

## ساختارهای خطی و غیر خطی در پیش بینی بازده سهام

احمد مدرس

استادیار دانشگاه تهران

محمدباقر کهن سال<sup>۱</sup>

کارشناسی ارشد حسابداری، دانشگاه آزاد واحد قزوین

تاریخ دریافت: ۹۲/۱۱/۲۱

تاریخ پذیرش: ۹۲/۱۲/۲۰

### چکیده

پیش بینی بازده سهام به کمک کشف الگوهای رفتاری فرآیند مولد قیمت سهام امکان پذیر است. میزان موفقیت در کشف اینگونه الگوهای رفتاری، میزان کارایی پیش بینی را مشخص می کند. به عبارت دیگر فرآیند مولد قیمت سهام را می توان به عنوان یک الگوی دینامیکی بررسی کرد. این فرآیند ممکن است به صورت مدل های خطی، مدل های غیر خطی و یا مدل های تصادفی به دست آید. این پژوهش ساختارهای خطی پیش بینی کننده را در قالب دو مدل قیمت گذاری دارایی های سرمایه ای و سه عاملی فاما و فرنچ و ساختارهای غیرخطی را به صورت شبکه های عصبی تشریح می نماید.

**واژه های کلیدی:** پیش بینی بازده سهام، مدل قیمت گذاری دارایی های سرمایه ای، مدل سه عاملی فاما و فرنچ، شبکه های عصبی مصنوعی

طبقه بندی موضوعی: G12, G17, C58, C53

### مقدمه

تفکر غالب در نظریه گام تصادفی اینست که امکان پیش بینی قیمت‌های آینده با استفاده از اطلاعات در دسترس عموم وجود ندارد و به عبارتی قیمت‌ها پیش بینی ناپذیر هستند. اگر چه این نظریه در بین بنیادگرایان با اقبال زیادی روبرو بوده است، اما پژوهش‌های بسیاری در تضاد با این نظریه ثابت نموده‌اند که ارزش‌های آینده اوراق بهادار قابل تعیین و بررسی اند (کینگ و همکاران، ۲۰۰۵). مقایسه روندهای مختلف پیش بینی نشان داده‌اند که برای پیش بینی نرخ‌های آتی، تحلیل‌هایی نظیر میانگین متحرک، نسبت به فرآیند گام تصادفی موفق تر عمل می‌کند (گنسای، ۱۹۹۷). عمده‌ی پژوهش‌های اولیه‌ای که در زمینه پیش بینی رفتار سهام صورت گرفته‌اند صرفاً معطوف به بکارگیری مدل‌های خطی بودند (بونیل و همکاران، ۲۰۰۷). تا اینکه هنیک و پترسون<sup>۱</sup> (۱۹۸۵) نشان دادند که نوسانات قیمت تعداد زیادی از سهام‌های مبادله شده در بورس اوراق بهادار نیویورک الگویی غیر خطی دارند. پس از آن شواهد بسیاری بدست آمد که نشان می‌داد بازده سهام متغیری است که می‌تواند با استفاده از یک مدل غیر خطی پیش بینی شود (هودنت و همکاران، ۲۰۱۲). از جمله مدل‌های غیر خطی بکار گرفته شده در این زمینه شبکه‌های عصبی مصنوعی بوده‌اند.

### مروری بر ادبیات نظری پیش بینی بازده سهام

سه مورد از عمده ترین مدل‌های پیش بینی بازده سهام که در این پژوهش در قالب دو ساختار خطی و غیرخطی معرفی می‌شوند به ترتیب مدل‌های قیمت گذاری دارایی‌های سرمایه ای و سه عاملی فاما و فرنچ و مدل شبکه‌های عصبی مصنوعی است.

#### مدل قیمت گذاری دارایی‌های سرمایه ای

هدف اصلی این مدل تعیین بازده اوراق بهادار است که با مشخص نمودن رابطه بین بازده این اوراق با ریسک آن‌ها تحقق می‌پذیرد (اعظم و جاسیر، ۲۰۱۱). مفهوم ریسک در این مدل به صورت حساسیت بازده یک نوع سهام نسبت به تغییر بازده پرتفوی بازار تعریف می‌شود. این نوع ریسک، ریسک سیستماتیک نام دارد. ریسک سیستماتیک خارج از کنترل سرمایه گذار بوده و به عوامل بازار مربوط است (فیشر و رونالد، ۱۹۹۵). ویژگی اساسی ریسک سیستماتیک

این است که چون همه انواع اوراق بهادار را شامل می‌شود، نمی‌توان با متنوع سازی سبد انتخابی سهام آن را کاهش داد (شارپ، ۱۹۶۴). از این روی، به آن، جز پاداش پذیر ریسک اطلاق می‌شود. به این معنی که چون سرمایه گذاران ناگزیر از پذیرش سطح معینی از این ریسک بوده و مدیریتی بر آن ندارند، انتظار دریافت پاداشی برای تحمل آن را دارند. این پاداش در قالب تفاوت مثبت بازده مورد انتظار از بازدهی بدون ریسک بیان می‌شود. چنین پاداشی را در نظریات مالی صرف ریسک سرمایه گذاری نامیده‌اند که در مدل قیمت گذاری دارایی‌های سرمایه ای، متناسب با شاخص ریسک سیستماتیک (بتا)، تعدیل می‌گردد (داموداران، ۲۰۱۲). مدل قیمت گذاری دارایی‌های سرمایه ای را می‌توان به صورت رابطه (۱) بیان نمود (پونیت و همکاران، ۱۹۹۳):

$$E(R_i) \varepsilon_1 = \varepsilon_0 + \beta_i \quad \text{رابطه (۱)}$$

بگونه ای که  $E(R_i)$ ، نرخ بازده مورد انتظار سرمایه گذار و  $\varepsilon_0$  نرخ بازده یک پرتفوی با شاخص بتای برابر صفر را نشان می‌دهد که به عنوان نرخ بازده بدون ریسک شناخته می‌شود.  $\varepsilon_1$  صرف ریسک بازار و  $\beta_i$  بیانگر شاخص بتای سهام  $i$  است. از این معادله می‌توان برداشت نمود که مدل فوق قایل به وجود رابطه خطی بین شاخص بتا و بازده مورد انتظار سرمایه گذار است. به همین خاطر، پیش بینی بازده مورد انتظار توسط این مدل بر اساس تابعی خطی از بتای بازار انجام می‌گیرد. شواهد بسیاری بر مبنای این مدل بدست آمده که بتا تن‌ها متغیری است که قابلیت پیش بینی بازده یک ورقه بهادار و همچنین سبدهی از سهام را دارد. در تایید این شواهد می‌توان به پژوهش‌های داگلاس<sup>۲</sup> (۱۹۶۹)، میلر و اسکولز<sup>۳</sup> (۱۹۷۲) و فرنند و بلومه<sup>۴</sup> (۱۹۷۰) اشاره نمود [۸].

### شاخص بتا

چون سرمایه گذاران در کسب بازده از یک پرتفوی مشترک توافق دارند، باید صرف ریسک سرمایه گذاری در این پرتفوی به نحوی بین آن‌ها تسهیم گردد. این تسهیم، متناسب با تاثیر ریسک سهام خریداری شده سرمایه گذار در ریسک کل پرتفوی انجام می‌شود. تاثیر ریسک یک سهام مجزا در ریسک پرتفوی بازار به صورت نسبت کوواریانس بازده سهام و بازده بازار به واریانس بازده بازار محاسبه و از آن به عنوان فاکتور بتا یاد می‌شود. تحلیل شیوه محاسبه بتا نشان می‌دهد که با این روش اثر ریسک یک سهم، در تسهیم صرف ریسک، خنثی شده است.

به بیان دیگر حتی اگر انحراف معیار بازده یک سهم به عنوان شاخصی از ریسک خرید آن افزایش یابد اما کوواریانس بازده سهم و بازده پرتفوی بازار روند کاهنده به خود بگیرد، صرف کمتری نصیب خریدار این سهام خواهد شد (شاه و همکاران، ۲۰۱۱).

### مدل سه عاملی فاما و فرنچ<sup>۵</sup>

فاما و فرنچ در پژوهشی که بر مبنای داده‌های مربوط به بازارهای مالی آمریکا در دوره بین سال‌های ۱۹۶۳ تا ۱۹۹۰ انجام دادند، دریافتند که رفتار میانگین بازده سهام در آن دوره تن‌ها با استفاده از بتای مدل قیمت‌گذاری قابل تشریح نبوده و ریسک مربوط به بازده سهام چند بعدی است. آنان در سال ۱۹۹۳ با مطالعه روند سود و بازده شرکت‌ها و تجزیه و تحلیل نتایج به دست آمده، مدل قیمت‌گذاری را با افزودن دو عامل اندازه و ارزش شرکت‌ها (در قالب متغیرهایی که تاثیر معنی‌دار روی بازده سهام دارند)، تعدیل و مدل سه عاملی را معرفی نمودند.

### عامل اندازه شرکت‌ها

فاما و فرنچ به منظور تعیین اثر اندازه شرکت‌ها به ایجاد پرتفوی‌هایی بر مبنای دو عامل اندازه و بتای سهام اقدام کردند. نتایج نشان داد که برای شرکت‌هایی که از نظر اندازه در یک سطح قرار گرفته‌اند، رابطه معنی‌داری بین عامل بتا و بازده سهام وجود ندارد و در واقع این عامل اندازه است که توانایی تبیین نوسانات بازده را در این شرکت‌ها داراست.

### عامل ارزش شرکت‌ها


پژوهش‌های بسیاری از نسبت مبلغ دفتری به ارزش بازار حقوق صاحبان سهام برای ارزش‌گذاری این متغیر به عنوان یک عامل خطر برای توضیح نوسانات بازده سهام بهره‌برده‌اند (لویلن، ۱۹۹۹). در این زمینه گریفین و لمون<sup>۶</sup> ثابت کرده‌اند که اگر بازده یک سهم در قبال هر واحد تغییر در این نسبت حساسیت بیشتری از خود بروز داد، ریسک خرید آن سهام بیشتر است (نواک و دیلبر، ۲۰۱۰). از نظر فاما و فرنچ (۱۹۹۲) این نسبت در مقایسه با متغیرهای مشابه پارامتر ممتاز تری برای توضیح و پیش‌بینی نوسانات بازده سهام به حساب می‌آید.

### شبکه‌های عصبی مصنوعی

ویژگی‌های متعددی در شبکه‌های عصبی مصنوعی وجود دارد که آن‌ها را برای پیش‌بینی‌ها جذاب و درعین حال ارزشمند نموده است. از آن جمله مزایایی است که این شبکه‌ها در مقایسه با روش‌های متداول پیش‌بینی دارند (ژانگ و همکاران، ۱۹۹۸). از عمده‌ترین خصوصیات شبکه‌های عصبی نسبت به مدل‌های قدیمی‌تر پیش‌بینی، می‌توان به غیرخطی بودن و ناپارامتری بودن آن‌ها اشاره نمود. شبکه‌های عصبی مصنوعی آموزش پذیر بوده و توانایی استنباط دقیق نوعی از روابط کارکردی میان داده‌ها را دارند، که زمینه این روابط برای روش‌های معمولی پیش‌بینی به سختی قابل توضیح و یا حتی ناشناخته است (چنگ و تیتزینگتن، ۱۹۹۴). این شبکه‌ها در مقایسه با روش‌های سنتی پیش‌بینی، ساختارهایی داده‌محور به حساب می‌آیند که به دلیل ویژگی‌های تعمیم‌پذیری یافته‌ها، مفروضات قیاسی کمتری برای کلیت بخشیدن به نتایج حاصل از پیش‌بینی آن‌ها نیاز است. تعمیم‌پذیری به این معناست که پس از آموزش شبکه عصبی، تحلیل شبکه (از مجموعه ورودی‌هایی که در قالب مثال‌های آموزشی به شبکه ارائه شده‌اند) در مورد ورودی‌های آموزش داده نشده نیز صدق می‌نماید. از آنجا که نرون بیولوژیکی، نهاد مبنای در سیستم عصبی به حساب می‌آید، شناخت ساختار آن برای توصیف نحوه عملکرد نرون‌ها و شبکه‌های مصنوعی ضروری است.

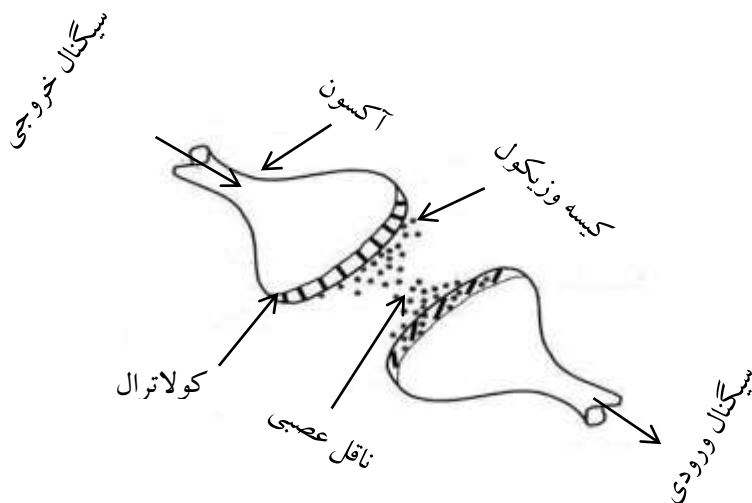
### نرون بیولوژیکی

سه جز عمده یک نرون بیولوژیکی شامل دندریت‌ها<sup>۱</sup>، بدنه سلول<sup>۲</sup> و آکسون<sup>۳</sup> است. بدنه سلول شامل هسته سلول<sup>۴</sup> و پلازما<sup>۵</sup> است. هسته یک سلول حاوی اطلاعات مرتبط با وراثت بوده و پلازما نیز ترکیبات مولکولی ای را نگهداری می‌نماید که در تولید مواد مورد نیاز برای حیات نرون استفاده می‌شود [۳]. ساختار یک نرون بیولوژیکی در شکل (۱) ارائه گردیده است (هگان و همکاران، ۱۹۹۶).



شکل (۱) نرون بیولوژیکی

وظیفه دندریت‌ها دریافت سیگنال‌ها از دیگر سلول‌ها و ارسال آن‌ها به بدنه سلول است. فرآیند کارکرد بر روی سیگنال دریافتی با یک عمل ساده‌ی جمع و مقایسه با یک سطح آستانه، مدل می‌گردد. آکسون که خود به رشته‌های کولاترال<sup>۱۲</sup> منشعب می‌شود، برون داد این فرآیند را از طریق اتصالات سیناپسی به دندریت سلول‌های دیگر منتقل می‌نماید. سیگنال پس از عبور از دندریت‌ها به غشای پیش سیناپسی<sup>۱۳</sup> می‌رسد. به محض انتقال سیگنال به این غشا، کیسه‌های وزیکول<sup>۱۴</sup>، بر پایه شدت موج دریافتی، ناقل عصبی<sup>۱۵</sup> ترشح می‌نمایند. ناقل عصبی در فاصله سیناپسی<sup>۱۶</sup> بین دو بین دو نرون به سمت غشای پس سیناپسی<sup>۱۷</sup> نرون دریافت کننده پیش رفته تا در نهایت به دندریت‌های این نرون می‌رسد. سپس بسته به حد آستانه دریافت نرون، آن را برای ایجاد یک سیگنال الکتریکی تحریک می‌نماید (بشیر و هجمیر، ۲۰۰۰). در شکل (۲) نحوه اتصالات بین دو نرون با ترشحات ناقل عصبی نشان داده شده است.



شکل (۲) اتصال دو نرون بیولوژیکی

### نرون مصنوعی

این نرون‌ها ورودی‌ها ( $x_i$ ) را به صورت محرکی از محیط دریافت نموده و آن‌ها را برای دستیابی به یک ورودی خالص ( $y$ ) تلفیق می‌نمایند. محاسبه ورودی خالص از طریق وزن دار کردن سیگنال ورودی صورت می‌پذیرد. وزن یک سیگنال ( $w_i$ ) برابر با شدت موجی است که سیگنال به نرون وارد می‌نماید. مقادیر وزنی سیگنال‌های ورودی می‌توانند اسکالرهایی مثبت یا منفی باشند. این اسکالرها بردارهایی با اندازه‌هایی جبری در مجموعه اعداد صحیح هستند. وزن مثبت یک ورودی، باعث تحریک نرون و در نتیجه افزایش ورودی خالص و وزن منفی به دلیل مهار نرون، باعث کاهش ورودی خالص خواهد شد. هر زمان که ورودی خالص نرون از حد آستانه‌ای دریافت آن بیشتر باشد، نرون با بایاس<sup>۱۸</sup> مواجه گردیده است. به منظور تعیین خروجی نرون، جمع وزنی سیگنال‌های ورودی از بابت بایاس تعدیل گردیده، سپس به تابع انتقال<sup>۱۹</sup> نرون منتقل می‌گردد. ورودی خالص پس از عبور از تابع انتقال، به خروجی نرون ( $y$ )، تبدیل و در قالب سیگنال خروجی به نرون بعدی رسیده و یا در محیط انتشار می‌یابد. توابع انتقال بر مبنای خصوصیات خاص مسئله‌ای که نرون برای حل آن طراحی گردیده است، انتخاب می‌گردند. سه مورد از شناخته شده‌ترین این توابع عبارتند از تابع انتقال به شدت محدود ساز<sup>۲۰</sup>، تابع انتقال خطی<sup>۲۱</sup> و تابع انتقال زیگموئید<sup>۲۲</sup>. در نگاره (۱) روابط میان ورودی و خروجی این توابع تبیین شده است.


## نگاره (۱): ارتباط ورودی و خروجی توابع انتقال

نوع تابع انتقال	ارتباط ورودی ( $\xi$ ) و خروجی ( $y$ )
به شدت محدود ساز	$y=0$ : آنگاه $\xi < 0$ : اگر
	$y=1$ : آنگاه $\xi \geq 0$ : اگر
خطی	$y = \xi$
زیگموئید	$y = \frac{1}{1+e^{-\xi}}$

اگر چه انواع مختلفی از توابع انتقال شناخته شده‌اند، هنوز به لحاظ تئوری مزیتی برای یک تابع انتقال خاص نسبت به دیگر توابع بیان نگردیده است.

## معماری شبکه

بر اساس معماری خاص یک شبکه، چگونگی اجتماع نرون‌ها در هر لایه از یک شبکه تعیین شده و نحوه اتصال لایه‌ها برای ایجاد شبکه عصبی مصنوعی توضیح داده می‌شود. دو مدل عمده برای معماری یک شبکه عبارتند از: پیشخور<sup>۳</sup> و پسخور یا برگشتی<sup>۲۴</sup> (کامروزمان و همکاران، ۲۰۰۶). نرون‌ها در یک شبکه پیشخور در چند لایه سازماندهی می‌گردند. لایه ابتدایی، لایه ورودی و آخرین لایه، لایه خروجی نامیده می‌شود. پیشخور بودن به جهت جریان داده‌ها از لایه ورودی به خروجی اشاره دارد. لایه ورودی، داده‌ها را برای حل مساله مورد نظر دریافت نموده و لایه خروجی پاسخی متناسب با اطلاعات دریافتی، در اختیار می‌گذارد. لایه‌های میانی اطلاعات در یافتی از لایه‌های ورودی را پردازش و به سمت لایه خروجی هدایت می‌نمایند. از آنجا که این لایه‌ها هیچ گونه بازخوردی از محیط یا به آن ندارند به لایه‌های پنهان<sup>۲۵</sup> مشهور هستند. شکل شماره (۳) نمودی از یک شبکه پیشخور با سه لایه را نشان می‌دهد (گیم و روپر، ۲۰۰۹).



شکل (۳) شبکه پیشخور سه لایه



تفاوت شبکه‌های پسخور با شبکه‌های پیشخور در این است که در شبکه‌های پسخور حداقل یک سیگنال برگشتی از یک نرون به همان نرون یا نرون‌های همان لایه و یا لایه قبل وجود دارد (منهاج، ۱۳۸۹). معماری شبکه، همچنین شامل ارتباطاتی می‌شود که نرون‌های موجود در لایه‌های مختلف شبکه با هم دارند. عموم شبکه‌هایی که برای مقاصد پیش بینی طراحی می‌گردند، کاملاً متصل در نرون‌های یک لایه و یا نرون‌های یک لایه و لایه بعد هستند، هر چند که ممکن است از شبکه‌هایی با اتصالات مجزا در هر لایه نیز برای چنین اهدافی استفاده گردد.

### یادگیری در شبکه‌های عصبی

فرآیند یادگیری، اصلاح معماری شبکه در مواردی نظیر تنظیم وزن سیگنال‌ها، حذف و یا ایجاد ارتباطات نرونی را شامل می‌گردد. قواعد متنوعی برای یادگیری شبکه‌های عصبی تعریف شده‌اند که در دو طبقه کلی شامل: یادگیری با ناظر<sup>۲۶</sup>، و یادگیری بدون ناظر<sup>۲۷</sup> قرار می‌گیرند. در یادگیری با ناظر، با مقایسه مقادیر خروجی محاسبه شده توسط شبکه و مقادیر هدف (که مجموعه‌ای از پاسخ‌های مطلوب شبکه‌اند) وزن سیگنال‌های ورودی و مقادیر بایاس به گونه‌ای تعدیل می‌گردند که پاسخ شبکه به سمت پاسخ‌های مطلوب حرکت نماید. در مقابل، در یادگیری بدون ناظر هیچ سیگنالی که اطلاعات در مورد مطلوبیت پاسخ شبکه به خود شبکه وارد نماید موجود نبوده و این یعنی اینکه، هیچ برگشتی از محیط که بگوید خروجی‌ها چه باید باشند و یا جواب شبکه چقدر مطلوب است، موجود نیست. در واقع، این قاعده پارامترهای شبکه شامل وزن سیگنال‌ها و بایاس‌ها را صرفاً بر اساس خروجی‌ها تعدیل نموده و هیچ گونه مقدار هدفی وجود ندارد.

### انواع شبکه‌های عصبی

انواع مختلفی از شبکه‌های عصبی شناخته شده است. لیپمن<sup>۲۸</sup> (۱۹۸۷) (بر اساس نوع داده‌های ورودی [دو دویی یا پیوسته] و نیز قواعد یادگیری [با ناظر یا بدون ناظر])، سیمپسون<sup>۲۹</sup> (۱۹۹۰) (بر اساس جهت جریان ورودی‌ها و قواعد یادگیری) و مارین<sup>۳۰</sup> (۱۹۹۱) (طبقه بندی سلسله مراتبی ساختار - قاعده یادگیری) از جمله پژوهشگرانی هستند که انواعی از شبکه‌های عصبی را معرفی نموده‌اند. وجود ساختارهای متنوع از شبکه‌های عصبی ضمن اینکه نشان دهنده انعطاف پذیری بالای این شبکه‌ها در حل مسایل متعدد است، تعیین ساختار شبکه مناسب را برای

مقصودی خاص دشوار می‌نماید. در این راستا قضیه ای موسوم به تقریب ساز جهانی اثبات نموده است که شبکه پرسپترون چند لایه با ارتباطات پیشخور، با یک لایه میانی، با توابع تبدیل زیگموئیدی در لایه میانی و توابع تبدیل خطی در لایه خروجی قادر به تقریب تمامی توابع مورد نظر خواهد بود، مشروط بر این که به اندازه کافی در لایه میانی نرون وجود داشته باشد. شبکه‌های پرسپترون در طیف گسترده‌ای از مسایل از جمله در پیش‌بینی‌ها بکار گرفته می‌شوند. دلیل اصلی گستردگی کاربرد این شبکه‌ها قابلیت‌های منحصر بفرد از جمله تعیین نگاشت‌های دلخواه برای ورودی‌ها و خروجی‌های آن‌هاست.

### پرسپترون‌ها

در سال ۱۹۵۸، رزنبلات<sup>۳۱</sup> مکانیزم یک نرون مصنوعی را تبیین و پرسپترون را برای حل مسایل مرتبط با تشخیص الگو معرفی نمود. برای  $n$  سیگنال، ساز و کار یک نرون پرسپترون به صورت رابطه (۲) بیان می‌گردد:

$$y = \begin{cases} 1 & \text{if } \sum_{i=1}^n w_i x_i \geq b \\ 0 & \text{if } \sum_{i=1}^n w_i x_i < b \end{cases} \quad \text{رابطه (۲)}$$

پرسپترون‌ها توانایی یادگیری بر مبنای مجموعه‌ای از مثال‌های آموزشی را دارا هستند. بر این اساس وزن سیگنال‌ها متناسب با تفاوت بین مقادیر هدف (که مجموعه‌ای از پاسخ‌های مطلوب شبکه هستند) و پاسخ واقعی شبکه تغییر می‌کنند. این تغییر در جهت حداقل نمودن تفاوت (که خطای شبکه نامیده می‌شود) صورت می‌گیرد. رزنبلات (۱۹۶۲) قاعده پرسپترون را به صورت " تعیین بردار وزن‌های مطلوب ورودی‌ها از طریق تکرار مثال‌های آموزشی و بدون در نظر گرفتن مقادیر ابتدایی وزن‌ها" بیان نمود. این قاعده صرفاً برای مسایلی که جدایی سازی خطی دارند کاربرد داشت. به همین خاطر برای حل مسایل مرتبط با جدایی سازی غیر خطی لایه‌های میانی، بین لایه ورودی (متشکل از نرون‌های ورودی) و لایه خروجی قرار گرفت که منجر به ساختار پرسپترون چند لایه گردید. یادگیری در شبکه‌های پرسپترون چند لایه مشابه پرسپترون ساده نیست. از جمله قواعد یادگیری شبکه‌های چند لایه، پس انتشار خطا<sup>۳۲</sup> است.

### الگوریتم پس انتشار خطا

هدف این الگوریتم کاهش خطای شبکه است. این کار از طریق تغییر مکرر وزن ورودی‌ها صورت می‌گیرد. خطای شبکه در این الگوریتم به صورت مجذور تفاوت مقادیر واقعی داده‌ها و مقادیر بدست آمده از شبکه محاسبه می‌گردد. در الگوی پس انتشار با هر مثالی که به شبکه وارد می‌شود، مقادیر وزن‌ها در جهت کاهش خطا به روز رسانی می‌گردند. رویه در الگوریتم پس انتشار بدین صورت است که ابتدا سیگنال ورودی تا محاسبه مقادیر خروجی در شبکه پیش می‌رود. سپس تفاوت مقادیر واقعی و خروجی شبکه محاسبه شده و برای تعدیل وزن‌ها استفاده می‌شود. تعدیل وزن‌ها در جهت هر چه کمتر نمودن خطای شبکه انجام می‌گیرد. این تعدیل از لایه‌های خروجی به سمت لایه‌های قبلی صورت می‌پذیرد. تکرار مثال‌های آموزشی تا سطحی است که وزن‌ها کاملاً در شبکه تعدیل شده باشند (اورکچی و بال، ۲۰۱۱). الگوریتم پس انتشار نوعی یادگیری با ناظر محسوب می‌شود. واژه پس انتشار خطا به شیوه این الگوریتم در تعدیل وزن‌ها اشاره دارد که بر اساس آن خطای محاسبه شده در لایه خروجی، مبنای تعدیل وزن‌ها در لایه‌های پیشین شبکه (میانی و ورودی) فرض می‌شود.

### نتیجه گیری

اگر چه تدوین مدل‌های سنتی پیش بینی توانسته تا حدودی نیازهای اطلاعاتی طیفی از سرمایه گذاران را پاسخ دهد، اما معرفی تکنیک‌های جدید نظیر شبکه‌های عصبی در تحلیل بازارهای مالی موجب می‌گردد تا محیط حاکم بر این بازارها دستخوش تغییرات بسیاری شود. از دلایل گسترده‌گی کاربرد شبکه‌های عصبی در مسایل مالی و اقتصادی سفارشی بودن ساختار این شبکه هاست. این ویژگی باعث می‌شود تا شبکه‌های عصبی نسبت به مدل‌های ساختاری از انعطاف پذیری بالاتری در حل مسایل برخوردار باشند. محدودیت‌های مدل‌های ساختاری موجب شده است تا تحلیل گران پیش از مدل سازی، نیازمند پیش فرض هایی برای ساده نمودن روابط واقعی حاکم بین متغیرها باشند. در حالی که با شبکه‌های عصبی می‌توان از جایگاهی فراتر از این فرضیات دست و پاگیر به تحلیل متغیرها و پیش بینی رفتار آتی آن‌ها اقدام نمود. بر این اساس می‌توان ادعا کرد که این شبکه‌ها به خصوص زمانی که امکان بکارگیری روش‌های پارامتری به دلیل غیر خطی بودن روند تغییرات وجود نداشته باشد، ابزاری سودمند در پیش بینی‌های مالی

به حساب آمده و دقت بالاتری بدست می‌دهند. این نتایج در انطباق با پژوهش بسیاری از جمله بشیر و همجیر (۲۰۰۰)، کینگ و همکاران (۲۰۰۵) و ژانگ و همکاران (۱۹۹۸) می‌باشند. سوابق بکارگیری تکنیک‌هایی نظیر شبکه‌های عصبی در این پژوهش‌ها نشان می‌دهد که اغلب آن‌ها با استقبال فراوانی از طرف سرمایه‌گذاران روبرو می‌شوند. چرا که به موجب ارتباط تنگاتنگی که با فناوری‌های پیشرفته کامپیوتری دارند، انتخاب بهینه از میان گزینه‌های متعدد سرمایه‌گذاری را تسهیل می‌بخشند.

### پی‌نوشت‌ها

۱	Hinich , Patterson	۱۷	Post-synaptic Membrane
۲	Douglas	۱۸	Bias
۳	Miller, Scholes	۱۹	Transfer function
۴	Friend , Blome	۲۰	Hard Limit transfer function
۵	Fama, French	۲۱	Linear transfer function
۶	Griffin, Lemmon	۲۲	Log-Sigmoid transfer function
۷	Dendrites	۲۳	Feed Forward
۸	Cell body	۲۴	Recurrent or feedback
۹	Axon	۲۵	Hidden layer
۱۰	Nucleus	۲۶	Supervised learning
۱۱	Plasma	۲۷	Unsupervised learning
۱۲	Collateral	۲۸	Lippmann
۱۳	Pre-synaptic Membrane	۲۹	Simpson
۱۴	Vesicles	۳۰	Maren
۱۵	Neurotransmitter	۳۱	Rosenblatt
۱۶	Synaptic gap	۳۲	Back Propagation

### منابع

منهاج محمد باقر. (۱۳۸۹). *مبانی شبکه‌های عصبی*، تهران: انتشارات دانشگاه صنعتی امیر کبیر (پلی تکنیک تهران).

Azam Mohammad, Jasir Ilyas. (2011). An Empirical Comparison of CAPM and Fama-French Model: A case study of KSE. *Interdisciplinary Journal of Contemporary Research in Business* (2) , 415-425.

- Basheer I. A. , M. Hajmeer. (2000). Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods* (43) , 3–31.
- Bonilla Claudio A. , Rafael Romero-Meza & Elizabeth Gutiérrez. (2007). nonlinear behavior of the Chilean capital markets. *Applied Economics Letters* (14) , 987 -991.
- Cao Qing, Karyl. B. Leggio & Marc. J. Schniederjans. (2005). A comparison between Fama and French’s model and artificial neural networks in predicting the Chinese stock market. *Computers & Operations Research* (32) , 2499–2512.
- Cheng B. , D. M. Titterington. (1994). Neural networks: A review from a statistical perspective. *Statistical Science* (9 (1)) , 2–54.
- Damodaran Aswath. (2012). Equity Risk Premiums (ERP): Determinants, Estimation and Implications – The 2012 Edition. Available:<http://ssrn.com/> [accessed 10 May 2012].
- Fama Eugene. F. ,D. J. MacBeth. (1981). Risk, Return and Equilibrium: Empirical Tests. *Journal of Political Economy* (73) , 607-636.
- Fama Eugene. F. , Kenneth. R. French. (1993). Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics* (33) , 3-56.
- Fisher Donald E. , Ronald J. Jordan. (1995). *Security Analysis and Portfolio Management (1nd ed)*. New Jersey: Pearson Education publisher.
- Geem Z. W, W. E. Roper. (2009). Energy demand estimation of South Korea using artificial neural network. *Energy Policy* (37) , 4049-4054.
- Gencay Ramazan. (1997). Linear, non-linear and essential foreign exchange rate prediction with simple technical trading rules. *Journal of International Economics* (47) , 91–107.
- Hagan M. T. , H. B. Demuth & MH. Beale. (1996). *Nural Network Design*. Boston: PWS Publishing.
- Hodnett Kathleen, Heng-Hsing Hsieh & Paul van Rensburg. (2012). Nonlinearities In Stock Return Prediction: Evidence From South Africa. *The Journal of Applied Business Research* (28) , 53-73.
- Kaastra I. , Boyd M. S. (1995). Forecasting futures trading volume using neural networks. *The Journal of Futures Markets* 15 (8) , 953-970.
- Kamruzzaman Joarder, Ruhul. A. Sarker & Rezaul Begg. (2006). *Artificial Neural Networks: Applications in Finance and Manufacturing*. Milan: IDEA GROUP Publishing.
- Lewellen Jonathan. (1999). The time-series relations among expected return, risk, and book-to-market. *Journal of Financial Economics* (54) , 5-43.

- Novak Jiri, Dilebor Petr. (2010). CAPM Beta, Size, Book to Market and Momentum in Realized Stock Markets. *Czech Journal of Economics and Finance* (60), 447-460.
- Örkcü Hasan, Hasan Bal. (2011). Goal programming approaches for data envelopment analysis cross efficiency evaluation. *Applied Mathematics and Computation* 218 (2), 346-356.
- Puneet Handa, S. P. Kothare & Charles Wasley. (1993). Sensitivity of Multivariate Tests of the Capital Asset-Pricing Model to the Return Measurement Interval. *The Journal of Finance* (48 (4)), 1543-1551.
- Shah Attaullah, Fahad Abdullah, Tauseef Khan & SafiUllah Khan. (2011). Simplicity Vs Accuracy: The Case Of Capm And Fama And French Model. *Australian Journal of Basic and Applied Sciences* (5 (10)), 520-535.
- Sharpe William. F. (1964). Capital asset prices: A theory of market equilibrium under conditions of risk. *Journal of Finance* (19), 425-442.
- Zhang G. , B. E. Patuwo & M. Y. Hu. (1998). Forecasting with artificial neural networks: the state of the art. *International Journal of Forecasting* (14 (1)) 35-62.