۰/۳۷۱۸۴۵	۰/۴۷۱۹۹	۰/۶۷۱۵۱۲	۰/۷۱۷۸
۱۰	۰/۲۹۴۴۴	۰/۳۴۴۹۱۹	۰/۴۳۶۳۴۹	۰/۵۴۳۹
۱۱	۰/۵۵۴۲۴	۰/۳۹۳۲۴۸	۰/۴۸۱۰۲۴	۰/۴۸۷۴
۱۲	۰/۶۲۵۵۶۸	۰/۶۱۳۹۰۶	۰/۴۱۴۷۳۹	۰/۶۰۰۵
۱۳	۰/۴۰۲۶۶	۰/۳۰۹۷۵	۰/۶۰۳۰۵۷	۰/۶۳۳۲
۱۴	۰/۵۱۳۴۵۷	۰/۳۷۷۴۷۳	۰/۵۰۴۴۳۶	۰/۵۰۹۸
۱۵	۰/۴۲۹۰۳۲	۰/۳۱۱۸۱۳	۰/۵۶۹۳	۰/۴۸۷۵
۱۶	۰/۳۸۱۷۱۸	۰/۴۶۱۲۲۲	۰/۳۱۹۶۶۷	۰/۵۱۴۶
۱۷	۰/۳۸۸۷۸۸	۰/۳۳۸۰۹۲	۰/۸۳۱۴۳	۰/۵۶۱۷
۱۸	۰/۴۰۰۱۸۲	۰/۴۵۱۰۹۴	۰/۳۶۹۴۰۳	۰/۷۹۰۴
۱۹	۰/۵۷۸۶۳۹	۰/۲۵۱۵۵	۰/۴۵۷۹۹۲	۰/۵۱۵۱
۲۰	۰/۸۴۵۶۹۸	۰/۸۱۸۶۲۱	۰/۴۵۵۶۵۴	۰/۶۰۳۳

اگر نیاز این بود که نتیجه بهتری بگیریم و خطا بیشتر کاهش یابد یا باید تعداد داده های آموزش را بیشتر کنیم، یا اینکه تعداد لایه ها را کم و زیاد کنیم، و یا تعداد نورون های لایه ها را تغییر دهیم. نکته مهم این است شبکه بالاخره به نتیجه مطلوب می رسد اما نکته مهم تر زمان رسیدن به جواب است که در این حالت زمان کمتری صرف شده است.

با توجه به نتایج مشاهده شده در جدول (۳-۵) قدرت پیش بینی کارایی شبکه عصبی NARX که حاصل تعداد زیادی آموزش دیدن شبکه بود در حد انتظار نبود و در ادامه به ارزیابی کارایی شرکت-های بورسی با استفاده از مدل های تطبیق پذیر شبکه عصبی، سیستم استنتاج عصبی-فازی سازگار که مرکب از الگوریتم های فازی می باشد می پردازیم.

۳-۶-۱-۲- پیش بینی کارایی توسط شبکه های عصبی - فازی یا سیستم استنتاج عصبی - فازی سازگار

شرح کامل شبکه های عصبی - فازی در فصل دوم ارائه شده است. در اینجا ما مدل سازی با سیستم استنتاج عصبی - فازی را ارائه می دهیم. پیش بینی با استفاده از مدل شبکه عصبی - فازی در سه مرحله انجام شد. ۱- طراحی ۲- تهیه داده ها و ۳- پیاده سازی مدل. در طراحی مدل شبکه عصبی - فازی، از یک شبکه تغذیه چند لایه با الگوریتم یادگیری ترکیبی پس از انتشار و حداقل مربعات و سیستم استنتاج فازی سوگنو استفاده شده است. تعداد دو لایه پنهان و تابع ورودی مدل سیگموئید و تابع خروجی خطی است. از تابع میانگین متحرک برای غیرفازی کردن استفاده می شود. در مرحله آماده سازی داده ها، ابتدا داده ها، پردازش اولیه می شوند.

همچنین برای اجرای الگو و وارد کردن داده ها، داده ها باید نرمال و سپس مورد استفاده قرار گیرند. در مرحله پیاده سازی مدل، با تغییر مداوم تعداد لایه ها و تعداد نورون های لایه های پنهان، شبکه عصبی مناسب پیاده سازی می شود و همچنین با تغییر توابع مختلف عضویت و تعداد آنها، سیستم فازی مناسب پیاده سازی می شود.

ساختار شبکه طراحی شده به صورت زیر می باشد:

تعداد نورون ها^۱: ۳۱۲

^۱ Number of nodes

تعداد پارمترهای خطی^۱: ۱۵۰

تعداد پارمترهای غیرخطی^۲: ۲۷۰


تعداد کل پارمترها^۳: ۴۲۰

تعداد زوج های آموزشی^۴: ۲۳۷

تعداد زوج های چک^۵: ۰

قوانین فاز^۶: ۱۵

همچنین برای اینکه عملکرد بهتری داشته باشیم سائز گام ها را افزایش یا کاهش می دهیم، این کار از افتادن در مینم های محلی جلوگیری و سرعت همگرایی را افزایش یابد. ساختار طراحی شده برای پیش بینی کارایی شرکت های بورسی به وسیله سیستم استنتاج عصبی-فازی سازگار در شکل (۷-۳) نشان داده شده است.



شکل (۷-۳) ساختار شبکه عصبی سیستم استنتاج عصبی-فازی سازگار

۱ Number of linear parameters

۲ Number of nonlinear parameters


۳ Total number of parameters

۴ Number of training data pairs


۵ Number of checking data pairs

۶ Number of fuzzy rules


نمودار مربوط به رگرسیون در شکل (۳-۸) و نمودارهای مربوط به خطا برای کل داده ها در شکل (۳-۹)، نمودار خطا برای داده های آموزش در شکل (۳-۱۰) و نمودار خطا برای داده های آزمایش در شکل (۳-۱۱) که خروجی سیستم استنتاج عصبی- فازی سازگار می باشد، نشان داده شده است.




شکل (۳-۸) نمودار رگرسیون تمام داده ها



شکل (۹-۳) نمودار خطای مربوط به تمام داده ها



شکل (۱۰-۳) نمودار خطای مربوط به داده های آموزش



شکل (۱۱-۳) نمودار خطای مربوط به داده های آزمایش

همان طور که در شکل (۱۰-۳) نشان داده شده عملکرد شبکه تا 10^{-4} برای داده ها کاهش یافته که این یعنی شبکه به میزان خوبی توانسته مدلی برای پیش بینی را ارائه کند.

داده های انتخاب شده برای آموزش و آزمایش از پراکندگی خوبی برخوردار هستند و خطا نیز به میزان قابل توجه ای کاهش یافته است. بنابراین با توجه به داده های و نمودارهای خروجی، شبکه با موفقیت آموزش دیده و مدلی بدست آمده که قابلیت پیش بینی کارایی شرکت های پذیرفته شده در بورس را دارد. که برای ۲۰ شرکت اول بورسی در جدول (۶-۳) آورده شده است. ستون مربوط به سال ۱۳۹۸ پیش بینی کارایی توسط شبکه عصبی سیستم استنتاج عصبی- فازی سازگار می باشد. همچنین پیش بینی کارایی توسط شبکه عصبی NARX در جدول (۶-۳) نشان داده شده است که در نهایت به مقایسه این دو شبکه عصبی پرداخته و نتایج آن را در جدول (۷-۳) آورده ایم.

جدول (۶-۳) محاسبه کارایی با استفاده از شبکه عصبی سیستم استنتاج عصبی - فازی سازگار

کارایی حاصل از شبکه عصبی Anfis	کارایی حاصل از شبکه عصبی NARX	کارایی حاصل از DEA			
سال ۱۳۹۸	سال ۱۳۹۸	سال ۱۳۹۷	سال ۱۳۹۶	سال ۱۳۹۵	۲۰ شرکت اول
۰/۴۶۶۱۵۱	۰/۴۴۱۴	۰/۴۶۶۳۱۲	۰/۶۰۳۵۰۱	۰/۷۰۲۲۴۶	۱
۰/۵۳۱۹۹۸	۰/۶۰۸۱	۰/۵۳۱۹۶	۰/۷۷۰۸۳۷	۰/۷۱۰۱۴	۲
۰/۹۹۹۹۰۹	۰/۶۴۷۸	۱	۰/۸۶۲۱۱۴	۰/۴۰۷۲۹۹	۳
۰/۵۰۷۶۲۹	۰/۴۸۴۲	۰/۵۰۷۲۸۸	۰/۲۵۹۸	۰/۳۷۰۳۴	۴
۰/۴۴۵۱۵۹	۰/۵۳۸۱	۰/۴۴۵۱۶۳	۰/۶۸۲۴۶۶	۰/۵۸۱۰۱	۵
۰/۵۳۳۹۳۵	۰/۵۱۶۵	۰/۵۳۳۷۴۱	۰/۱۹۱۲۳۴	۰/۵۲۰۱۲۲	۶
۰/۵۰۸۳۶۷	۰/۴۸۹۶	۰/۵۰۸۷۲۸	۰/۲۶۲۹۸۶	۰/۴۰۶۵۴۷	۷
۰/۶۳۷۰۹۹	۰/۵۸۵۲	۰/۶۳۷۰۶۷	۰/۷۸۵۲۲۲	۰/۶۶۰۲۴۱	۸
۰/۶۷۱۵۱۳	۰/۷۱۷۸	۰/۶۷۱۵۱۲	۰/۴۷۱۹۹	۰/۳۷۱۸۴۵	۹
۰/۴۳۶۳۴۰	۰/۵۴۳۹	۰/۴۳۶۳۴۹	۰/۳۴۴۹۱۹	۰/۲۹۴۴۴	۱۰
۰/۴۸۱۳۱۳	۰/۴۸۷۴	۰/۴۸۱۰۲۴	۰/۳۹۳۲۴۸	۰/۵۵۴۲۴	۱۱
۰/۲۴۶۶۷۲	۰/۶۰۰۵	۰/۴۱۴۷۳۹	۰/۶۱۳۹۰۶	۰/۶۲۵۵۶۸	۱۲
۰/۶۰۳۱۰۷	۰/۶۳۳۲	۰/۶۰۳۰۵۷	۰/۳۰۹۷۵	۰/۴۰۲۶۶	۱۳
۰/۵۰۴۹۹۱	۰/۵۰۹۸	۰/۵۰۴۴۳۶	۰/۳۷۷۴۷۳	۰/۵۱۳۴۵۷	۱۴
۰/۵۶۹۴۳۳	۰/۴۸۷۵	۰/۵۶۹۳	۰/۳۱۱۸۱۳	۰/۴۲۹۰۳۲	۱۵
۰/۳۱۹۶۴۵	۰/۵۱۴۶	۰/۳۱۹۶۶۷	۰/۴۶۱۲۲۲	۰/۳۸۱۷۱۸	۱۶
۰/۸۳۱۵۱۷	۰/۵۶۱۷	۰/۸۳۱۴۳	۰/۳۳۸۰۹۲	۰/۳۸۸۷۸۸	۱۷
۰/۳۶۹۴۸۶	۰/۷۹۰۴	۰/۳۶۹۴۰۳	۰/۴۵۱۰۹۴	۰/۴۰۰۱۸۲	۱۸
۰/۴۵۸۰۶۹	۰/۵۱۵۱	۰/۴۵۷۹۹۲	۰/۲۵۱۵۵	۰/۵۷۸۶۳۹	۱۹
۰/۴۵۵۷۹۲	۰/۶۰۳۳	۰/۴۵۵۶۵۴	۰/۸۱۸۶۲۱	۰/۸۴۵۶۹۸	۲۰

جدول (۷-۳) مقایسه عملکرد انواع شبکه های عصبی

خطای داده های آموزش	خطای داده های آزمایش	خطای کل شبکه	نوع شبکه عصبی
۰/۰۱	۰/۰۳۴	۰/۰۱۵	شبکه عصبی NARX
۳/۴۰۷e-۰۶	۰/۰۸۹	۰/۰۱۳	شبکه عصبی Anfis

همان طور که در جدول (۷-۳) مشخص است، مدل استنتاج عصبی- فازی برای تمامی گام ها پیش-بینی مناسب تری را ارائه می کند. شبکه عصبی- فازی نتایج بهتر و قدرت پیش بینی بیشتری نسبت به سایر مدل ها از خود نشان می دهد.

در نهایت با توجه به مطالب ارائه شده در این فصل می توان نتیجه گرفت:

- شبکه عصبی چیزی نیست جز عملکردی که با اجزای ساده اجرا می شود و چون این اجزای ساده به تعداد زیاد در یک مکان استفاده می شوند، به یک سیستم کارآمد تبدیل می شوند.
- شبکه عصبی با تغییر داده های آموزش و تعداد لایه ها سرانجام با آموزش های مکرر به نتیجه می رسد فقط نکته مهم صرف زمان است که با اختصاص داده های بیشتر، به داده های آموزش، زمان کمتر و دقت مسئله بیشتر خواهد شد.

فصل ۴:

نتایج و پیشنهادات

۴-۱- بحث و نتیجه گیری

۴-۱-۱- نتایج حاصل از شبکه های عصبی خودبرگشتی غیرخطی با ورودی های برونزاد (NARX)

- تأثیر تعداد نقاط تمرینی آموزشی برای شبکه عصبی تنها در زمان سپری شده است، زیرا در نهایت شبکه عصبی با تغییرات زیاد در تعداد نورون ها، عملکردهای تحریکی، عملکردهای آموزشی و تمرینات مکرر با توجه به عملکرد مورد نظر ما پاسخ داده می شود و یک مدل ارائه می کند، اما زمان بسیار مهم است، بنابراین توصیه می شود شبکه را با داده های بیشتر آموزش دهید تا زمان کمتری صرف کرده و دقت شبکه را افزایش دهید.
- می توان شبکه عصبی را با توجه به مقایسه ها، جداول و نمودارهای ترسیم شده در فصل قبل، به عنوان یک تابع در نظر گرفت و با تقریب خوب، مدل سازی و خطای کمی را بدست آورد. همچنین مشاهده شد که با آموزش شبکه با جمعیت کمتر و سپس دادن جمعیت مطلوب جدید به شبکه و جمع آوری تمام داده ها با هم، شبکه توانست نقاط بهتری را پیشنهاد دهد.
- با توجه به اهمیت زمان برای حل مشکلات و همچنین محاسبه مقادیر برخی از نقاطی که ما در نظر می گیریم، شبکه توانست نقاط خوبی را بدست آورد، اما آموزش شبکه برای دستیابی به عملکرد مطلوب زمان زیادی می برد.
- شبکه های عصبی می توانند ابزاری مطمئن برای پیش بینی سری های زمانی باشند.
- اعتبار شبکه عصبی با آزمایش شبکه با داده های مورد استفاده در آماده سازی بدست آمد. تصاویر مربوط به تهیه و آزمایش این شبکه کارآیی آن را اثبات کرد.
- ضریب همبستگی بین مجموعه آموزش و مجموعه آزمون شبکه نشان دهنده قدرت شبکه- های عصبی در پیش بینی است. این مدل قدرت بالایی برای شبیه سازی نداشت.

در پیش بینی سری های زمانی بر اساس نتایج تحقیق و ارزیابی مدل، نشان می دهد که، می توان با توجه به تعیین خطای آموزشی، استفاده از روش تأخیری شبکه عصبی را مد نظر قرار داد و از آن استفاده کرد. در نهایت، شبکه های عصبی با توانایی قابل توجه خود در استنباط نتایج از داده های پیچیده می توانند برای استخراج الگوها و شناسایی گرایش های مختلف که تشخیص آنها برای انسان و رایانه بسیار دشوار است، مورد استفاده قرار گیرند.

۴-۱-۲- نتایج شبکه های عصبی سیستم استنتاج عصبی - فازی سازگار (ANFIS)

- این سبک علاوه بر استنتاج فازی، سادگی و تفسیرپذیری را به خواص شبکه های عصبی می-افزاید. سیستم عصبی- فازی به دلیل انعطاف پذیری پارامترهای سیستم فازی سریعتر از شبکه عصبی تمرین می کند و همچنین دقیق تر است، اما نسبت به شبکه عصبی تأخیری به زمان پردازش بیشتری نیاز دارد.
- سایر مزایای اساسی سیستم استنتاج عصبی- فازی نسبت به سایر سیستم ها را می توان به شرح زیر خلاصه کرد:
- این سیستم دارای یک سیستم استنباط فازی شفاف است که اشکالات کمی دارد و خطاهای کمتری در محاسبات نسبت به شبکه های عصبی نشان می دهد. این سیستم مزایای یک سیستم تخصصی فازی را حفظ می کند، در حالی که نیاز به یک متخصص را نیز کاهش می-دهد. با استفاده از منطق فازی، مشکلات مدل سازی و تجزیه و تحلیل داده های پیچیده در این روش کاهش می یابد. امکان افزودن ابعاد کیفی تجربه انسانی به این سیستم وجود دارد و در نهایت، سیستم عصبی- فازی با حفظ مزایای سیستم استنتاج فازی، قابلیت یادگیری را دارد.
- شبکه های عصبی تاخیر زمانی و عصبی- فازی می توانند به عنوان ابزارهای مدل سازی قابل اعتماد برای پیش بینی عملکرد مورد استفاده قرار گیرند.

۴-۲- جمع بندی و پیشنهادات

بهترین مدل ها از نظر دقت در پیش بینی در این مطالعه، با مدل سازی شبکه های عصبی با تاخیر زمانی و شبکه های عصبی- فازی و در نظر گرفتن چگونگی تغییر خطاها (در پیش بینی آینده)، معرفی شدند.

در پایان تحقیق، محقق دیدگاه های جدیدی را خواهد شناخت که می تواند راهنمای محققانی باشد که قصد انجام تحقیقات مشابه را دارند. بر این اساس، مطالعه حاضر می تواند مبنایی کاربردی برای سایر تحقیقات در ارزیابی و پیش بینی عملکرد شرکت ها باشد.

اما به دلیل برخی محدودیت، اگرچه هر تحقیقی به طور جامع فرض می شود، از جمله موضوعی و زمانی، نمی تواند به همه جنبه های موضوع پردازد و جنبه های مختلف آن را بررسی کند. این تحقیق از این قاعده مستثنی نیست، بنابراین پیشنهادات زیر برای تحقیقات آینده ارائه خواهد شد.

۱- پیشنهاد می شود روش های دیگری که مقادیر بهینه پارامترهای تاخیر زمانی را استخراج می کنند، آزمایش و مدل سازی و با استفاده از آنها پیش بینی شده و با مدل سازی سایر روش های کلاسیک مقایسه شود.

۲- پیشنهاد می شود مدل نظری تحقیق حاضر با در نظر گرفتن متغیرهای بیشتری مانند:

۱- قیمت پایانی روزانه هر سهم ۲- نسبت قیمت به درآمد هر سهم (p/e) ۳- ارزش معاملات

۴- تعداد دفعات معامله ۵- حجم معاملات بررسی گردد و رابطه هر یک از آنها با کارایی

مشخص گردد.

۳- در نظر گرفتن شاخص های کیفی و سایر شاخص های کمی شرکت های داخلی و خارجی

برای سنجش کارایی، مورد ارزیابی قرار گیرد که می تواند نتایج پژوهش را قابل اطمینان تر نماید.

۴- پیشنهاد می شود نقش هر یک از المان های ورودی و خروجی در این تحقیق در رابطه با

کارایی شرکت ها مورد ارزیابی قرار گیرد.

۵- موانع و چالش های پیش روی شرکت های بورس اوراق بهادار جهت بهره وری، بازده سهام و

کارایی آنها بررسی، شناسایی و اولویت بندی شوند.

۶- شناسایی و اولویت بندی عوامل موثر بر کارایی شرکت های بورس اوراق بهادار به عنوان یک

نهاد اقتصادی مهم صورت گیرد.

- ۷- بررسی ارزیابی کارایی یا مدل های فرا ابتکاری دیگر همچون الگوریتم ژنتیک و الگوریتم ژنتیک چند هدفه و.... و مقایسه ی نتایج با مدل شبکه های عصبی
- ۸- انجام این تحقیق در نهادهای سازمان ها و ارگان های دیگر جهت ارزیابی و پیش بینی کارایی آنها.

۳-۴- محدودیت های پژوهش

اساس هر تحقیق، اطلاعات مورد استفاده در تحقیق است. بدیهی است که هرچه اطلاعات دقیق تر و کامل تری در اختیار محقق قرار گیرد، نتایج تحقیق کامل تر و معتبرتر خواهد بود. برخی از محدودیت های تحقیق به شرح زیر است:

- ۱- یکی از محدودیت های تحقیق عدم امکان داشتن همه اطلاعات در مورد شرکت ها به دلایل مختلف از جمله محرمانه بودن مسائل مالی آنها است.
- ۲- محقق زمان محدودی در ارائه و بازخورد نتایج تحقیق دارد که امکان بررسی جامع تری از مدل تحقیق را فراهم نکرده است.
- ۳- نکته مهم دیگر برای آموزش شبکه عصبی تهیه داده های ورودی و خروجی می باشد. بنابراین برای تهیه زوج های آموزش (ورودی و خروجی) باید از یکی از روش های بهینه سازی استفاده شود، که این مسئله باعث اتلاف وقت زیادی می شود، ولی با استفاده از روش های بهینه سازی تکاملی هم صرفه جویی در زمان داریم و هم اینکه در ایجاد زوج های آموزش هیچ محدودیتی نداریم.

منابع

منابع

منابع فارسی

- [۱] آرمسترانگ م، (۱۳۸۵) "مدیریت عملکرد (راهبردهای کلیدی و راهنمای عمل)" (ترجمه س. صفری)، تهران: انتشارات دانشگاه تهران.
- [۲] آریا نژاد م. حسین زاده لطفی ف. و حمزه پ، (۱۳۸۹) "به کارگیری الگوریتم تدوین شده با استفاده از DEA برای رتبه بندی امور پژوهشی دانشگاه های آزاد اسلامی" پژوهش های مدیریت، ۸۵، ۶۵-۸۸.
- [۳] اجلی قشلاجوقی م. و صفری ح، (۱۳۹۰) "ارزیابی عملکرد واحدهای تصمیم گیری با استفاده از مدل ترکیبی شبکه های عصبی پیش بینی کننده عملکرد و تحلیل پوششی داده ها" نشریه مهندسی صنایع، ۴۵ (۱)، ۱۳-۲۹.
- [۴] امامی میبدی ع. و باقری ص، (۱۳۹۳) "مقایسه توانایی پیش بینی مدل های شبکه عصبی مصنوعی (ANN)، سیستم استنتاج عصبی- فازی انطباقی (ANFIS) و تبدیل موجک-عصبی: قیمت سبد نفت خام اوپک" فصلنامه مطالعات اقتصاد انرژی، ۴۳، ۱۲۹-۱۵۴.
- [۵] بهرامی آ. و همه خانی ص، (۱۳۹۵) "استفاده از شبکه عصبی برای پیش بینی روند قیمت سهام" مطالعات مدیریت و حسابداری، ۲، ۳۰۱-۳۲۲.
- [۶] حاجی کریمی ع. و پرهیزگار م، (۱۳۸۶) "سازوکارهای موثر در طراحی و پیاده سازی نظام های نوین ارزیابی عملکرد سازمانی در بانک های تجاری کشور" پژوهش نامه علوم انسانی و اجتماعی، ۷ (۲۷)، ۱۲-۴۲.
- [۷] خاتمی نژاد ح. قمریان ح. و اقبالی م، (۱۳۹۱) "کاربرد روش تلفیقی تحلیل پوششی داده ها در ارزیابی کارایی نسبی واحدهای تصمیم گیرنده" اولین همایش ملی بررسی راهکارهای ارتقاء مباحث مدیریت، حسابداری و مهندسی صنایع در سازمان ها.
- [۸] خدادادی و. و کارگرپور خ، (۱۳۸۸) "بررسی رابطه بین جریان نقد عملیاتی و نسبت های نقدینگی با بازده سهام در شرکت های پذیرفته شده در بورس اوراق بهادار تهران".
- [۹] سعیدی ع. و اکبری ن، (۱۳۸۹) "رابطه بین ارزش افزوده اقتصادی و ارزش افزوده تعدیل شده بر اساس تورم با بازده و قیمت سهام"
- [۱۰] سلطانی م. ر. صیادی ا. ر. مهرگان م. ر. و عابدی م. ر، (۱۳۹۱) "ارائه رویکرد ترکیبی DEA-AP برای رتبه بندی کارایی معادن سنگ آهن ایران" پژوهش های مدیریت منابع انسانی، ۲ (۳)، ۴۵-۶۵.
- [۱۱] شجاعیان ع. ر، (۱۳۹۳)، پایان نامه ارشد: "محاسبه منحنی پارتو برای بهینه سازی توپولوژی سازه های خرپا با استفاده از شبکه عصبی"، دانشکده مهندسی مکانیک، دانشگاه سمنان.
- [۱۲] صالحی صدقیان ج. امیری م. تقوی فرد م. ت. و رضوی س. ح، (۱۳۸۷) "رتبه بندی واحدهای کار با ترکیب رویکرد تحلیل پوششی داده ها و فرآیند تحلیل سلسله مراتبی در سازمان های بازرگانی استانی" دانش مدیریت، ۲۱ (۸۱)، ۷۵-۹۰.

- [۱۳] صفایی قادی کلایی ع. و زارع شاهی ع، (۱۳۸۸) "تخمین مرز کارایی با استفاده از شبکه های عصبی مصنوعی" اثر ارائه شده در دومین کنفرانس بین المللی تحقیق در عملیات ایران، بابلسر، دانشگاه مازندران.
- [۱۴] گریوانی ح، (۱۳۹۰)، پایان نامه ارشد "بررسی کارایی شعب بانک ملت خراسان شمالی با استفاده از روش تحلیل پوششی داده ها" مدیریت بازرگانی، دانشگاه فردوسی مشهد.
- [۱۵] مرتضی زاده م، (۱۳۹۴)، پایان نامه ارشد: "ارزیابی کارایی با ارائه مدل ترکیبی تحلیل پوششی داده ها و شبکه های عصبی مصنوعی"، دانشکده علوم اداری و اقتصاد، دانشگاه فردوسی مشهد.
- [۱۶] معین الدین م. نایب زاده ش. و منصوری ا، (۱۳۸۹) "مقایسه توان تبیین معیارهای سنتی و نوین در ارزیابی عملکرد" فصلنامه حسابداری مالی، ۲، ۱۴۰-۱۲۱: p. (۶)
- [۱۷] منهج م. ب، (۱۳۸۱) "هوش محاسباتی" جلد اول، مبانی شبکه های عصبی.
- [۱۸] مومنی م، (۱۳۸۵) "مباحث نوین پژوهش در عملیات" چاپ اول، انتشارات دانشکده مدیریت دانشگاه تهران.
- [۱۹] مهرگان م. ر. اجلی قشلاجوقی م. و صفوی میر محله ر، (۱۳۸۸) "تحلیل کارایی فنی شرکت های گاز استانی در کشور با استفاده از مدل ترکیبی شبکه های عصبی پیش بینی کننده عملکرد و تحلیل پوششی داده ها (Neuro-DEA)" اثر ارائه شده در دومین کنفرانس بین المللی تحقیق در عملیات ایران، بابلسر، دانشگاه مازندران، http://www.civilica.com/Paper/ICIORS02/ICIORS02_055.htm
- [۲۰] مهرگان م. ر. فراست ع. و کامیاب مقدس ا، (۱۳۸۵) "تحلیل کارایی فنی پالایشگاه های نفت کشور با استفاده از مدل ترکیبی شبکه های عصبی و تحلیل پوششی داده ها" پژوهشنامه علوم انسانی و اجتماعی، ۶ (۲۳)، ۱۰۵-۱۲۸.
- [۲۱] نصر اصفهانی م. و رضوی س. ع، (۱۳۸۹) "بررسی و مقایسه کارایی و بهره وری شرکت های خودروسازی با استفاده از تحلیل پوششی داده ها" نشریه عمومی پژوهشی مدیریت فردا، ۲۵، ۹۷-۱۰۸.
- [۲۲] هاشمی س. ع. و ساعدی ر، (۱۳۸۸) "بررسی تاثیر ویژگی های خاص شرکت ها بر محتوای اطلاعاتی سود و جریان های نقدی عملیاتی در توضیح بازده سهام"

منابع لاتین

- [۲۳] Athanassopoulos A. D. and Curram S. P. A. (۱۹۹۶) "comparison of data envelopment analysis and artificial neural networks as tool for assessing the efficiency of decision making units" Journal of the Operational Research Society, ۴۷(۸), ۱۰۰۰-۱۰۱۶.
- [۲۴] Beal M. Demuth H. B. and Hagan M. T. (۱۹۹۶) "Neural Network Design" PWS ۱۳.
- [۲۵] Emrouznejad A. and Shale E. (۲۰۰۹) "A combined neural network and DEA for measuring efficiency of large scale datasets" Computers & Industrial Engineering, ۵۶(۱): p. ۲۴۹-۲۵۴

- [٢٦] Khalili-Damghani K. Tavana M. and Haji-Saami E. (٢٠١٥) “A data envelopment analysis model with interval data and undesirable output for combined cycle power plant performance assessment.” *Expert Systems with Applications*, ٤٢(٢): p, ٧٦٠-٧٧٣
- [٢٧] Lampe H.W. and Hilgers D. (٢٠١٥) “Trajectories of efficiency measurement: A bibliometric analysis of DEA and SFA” *European journal of operational research*, ٢٤٠(١): p, ١-٢١.
- [٢٨] Mostafa M. M. (٢٠٠٩) “Modeling the competitive market efficiency of Egyptian companies: A probabilistic neural network analysis” *Expert Systems with Applications*, ٣٦(٥), ٨٨٣٩-٨٨٤٨.
- [٢٩] Wang S. (٢٠٠٣) “Adaptive non-parametric efficiency frontier analysis: A neural-networkbased model” *Computers and Operations Research*, ٣٠, ٢٧٩-٢٩٥
- [٣٠] Wu D. Yang Z. and Liang L. (٢٠٠٦) “Using DEA-neural network approach to evaluate branch efficiency of a large Canadian bank” *Expert Systems with Applications* ٣١, ١٠٨-١١٥

Abstract:

Today, due to high competition in global markets and technological innovation, the issue of measuring the Performance of organizations has become a global issue. One of the most common methods of measuring performance is data envelopment analysis. But it has problems such as sensitivity to the border of performance and lack of predictive power, which one of the ways to solve these problems is to combine it with an artificial neural network.

Border neural networks have more robust and flexible performance than data envelopment analysis and it can also be used to solve larger scale problems

The purpose of this study is to evaluate the performance of companies listed on the stock exchange using a neural network. In this research, for the given time series, after preparing the data, the optimal values of the phase space parameters, including time delay, are obtained.

Then, by creating an input matrix of time series data and a suitable structure for the forecasting network, modeling and forecasting time series should be done. In this regard, two proposed models based on nonlinear methods for predicting time series are presented. The first model of nonlinear autoregressive neural network is compatible with exogenous inputs and the second model of neural networks is adaptive neuro-fuzzy inference system. In order to have a criterion for comparison, we used the mean squared error. Finally, reviewing and evaluating the results shows the appropriate structure of the models used and the use of fuzzy space in increasing the accuracy of modeling and predicting time series is effective and at the same time, the performance of the neural-fuzzy network model is significantly better than the time delay neural model. The results indicate that time latency and neural-fuzzy neural networks can be used as reliable modeling tools to predict performance.

Keywords: Performance, Data envelopment analysis, Artificial neural network, Stock Exchange, Nonlinear autoregressive with exogenous inputs (NARX)



Shahrood University of Technology
Faculty of Industrial Engineering and Management

Evaluate the performance of companies listed on the stock exchange using neural networks

Thesis for a master's degree
Industrial management Production orientation and operations

By:
Ali Reza Shojaeyan

Supervisor:
Dr. Mojtaba Ghiyasi

October ۲۰۲۱

