

ارائه مدلی برای پیش‌بینی هزینه و زمان نهایی پروژه‌ها با رویکرد فراالبتکاری

اکبر عالم تبریز*، مجتبی فرخ**، احسان احمدی***

چکیده

در مدیریت پروژه‌های ساخت‌وساز، موفقیت در کنترل هزینه و زمان پروژه‌ها برای کمک به پیمانکاران امری حیاتی است. افزایش هزینه و زمان پروژه‌ها از برنامه تعریف‌شده، ممکن است به کاهش سود و حتی برخی اوقات به شکست پروژه‌ها منجر شود. پیش‌بینی هزینه و زمان نهایی پروژه‌ها، یکی از اقداماتی است که برای کنترل هزینه و زمان پروژه‌ها مورد توجه قرار می‌گیرد. در این تحقیق، مدل شبکه‌های عصبی برای پیش‌بینی هزینه و زمان نهایی پروژه‌ها توسعه یافته و برای متغیرهای ورودی شبکه‌های عصبی، از دو مجموعه متغیر «ارزش کسب‌شده» و «محیطی» استفاده شده است. در این تحقیق، عملکرد تکنیک ارزش کسب‌شده با شبکه‌های عصبی مقایسه شده و به‌طور جداگانه تأثیر هر یک از این مجموعه داده‌ها بر عملکرد مدل در پیش‌بینی هزینه و زمان نهایی، مورد بررسی قرار گرفته است. نتایج تحقیق نشان می‌دهند که عملکرد شبکه‌های عصبی بهتر از مدیریت ارزش کسب‌شده است و با استفاده از شبکه‌های عصبی مبتنی بر داده‌های ارزش کسب‌شده و محیطی می‌توان به نتایج بهتری، در مقایسه با شبکه‌های عصبی مبتنی بر داده‌های ارزش کسب‌شده، رسید.

کلیدواژه‌ها: پیش‌بینی هزینه و زمان اتمام پروژه‌ها؛ مدیریت ارزش کسب‌شده؛ شبکه‌های عصبی؛ متغیرهای ارزش کسب‌شده؛ متغیرهای محیطی.

تاریخ دریافت مقاله: تاریخ پذیرش مقاله:

* استاد، دانشگاه شهید بهشتی.

** دانشجوی دکتری، دانشگاه تهران (نویسنده مسئول).

*** کارشناسی ارشد، دانشگاه شهید بهشتی.

۱. مقدمه

با توجه به وجود چالش‌های پروژه‌های ساخت‌وساز در دنیای امروز، مدیران این پروژه‌ها برای کنترل بهتر وضعیت پروژه‌هایشان باید از تکنیک‌ها و مدل‌هایی برای پیش‌بینی نتایج و عملکرد آن‌ها استفاده کنند. با این پیش‌بینی، مدیریت پروژه تعیین می‌کند که کدام پروژه‌ها به برنامه‌های اصلاحی جزئی و کدام پروژه‌ها به برنامه‌های اصلاحی اساسی برای حل مشکلات نیاز دارند [۱۱]. با این حال، معمولاً شرکت‌های ساخت‌وساز از تکنیک‌های پیشرفته‌ای برای این منظور استفاده نمی‌کنند [۸]. این واقعیت مانع کنترل مؤثر هزینه‌ها و زمان پروژه‌ها و باعث به‌تعویق افتادن زمان شناسایی مشکلات بالقوه می‌شود؛ بنابراین، پیش‌بینی هزینه و زمان اتمام پروژه‌ها برای شناسایی و حل مشکلاتی که براساس وضعیت جدید صورت می‌گیرند، برای رسیدن به مدیریت مؤثر پروژه اجتناب‌ناپذیر است.

در بین تکنیک‌هایی که برای مدیریت و کنترل هزینه و زمان‌بندی پروژه‌ها وجود دارد، تکنیک مدیریت ارزش کسب‌شده (EVM^۱) به‌طور گسترده‌ای برای پیش‌بینی هزینه و زمان اتمام پروژه‌ها استفاده می‌شود [۲۶]. این تکنیک با توجه به پیش‌فرض‌هایی که براساس آن شکل گرفته است، نمی‌تواند به‌درستی نتایج پایانی پروژه‌ها را پیش‌بینی کند. در این تکنیک، حداقل هشت روش برای پیش‌بینی هزینه و زمان اتمام پروژه در مدیریت ارزش کسب‌شده وجود دارد [۱۰]. هریک از این روش‌ها برای پروژه‌های خاص و مختلفی به کار می‌روند و نرخ خطای متفاوتی دارند [۲، ۲۴].

یکی از ضعف‌های مربوط به مدیریت ارزش کسب‌شده این است که برای پیش‌بینی هزینه و زمان اتمام پروژه‌ها، تنها از داده‌های تاریخی همان پروژه‌ای استفاده می‌شود که نتایج آن پیش‌بینی می‌گردد. مطمئناً این داده‌های اندک، با توجه به مشکلات بی‌شماری که در پیشرفت پروژه‌های مشابه دیگر وجود دارد، برای پیش‌بینی نتایج پروژه کافی به‌نظر نمی‌رسد [۴]. با توجه به مشکلات مربوط به سیستم مدیریت ارزش کسب‌شده، توسعه یک سیستم سریع و کارا برای کنترل هزینه و زمان پروژه‌ها، موضوعی حیاتی است که باید انجام شود. در این پژوهش سعی می‌شود برای مشکلات کنترل هزینه و زمان پروژه‌ها، راه‌حلی پیدا شود. برای این کار از مقالات مرتبط موجود در ادبیات تحقیق و گفت‌وگو با صاحب‌نظران حوزه صنعت ساخت‌وساز استفاده شده است تا متغیرهایی که به‌طور قابل توجهی روی هزینه و زمان پروژه‌ها تأثیرگذار هستند، شناسایی شوند.

شبکه‌های عصبی مصنوعی (ANN^1) سیستم کامپیوتری است که می‌تواند مسائل پیچیده یا بدساختار را به صورت ماهرانه و از طریق یادگیری رابطه بین متغیرهای ورودی و خروجی حل کند [۸]. طی یک دهه گذشته، در تحقیقات بی‌شماری از این تکنیک برای پیش‌بینی هزینه و زمان پروژه‌های ساخت‌وساز استفاده شده است؛ اما در هیچ‌یک از آن‌ها عملکرد شبکه‌های عصبی با تکنیک ارزش کسب‌شده مقایسه نشده است. به نظر می‌رسد که با توجه به پیچیده بودن ماهیت هزینه و زمان پروژه‌ها، شبکه‌های عصبی می‌تواند با عملکرد بهتری نسبت به تکنیک مدیریت ارزش کسب‌شده، نتایج پایانی پروژه‌ها را پیش‌بینی کند. در این پژوهش، یک مدل پیش‌بینی مبتنی بر شبکه‌های عصبی ($EAC-ANN^2$) با استفاده از داده‌های ارزش کسب‌شده و داده‌های محیطی توسعه می‌یابد که طی فازهای اجرایی پروژه، هزینه و زمان نهایی پروژه‌ها به نحو بهتری کنترل شود. هدف اصلی این تحقیق طراحی مدل شبکه عصبی برای پیش‌بینی هزینه و زمان نهایی پروژه‌های صنعت ساخت‌وساز است تا مدیران بتوانند هزینه و زمان را بهتر کنترل کنند و با خطای کمتری نسبت به تکنیک ارزش کسب‌شده، هزینه و زمان پروژه‌ها را پیش‌بینی کنند.

۲. مبانی نظری و پیشینه پژوهش

بسیاری از محققان به مطالعه پیش‌بینی هزینه و زمان پروژه با استفاده از تکنیک‌های مختلف پرداخته‌اند. این تکنیک‌ها شامل تکنیک‌های تجزیه و تحلیل آماری مانند تجزیه و تحلیل رگرسیون چندگانه (MAR^3)، تکنیک‌های تجزیه و تحلیل مبتنی بر احتمالات مانند شبیه‌سازی مونت کارلو (MCS^4) و تکنیک‌های مبتنی بر هوش مصنوعی (AI^5) مانند شبکه‌های عصبی (ANN)، الگوریتم ژنتیک (GA^6) و ماشین بردار پشتیبان (SVM^7) هستند. مدل‌های سنتی پیش‌بینی هزینه، با استفاده از روش‌های آماری توسعه داده شده‌اند [۲۱]. تجزیه و تحلیل رگرسیون، یکی از روش‌های سنتی است [۵، ۱۴]. یکی از معایب روش تجزیه و تحلیل رگرسیون این است که به یک شکل ریاضی تعریف‌شده برای توابع هزینه نیاز دارد. فرض مدل‌های سنتی پیش‌بینی هزینه بر خطی بودن رابطه بین متغیرهای ورودی و خروجی است و به همین دلیل، کاربرد این روش‌ها محدود شده است [۱۳]. اخیراً به دلیل ظهور تکنولوژی‌های کامپیوتری و تکنیک‌های برنامه‌ریزی ریاضی، رویکردهای توسعه داده‌شده بیشتر از روش‌های پیچیده‌تر همراه با حجم بالایی از داده‌ها استفاده می‌کنند.

1. Artificial Neural Network
2. Estimate at Completion ° Artificial Neural Network
3. Multiple Regression Analysis
4. Mont Carlo Simulation
5. Artificial Intelligent
6. Genetic Algorithm
7. Support Vector Machine

رویکرد هوش مصنوعی یکی از روش‌های جدیدی است که برای مسئله پیش‌بینی هزینه استفاده شده است. این رویکرد مبتنی بر سیستم‌های خبره (ES^۱)، علت‌یابی مبتنی بر مورد (CBR^۲)، شبکه‌های عصبی، منطق فازی (FL^۳)، الگوریتم ژنتیک و یا ترکیبی از این روش‌ها هستند. یاو و یانگ^۴ (۱۹۹۸) از مدل علت‌یابی مبتنی بر مورد، برای تخمین هزینه و زمان پروژه‌های ساخت‌وساز طی مرحله طراحی اولیه استفاده کردند. آن‌ها تشریح کردند که تکنیک علت‌یابی مبتنی بر مورد می‌تواند در مدیریت و پیش‌بینی هزینه و زمان اتمام پروژه‌های ساخت‌وساز، در مراحل اولیه طراحی یک پروژه ساخت‌وساز به کار رود [۳۱].

راو^۵ و همکاران (۱۹۹۳) از رویکرد سیستم خبره-عصبی برای تخمین هزینه پروژه‌های ساخت‌وساز استفاده کردند [۲۰]، ویلیامز^۶ (۱۹۹۴) از شبکه‌های عصبی برای پیش‌بینی تغییر در شاخص هزینه ساخت‌وساز استفاده کرد [۲۹] و بوسابین و الهاگ^۷ (۱۹۹۷) یک سیستم عصبی فازی را برای تخمین هزینه و زمان پروژه‌های ساخت‌وساز توسعه دادند [۶]. آدلی و وو^۸ (۱۹۹۸) از شبکه‌های عصبی برای تخمین هزینه ساخت اتوبان استفاده کردند [۱]. هگیز و آید^۹ (۱۹۹۸) شبکه‌های عصبی را برای توسعه یک مدل تخمین هزینه پارامتریک برای پروژه‌های ساخت اتوبان به کار بردند و برای بهینه‌سازی وزن‌های شبکه‌های عصبی، از الگوریتم ژنتیک استفاده کردند [۱۲]. آتالا و هگز^{۱۰} (۲۰۰۳) به پیش‌بینی هزینه پروژه‌های ساخت‌وساز با استفاده از شبکه‌های عصبی و رگرسیون پرداختند و نتایج تحقیقشان نشان داد که عملکرد شبکه‌های عصبی بهتر از مدل‌های رگرسیون است [۳]. کیم و همکاران (۲۰۰۴) از مدل‌های شبکه‌های عصبی و الگوریتم ژنتیک برای تخمین هزینه ساخت مسکن، برای پیش‌بینی تخمین‌های اولیه هزینه استفاده کردند [۱۶] و ویلموت و می^{۱۱} (۲۰۰۵) مدل شبکه‌های عصبی را برای پیش‌بینی شکست هزینه پروژه ساخت اتوبان به کار بردند [۲۸]. کیم^{۱۲} و همکاران (۲۰۰۵) یک مدل پیش‌بینی هزینه مبتنی بر CBR، MRA و ANN را برای پیش‌بینی هزینه یک پروژه خانه‌سازی توسعه دادند و عملکرد پیش‌بینی هر یک از این مدل‌ها را با یکدیگر مقایسه کردند و نتایج نشان داد که عملکرد پیش‌بینی ANN از سایر مدل‌ها بهتر است [۱۵]. سونمز^{۱۳} (۲۰۱۱) یک مدل

1. Expert System
2. Case ° Based Reasoning
3. Fuzzy Logic
4. Yau & Yang
5. Rao
6. Williams
7. Boussabaine & Elhag
8. Adeli & Wu
9. Hegazy & Ayed
10. Attalla & Hegazy
11. Wilmot.& Mei
12. Kim
1. Sonmez

شبکه‌های عصبی با فواصل پیش‌بینی خودراه‌انداز^۱ را برای پیش‌بینی هزینه ساخت‌وساز ارائه داد و با پیدا کردن رابطه بین متغیرهای مربوط به ساختمان، مکان و شرایط ساخت‌وساز به‌عنوان متغیرهای مستقل و عناصر هزینه به‌عنوان متغیرهای وابسته، به محاسبه هزینه ساخت‌وساز پرداخت [۲۵]. وانگ^۲ و همکاران (۲۰۱۱) با معرفی شاخص تعریف پروژه که مبتنی بر ۶۴ متغیر وضعیتی است، به پیش‌بینی امکان موفقیت در رسیدن به هزینه و زمان برنامه اولیه پرداختند و در مدل خود، از شبکه‌های عصبی و ماشین بردار پشتیبان استفاده کردند [۳۰]. چنگ^۳ و همکاران (۲۰۱۲) با ترکیب ماشین بردار پشتیبان، منطق فازی و الگوریتم ژنتیک و با استفاده از شاخص‌های ارزش کسب‌شده، به پیش‌بینی هزینه کمک کردند [۷].

جدول ۱. مقایسه مدل پیشنهادی با مدل‌های هوش مصنوعی سابق

| مدل‌ها | تکنیک‌های استفاده‌شده | شاخص‌های پیش‌بینی (متغیرهای مستقل) | نوع پیش‌بینی (متغیرهای وابسته) |
|---------------------------|---|---|------------------------------------|
| آتالا و هگز (۲۰۰۳) | شبکه‌های عصبی با رگرسیون | متغیرهای محیطی | هزینه ساختمان |
| ویلموت و می (۲۰۰۵) | شبکه‌های عصبی | مختصات برنامه اولیه پروژه | هزینه اتوبان |
| کیم و همکاران (۲۰۰۵) | شبکه‌های عصبی و الگوریتم ژنتیک | ویژگی‌های ساختمان | هزینه ساختمان |
| ریفات سونمز (۲۰۱۱) | شبکه‌های عصبی | متغیرهای مربوط به ساختمان، مکان و شرایط ساخت‌وساز | هزینه ساختمان |
| وانگ و همکاران (۲۰۱۱) | شبکه‌های عصبی و ماشین بردار پشتیبان | ۶۴ متغیر مربوط به وضعیت ابتدایی پروژه | احتمال موفقیت هزینه و زمان ساختمان |
| چنگ و همکاران (۲۰۱۲) | ماشین بردار پشتیبان، منطق فازی و الگوریتم ژنتیک | شاخص‌های ارزش کسب‌شده | هزینه ساختمان |
| مدل پیشنهادی (تحقیق حاضر) | شبکه‌های عصبی | شاخص‌های ارزش کسب‌شده و فاکتورهای محیطی | هزینه و زمان ساختمان |

۳. روش‌شناسی پژوهش

داده‌های مورد استفاده در این تحقیق، به پروژه‌های ساختمان‌سازی مسکن مهر مربوط هستند که بین سال‌های ۱۳۸۵ تا ۱۳۹۱ توسط چند شرکت ساخت‌وساز در استان‌های تهران و قم اجرا شده‌اند. این پروژه‌ها به‌ترتیب حروف لاتین از A تا N نام‌گذاری شده‌اند. ساختمان‌ها

2. Bootstrap
3. Wang
4. Cheng

شامل ۳ تا ۷ طبقه به همراه زیرزمین می‌شود. ارزش قراردادهای آن ۲/۱ میلیارد تومان تا ۲۲ میلیارد تومان متغیر است و کل مساحت ساختمان‌ها از ۳۹۴ تا ۳۷۸۸ متر مکعب است. مدت زمان اجرای پروژه‌ها از ۱۵ تا ۳۹ ماه متغیر است. مجموعه داده‌های تاریخی به داده‌های آموزش A, B, D, E, F, G, I, J, K, L, M, N و داده‌های آزمایش C و H تقسیم می‌شوند. داده‌های آزمایش به پیشنهاد خبرگان، با توجه به نزدیکی الگوی این داده‌ها به داده‌های آتی انتخاب شده‌اند. داده‌های آموزش ۳۰۵ مورد و داده‌های آزمایش نیز ۶۵ مورد هستند.

پیش‌بینی EAC^1 و $EAC(t)^2$ در تکنیک ارزش کسب‌شده. در زمینه متدولوژی مدیریت ارزش کسب‌شده، دو متغیر مهم وجود دارد که با عنوان تخمین هزینه تکمیل (نهایی) پروژه (EAC) و تخمین زمان تکمیل (نهایی) پروژه ($EAC(t)$) شناخته شده‌اند. در این تحقیق، برای محاسبه EAC و $EAC(t)$ ، از سه مورد از روش‌های (فرمول‌ها) تکنیک ارزش کسب‌شده استفاده کردیم. این روش‌ها در تحقیقات قبلی، بیشتر از روش‌های موجود تأیید شده‌اند [۲۷]. اصطلاحات مرتبط با مدیریت ارزش کسب‌شده در جدول ۲ ارائه شده است.

جدول ۲. اصطلاحات مرتبط با ارزش کسب‌شده

| نماد | توضیح |
|-----------------|-----------------------|
| PV^3 | ارزش برنامه‌ریزی شده |
| AC^4 | هزینه واقعی |
| EV^5 | ارزش کسب‌شده |
| $CPI^6 = EV/AC$ | شاخص عملکرد هزینه |
| $SPI^7 = EV/PV$ | شاخص عملکرد زمان‌بندی |
| BAC^8 | بودجه کل پروژه |
| ES^9 | زمان‌بندی کسب‌شده |
| PD^{10} | زمان برنامه‌ریزی شده |

پیش‌بینی EAC و $EAC(t)$ در شبکه‌های عصبی

فاکتورهای مؤثر در پیش‌بینی EAC و $EAC(t)$ در این تحقیق، ۹ عامل بسیار مؤثر و مهم

1. Estimate At Completion (EAC)
2. Estimate At Completion (Time) (EAC(t))
3. Planned Value (PV)
4. Actual Cost (AC)
5. Earned Value (EV)
6. Cost Performance Index (CPI)
7. Scheduling Performance Index (SPI)
8. Budget At Completion (BAC)
9. Estimated Scheduling (ES)
1. Planned Duration (PD)

برای مسئله پیش‌بینی EAC و EAC(t) را انتخاب کرده‌ایم که در دو دسته فاکتورهای ارزش کسب‌شده و فاکتورهای محیطی طبقه‌بندی شده‌اند. فاکتورهای ارزش کسب‌شده از مهم‌ترین فاکتورهای این تکنیک هستند که در پیش‌بینی هزینه و زمان نهایی پروژه‌ها مورد استفاده قرار می‌گیرند. فاکتورهای محیطی نیز به پیشنهاد خبرگان صنعت ساخت‌وساز انتخاب شده‌اند. این عوامل در جدول‌های ۳ و ۴ نشان داده شده‌اند:

جدول ۳. فاکتورهای تأثیرگذار مدیریت ارزش کسب‌شده بر EAC و EAC(t)

| فاکتور | فاکتور | شاخص | تعریف |
|----------------|-------------------|---|------------------|
| F ₁ | زمان واقعی پروژه | درصد پیشرفت پروژه (AD _p) | $\frac{AD}{PD}$ |
| F ₂ | هزینه واقعی پروژه | درصد هزینه واقعی (AC _p) | $\frac{AC}{BAC}$ |
| F ₃ | ارزش کسب‌شده | درصد ارزش کسب‌شده (EV _p) | $\frac{EV}{BAC}$ |
| F ₄ | زمان‌بندی کسب‌شده | درصد زمان‌بندی کسب‌شده (ES _p) | $\frac{ES}{PD}$ |
| F ₅ | مدیریت هزینه | شاخص عملکرد هزینه (CPI) | $\frac{EV}{AC}$ |
| F ₆ | مدیریت زمان | شاخص عملکرد زمان‌بندی (SPI) | $\frac{EV}{PV}$ |

جدول ۴. فاکتورهای تأثیرگذار محیطی بر روی EAC و EAC(t)

| فاکتور | فاکتور | شاخص | تعریف |
|----------------|-----------------------------|---|---------------------------|
| F ₇ | نوسانات قیمت مصالح ساختمانی | شاخص هزینه ساختمان (CCI) | MPI_t^2 / MPI_1^3 |
| F ₈ | شرایط آب و هوایی | شاخص تأثیرات آب و هوایی (CEI ^۴) | $(AD \cdot NRD^5) / (AD)$ |
| F ₉ | کیفیت پرداخت به پیمانکار | شاخص پرداخت به پیمانکار (CBI ^۶) | CBA^7 / AC |

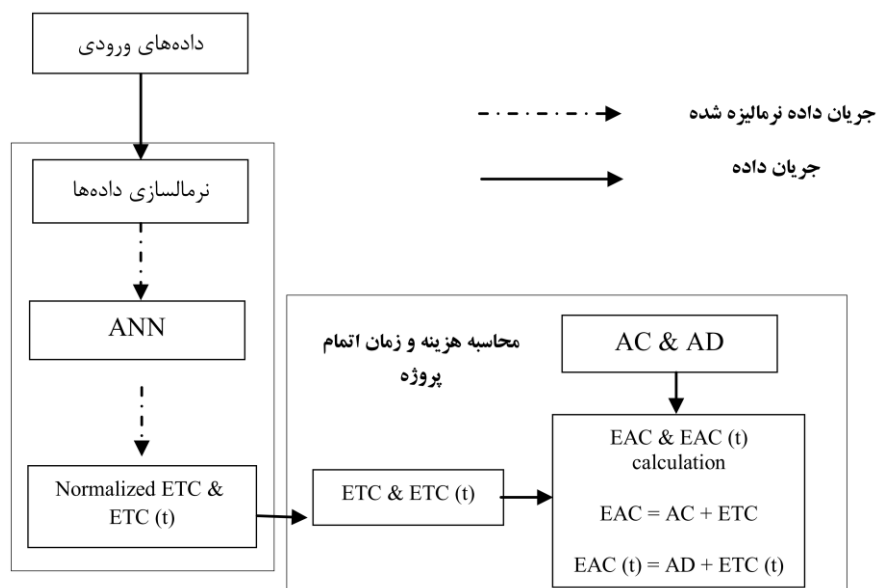
گفتنی است که شاخص قیمت مصالح ساختمانی (MPI) نشان‌دهنده نرخ رشد قیمت مصالح

2. Construction Cost Index
3. Material Price Index of that month
4. Material Price Index of initial month
5. Climate Effect Index
6. Number of Rainy day
7. Contractor billed index
8. Contractor billed Amount

ساختمانی در هر ماه است و NRM تعداد روزهای برفی و بارانی را نشان می‌دهد که عملیات ساخت متوقف می‌شود. CBA نیز مبلغ پول پرداختی به پیمانکار است که به‌نظر خبرگان ممکن است روی نتایج پروژه تأثیرگذار باشد.

محاسبه EAC و EAC(t) در شبکه‌های عصبی. برای پیش‌بینی EAC و EAC(t)، یک بار از فاکتورهای ارزش کسب‌شده استفاده می‌شود و یک بار از فاکتورهای ترکیبی. در استفاده از فاکتورهای ارزش کسب‌شده برای پیش‌بینی EAC و EAC(t)، با توجه به جدول ۳، از ۶ معیار مرتبط با هریک از آن‌ها استفاده می‌شود. خروجی حاصل از این پیش‌بینی‌ها به‌ترتیب به‌صورت $EAC-ANN_{UF}$ و $EAC(t)-ANN_{UF}$ نشان داده می‌شوند. در این مدل‌ها فاکتورهای محیطی برای پیش‌بینی هزینه و زمان اتمام پروژه‌ها دخالت داده نمی‌شوند. در استفاده از فاکتورهای ترکیبی برای پیش‌بینی EAC و EAC(t) که شامل فاکتورهای ارزش کسب‌شده و فاکتورهای محیطی می‌شود؛ با توجه به جداول ۳ و ۴، از ۹ معیار مرتبط با هریک از آن‌ها استفاده می‌شود. خروجی حاصل از این پیش‌بینی‌ها به‌ترتیب به‌صورت $EAC-ANN_F$ و $EAC(t)-ANN_F$ نشان داده می‌شوند. فاکتورهای محیطی، شامل نرخ تورم در قیمت مصالح ساختمانی، شرایط آب و هوایی و کیفیت پرداخت به پیمانکاران است. انتظار می‌رود با اضافه شدن این متغیرها به متغیرهای ارزش کسب‌شده، در نتایج پیش‌بینی بهبود حاصل شود. در این پژوهش، چهار شبکه عصبی توسعه داده می‌شود که برای هریک از پیش‌بینی‌های مربوط به زمان و هزینه، از دو مدل استفاده شده است. از این داده‌ها برای یادگیری شبکه استفاده می‌شود؛ به‌طوری که در این یادگیری باید داده‌های ورودی ویژگی‌های یکسانی با داده‌های یادگیری داشته باشند که به‌طور کامل در جداول ۳ و ۴ شرح داده شده‌اند. شکل ۱ فرآیند $EAC-ANN$ و $EAC(t)-ANN$ را نشان می‌دهد. فرآیند محاسبه EAC و EAC(t) شامل دو بخش است: محاسبه ETC^1 و $ETC(t)$ و محاسبه EAC و EAC(t). با یک الگوی خاصی از ورودی‌ها، مدل شبکه‌های عصبی از تابع رگرسیون برای پیش‌بینی EAC و EAC(t) استفاده می‌کند؛ این تابع طی فرآیند یادگیری یافت شده است. در طی فرآیند یادگیری شبکه، پارامترهای شبکه باید طوری انتخاب شوند که مدل با حداقل خطا بتواند نتایج هزینه و زمان نهایی پروژه را تخمین بزند. این پارامترها شامل تعداد لایه‌های پنهان، تعداد نرون‌ها و ... است.

1. Estimate To Completion



شکل ۱. فرآیند پیش‌بینی با استفاده از مدل‌های $EAC-ANN$ و $EAC(t)-ANN$

در این تحقیق، EAC و $EAC(t)$ به ترتیب به وسیله جمع درصد هزینه واقعی و تخمین درصد هزینه مورد نیاز برای تکمیل (ETC_p) و جمع درصد زمان واقعی و تخمین درصد زمان لازم برای اتمام پروژه ($ETC(t)_p$) محاسبه می‌شوند. در این قسمت، برای محاسبه EAC از کارهای قبلی که چنگ و همکاران [۷] برای پیش‌بینی هزینه پروژه‌ها انجام داده‌اند کمک گرفته‌ایم. این محاسبات در زیر نشان داده شده است:

$$EAC_p = AC_p + ETC_p \quad \text{رابطه ۱}$$

$$EAC(t)_p = AD_p + ETC(t)_p \quad \text{رابطه ۲}$$

EAC_p نسبت هزینه پیش‌بینی شده (EAC) به کل هزینه بودجه‌شده (BAC) است که به صورت درصد بیان می‌شود.

AC_p نسبت هزینه واقعی (AC) در لحظه پیش‌بینی به کل هزینه بودجه‌شده (BAC) است که به صورت درصد بیان می‌شود.

ETC_p نسبت تخمین هزینه مورد نیاز برای تکمیل پروژه (ETC) به کل هزینه بودجه‌شده (BAC) است که به صورت درصد بیان می‌شود.

$EAC(t)_P$ نسبت زمان پیش‌بینی شده برای اتمام پروژه $(EAC(t))$ به کل زمان بودجه‌شده (PD) است که به صورت درصد بیان می‌شود.

AD_P نسبت زمان واقعی (AD) در لحظه پیش‌بینی به کل زمان بودجه‌شده (PD) است. $ETC(t)_P$ نسبت تخمین زمان مورد نیاز برای تکمیل پروژه $(EAC(t))$ به کل زمان بودجه‌شده (PD) است.

انواع مختلفی از شبکه‌های عصبی با توجه به اهداف تحقیق می‌توانند مورد استفاده قرار گیرند که یکی از معروف‌ترین آن‌ها، شبکه عصبی چندلایه پیش‌خور $(MFNN^1)$ است. در این تحقیق، از شبکه عصبی چند لایه پیش‌خور استفاده شده است. این نوع شبکه عصبی به دلیل کاربرد گسترده، در بسیاری از مسائل مدیریتی، مانند پیش‌بینی، طبقه‌بندی و مدل‌سازی معتبر و محبوب است.

در این تحقیق، برای تعیین توپولوژی مناسب شبکه‌های عصبی، مدل‌های مختلفی آزمون شده است و با تغییرات تعداد نرون‌های لایه پنهان و تعداد لایه‌ها، مدل اصلی پیش‌بینی انتخاب شد. تعداد لایه‌ها در این تحقیق ۳ لایه و تعداد نرون‌ها در این لایه‌ها به ترتیب ۳، ۲ و ۱ است. برای انتخاب تابع لایه میانی، انواع توابع مانند تابع سیگموئیدی، تانژانت هزلولی سیگموئیدی، لگاریتمی سیگموئیدی، خطی، محدودکننده شدید و ... استفاده و عملکرد شبکه ارزیابی شد. بهترین تابع بررسی شده برای لایه میانی، تابع تانژانت هزلولی سیگموئیدی^۲ است که تحقیقات مشابه نیز این مطلب را تأیید می‌کنند [۲۲]. تابع فعال‌سازی (جمع‌کننده) نیز تابع خطی در نظر گرفته شده است.

الگوریتم یادگیری استفاده شده در این تحقیق، الگوریتم پس‌انتشار خطا است و برای یادگیری سریع‌تر، از الگوریتم پس‌انتشار ارتجاعی (RPB^3) استفاده شده است. تعداد تکرارها ۲۵۰۰ است. معیار توقف الگوریتم زمانی است که بعد از محاسبات در چندین تکرار، تطابق $(Fitness)$ مناسبی برای مدل حاصل شود و به همگرایی در جواب برسیم. برای ارزیابی عملکرد مدل، از میانگین مجذور خطا (MSE) ، مربع میانگین مجذور خطا $(RMSE)$ و میانگین قدر مطلق خطا (MAE) استفاده می‌شود.

۴. تحلیل داده‌های و یافته‌های پژوهش

هدف این بخش اثبات صحیح‌تر و منطقی‌تر بودن نتایج پیش‌بینی حاصل از شبکه‌های عصبی نسبت به روش‌های سنتی، در پروژه‌های ساخت‌وساز است. در این تحقیق، از شش روش

1. Multilayered Feed forward Neural Network
2. Hyperbolic Tangent Sigmoid Function
3. Resilient Back Propagation

برای پیش‌بینی هزینه و زمان پایانی پروژه‌ها استفاده شده است که شامل یک روش رگرسیون چندگانه، سه روش مدیریت ارزش کسب‌شده (روش‌های سنتی) و دو روش مربوط به شبکه‌های عصبی است. خلاصه مقایسه نتایج برای مجموعه داده‌های آزمایش در جدول ۵ و ۶ نشان داده شده است:

جدول ۵. مقایسه خطای بین روش‌های سنتی و شبکه عصبی در پیش‌بینی هزینه

| ررر | MSE% | RMSE% | MAE% |
|-------------------------|------|-------|------|
| . EAC-MRA | . / | . / | . / |
| . EAC-EVM 1 | . / | . / | . / |
| . EAC-EVM 2 | . / | . / | . / |
| . EAC-EVM 3 | . / | . / | . / |
| . EAC-ANN _F | . / | . / | . / |
| . EAC-ANN _{UF} | . / | . / | . / |

جدول ۶. مقایسه خطای بین روش‌های سنتی و شبکه عصبی در پیش‌بینی زمان

| ررر | MSE% | RMSE% | MAE% |
|----------------------------|------|-------|------|
| . EAC(t)-MRA | . / | . / | . / |
| . EAC(t)-EVM 1 | . / | . / | . / |
| . EAC(t)-EVM 2 | . / | . / | . / |
| . EAC(t)-EVM 3 | . / | . / | . / |
| . EAC(t)-ANN _F | . / | . / | . / |
| . EAC(t)-ANN _{UF} | . / | . / | . / |

. همان‌طور که در جداول مربوط به نتایج آزمایش پروژه‌های C و H مشخص است، دو مدل شبکه عصبی عملکرد بهتری نسبت به تکنیک ارزش کسب‌شده و رگرسیون چندگانه در پیش‌بینی هزینه و زمان نهایی دارند. از بین دو مدل شبکه عصبی که برای پیش‌بینی هزینه و زمان نهایی این پروژه‌ها به کار رفته است، عملکرد مدل اول به مراتب بهتر از مدل دوم است. این نشان می‌دهد که با اضافه کردن متغیرهای محیطی به متغیرهای ارزش کسب‌شده می‌توان با دقت بیشتری نتایج پایانی پروژه‌ها را پیش‌بینی کرد.

با در نظر گرفتن ۵ درصد حد قابل قبول خطا (MSE%)، با توجه به جدول ۵ و ۶ در بین روش‌های مدیریت ارزش کسب‌شده و رگرسیون چندگانه، تنها روش EAC-EVM 2 در پیش‌بینی هزینه نهایی پروژه‌های C و H و EAC(t)-EVM 1 نیز در پیش‌بینی زمان نهایی پروژه‌های C و H توانسته‌اند به ترتیب با مقادیر ۴/۴۷ و ۱/۱۶ درصد، کمتر از این مقدار قرار گیرند و بقیه در بالای این مقدار قرار می‌گیرند. به‌طور کلی، نتایج حاصل از این تکنیک عملکرد ضعیف و ناپایداری دارد.

چنانکه گفتیم، در این تحقیق از دو نوع مجموعه داده‌ها (ورودی‌ها) استفاده شده است که مجموعه داده‌های مدیریت ارزش کسب‌شده و مجموعه داده‌های ترکیبی (داده‌های ارزش کسب‌شده به همراه داده‌های محیطی) نامیده می‌شوند. با اضافه کردن مجموعه ورودی‌های تورم،

وضعیت پرداخت و شرایط جوی به داده‌های ارزش کسب‌شده، نتایج پیش‌بینی متفاوتی به‌دست می‌آید. در مدل اول، از شش فاکتور ارزش کسب‌شده در کنار سه فاکتور محیطی استفاده شده است. خطای این دو مدل در پیش‌بینی هزینه و زمان نهایی کمتر از ۵ درصد است. به‌طور خلاصه، نتایج نشان می‌دهند که مدل‌های پیشنهادی می‌توانند پیش‌بینی صحیح‌تر و پایدارتری را ارائه دهند.

خطای مربوط به پیش‌بینی هزینه و زمان اتمام هر دو مدل شبکه‌های عصبی برای مجموعه داده‌های آموزش و یادگیری نیز در جدول ۷ نشان داده شده است. همان‌طور که در این جدول آمده است، میانگین مجذور خطای (MSE) مدل ANP_F در پیش‌بینی هزینه و زمان کمتر از خطای مدل ANP_{UF} در هر دو مجموعه داده‌ها است:

جدول ۷. مقایسه نتایج برای ANP_{UF} و ANP_F

| خطای پیش‌بینی هزینه | | خطای پیش‌بینی زمان | | |
|---------------------|---------|--------------------|---------|--------------|
| ANP_{UF} | ANP_F | ANP_{UF} | ANP_F | |
| ۰/۱۱۱۲ | ۰/۰۲۳۷ | ۰/۰۳۴ | ۰/۰۶۰۶ | خطای یادگیری |
| ۰/۱۵۴۲ | ۰/۰۵۱۲ | ۰/۰۶۱۳ | ۰/۱۴۱ | خطای آزمایش |
| ۰/۱۴۱۶ | ۰/۰۲۳۷ | ۰/۰۴۷۲ | ۰/۰۵۸۴ | مورد C |
| | | | | مورد H |

۵. نتیجه‌گیری و پیشنهادها

نتایج به‌دست آمده از روش‌های EAC-ANN و EAC-EVM نشان می‌دهند که هیچ روشی در مدیریت ارزش کسب‌شده وجود ندارد که خطای کمتری را در پیش‌بینی هزینه و زمان نهایی پروژه‌ها نسبت به شبکه‌های عصبی داشته باشد. به‌طور خلاصه، نتایج نشان می‌دهند که مدل پیشنهادی می‌تواند نتایج پیش‌بینی صحیح‌تر و پایدارتری را ارائه دهد. با توجه به عملکرد بهتر شبکه‌های عصبی نسبت به تکنیک ارزش کسب‌شده، نتیجه می‌گیریم که شبکه‌های عصبی به‌دلیل توانایی در حل مسائل پیچیده و بدساختار و استفاده از داده‌های چندین پروژه، می‌توانند به مدیران برای تصمیم‌گیری‌های صحیح‌تر کمک کنند. دلیل اینکه شبکه عصبی با داده‌های ترکیبی می‌تواند به‌شکل بهتری ویژگی سری زمانی را تشریح کند این است که پروژه‌هایی که برای آزمایش انتخاب شده‌اند در شرایط تورمی تکمیل شده‌اند. شرایط جوی و نحوه پرداخت پیمانکاران نیز از متغیرهایی هستند که توانسته‌اند در بهبود نتایج پیش‌بینی مؤثر باشند. این فاکتورها به تعدیل خطای پیش‌بینی هزینه و زمان نهایی پروژه‌ها کمک می‌کنند.

در تحقیقات آتی، برای پیش‌بینی هزینه و زمان اتمام پروژه‌ها می‌توان از تکنیک‌های دیگری مثل علت‌یابی مبتنی بر مورد (CBR)، شبکه‌های عصبی فازی (FANN)، ماشین بردار پشتیبان (SVM) و ... استفاده کرد و سپس به مقایسه این روش‌ها با تکنیک مدیریت ارزش کسب‌شده

پرداخت. تعیین توپولوژی بهینه شبکه عصبی، با استفاده از الگوریتم ژنتیک در پیش‌بینی هزینه و زمان نهایی پروژه‌ها نیز موضوع مناسبی برای بررسی است.



منابع

1. Adeli, H., & Wu, M. (1998). Regularization neural network for construction cost estimation. *Journal of Construction Engineering and Management*, 124(1), 18° 24.
2. Alexander, S. (2002). *Earned Value Management Systems (EVMS): Basic Concepts*. Project Management Institute, Washington DC.
3. Attalla, M., & Hegazy, T. (2003). Prediction cost deviation in reconstruction project: Artificial neural networks versus regression. *Journal of Construction Engineering and Management*, ASCE, 129(4), 405° 411.
4. Bao, Y.K., Liy, Z.T., Guo, L., & Wang, W. (2005). Forecasting composite index by fuzzy support vector machines regression. In: *Proceedings of Fourth International Conference on Machine Learning and Cybernetic, Guangzhou*, pp. 3535° 3540.
5. Bowen, P.A., & Edwards, P.J. (1985). Cost modeling and price forecasting; practice and theory in perspective. *Construction Management and Economics*, 3, 199° 215.
6. Boussabaine, A. H., & Elhag, T. M. S. (1997). A neurofuzzy model for predicting cost and duration of construction projects. *RICS Research (9 p.)*. The Royal Institution of Chartered Surveyors.
7. Cheng, M.Y, Hoang, N.D, Roy, A.F.V, & Wu, Y.W. (2012). A novel time depended evolutionary fuzzy SVM inference model for estimating construction project at completion. *Engineering Applications of Artificial Intelligence*, 25, 744° 752
8. Cheng, M.Y., & Roy, A.F.V. (2011). Evolutionary fuzzy decision model for cash flow prediction using time-dependent support vector machines. *International Journal of Project Management*, 29 (1), 56° 65.
9. Chou, J. (2009). Web-based CBR system applied to early cost budgeting for pavement maintenance project. *Expert Systems with Applications*, 36, 2947° 2960.
10. Christensen, D.S., Antolini, R.C., & McKinney, J.W. (1995). A review of estimate at completion research. *J. Cost Anal. Manage.*, 41° 62.
11. Gowan, J.A., Mathieu, R.G., & hey, M. B. (2006). Earned value management in a data warehouse project. *International Management and Computer Security*, 14, 37° 50.
12. Hegazy, T., & Ayed, A. (1998). Neural network model for parametric cost estimation of highway projects. *Journal of Construction Engineering and Management*, 124(3), 210° 218.
13. Jin, R.Z, Cho, K.M, Hyun, C.T, & Son, M.J. (2012). MRA-based revised CBR model for cost prediction in the early stage of construction projects. *Expert Systems with Applications*, 39, 5214° 5222.
14. Khosrowshahi, F., & Kaka, A.P. (1996). Estimation of project total cost and duration for housing projects in the UK. *Building and Environment*, 31 (4), 373° 383.
15. Kim, G., Seo, D., & Kang, K. (2005). Hybrid models of neural networks and genetic algorithms for predicting preliminary cost estimates. *Journal of Computing in Civil Engineering, ASCE*, 19(2), 208° 211.

16. Kim, G., An, S., & Kang, K. (2004). Comparison of construction cost estimating models based on regression analysis, neural networks, and case-based reasoning. *Building and Environment*, 39(10), 1235° 1242.
17. Lowe, D.J., Emsley, M.W., & Harding, A. (2006). Predicting construction cost using multiple regression techniques. *ASCE Journal of Construction Engineering and Management*, 132, 750° 758.
18. Nassar, K. M., Gunnarsson, H. G., & Hegab, M. Y. (2005). Using weibull analysis for evaluation of cost and schedule performance. *Journal of Construction Engineering and Management*, ASCE, 131(12), 1257° 1262.
19. Phaobunjong, K. (2002). Parametric Cost Estimating Model for Conceptual Cost Estimating of Building Construction Projects. *PhD Thesis, University of Texas, Austin, Tex.*
20. Rao, G. N., Grobler, F., & Kim, S. (1993). Conceptual cost estimating: A hybrid neural expert system approach. *Computing in Civil and Building Engineering*, 423° 430.
21. Singh, S., (1990). Cost model for reinforced concrete beam and slab structures in building. *Journal of Construction Engineering and Management*, 116 (1), 54° 67.
22. Smith K. A., & Gupta J. N. D. (2002). Neural network in business: Techniques and application. *Idea Group Publishing.*
23. Sonmez, R. (2004). Conceptual cost estimation of building projects with regression analysis and neural networks. *Canadian Journal of Civil Engineering*, 31, 677° 683.
24. Stephenson, H.L. (2004). Identifying risks and opportunities using EAC. *Proc. 48th AACE International Annual Meeting '04, AACE International Transactions*, pp. CSC.06.1° CSC.06.9.
25. Sonmez, R. (2011). Range estimation of construction costs using neural networks with bootstrap prediction intervals. *Expert Systems with Applications*, 38, 9913° 9917.
26. Trost, S. M., & Oberlender, G. D. (2003). Prediction accuracy of early cost estimates using factor analysis and multivariate regression. *Journal of Construction Engineering and Management*, ASCE, 129(2), 198° 204.
27. Vandevoorde, S., & Vanhoucke, M. (2005). A comparison of different project duration forecasting methods using earned value metrics. *International Journal of Project Management*, 24 (4), 289° 302.
28. Wilmot, C. G., & Mei, B. (2005). Neural network modeling of highway construction costs. *Journal of Construction Engineering and Management*, 124(3), 210° 218.
29. Williams, T. P. (1994). Predicting changes in construction cost indexes using neural networks. *Journal of Construction Engineering and Management*, 120(2), 306° 320.
30. Wang, Y. R., Yu, C. Y., Chan, H. H. (2011). Predicting construction cost and schedule success using artificial neural networks ensemble and support vector machines classification models. *International Journal of Project Management*, 25, 744° 752.
31. Yau, N. J., & Yang, J. B. (1998). Case-based reasoning in construction management. *Computer-Aided Civil and Infrastructure Engineering*, 13(2), 143° 150.