

## التنبؤ بزمن الانتهاء المتوقع لمشاريع الأبنية السورية باستخدام إدارة القيمة المكتسبة والذكاء الصناعي

د. سماح مكيه\*

(تاريخ الإيداع 11 / 11 / 2020. قُبل للنشر في 12 / 4 / 2021)

### □ ملخص □

يعتبر عامل الزمن من العوامل الهامة المؤثرة في المشاريع الانشائية ويحتاج لتقنيات فعالة لإدارته، وكثيراً ما تستغرق الأنشطة خلال مرحلة التنفيذ مدداً أطول من المدد المتوقعة لها أو ربما تفشل وتتوقف المشاريع دون إنهاؤها. يعتبر منهجية إدارة القيمة المكتسبة (EVM) أداة تساعد في إيجاد حل لهذه الظاهرة؛ إذ أنها تتفوق في مجال تحليل وتقييم الأداء الزمني الحالي للمشروع الا أن دقتها في مجال التنبؤ بزمن الانتهاء المتوقع للمشروع غير كافية، لذا يهدف هذا البحث الى تحسين أداء الـ EVM في التنبؤ بزمن انتهاء مشاريع الأبنية باستخدام الشبكات العصبية الاصطناعية. تم اختيار مشروع اكاملات كلية التربية ومشروع اكاملات كلية طب الأسنان في جامعة تشرين في اللاذقية كحالة دراسية، وتم تحديد مدخلات الشبكة استناداً إلى كل من: قيم مؤشرات الأداء والمدة المخططة للمشروع ومتغيرات التباين الزمني والمدة المكتسبة والجدولة المكتسبة.

أوضحت نتائج تدريب الشبكة على عدة تصاميم معمارية ومن ثم اختيار التصميم الموافق للخطأ الأصغري كأفضل هيكلية في التنبؤ أن الهيكلية المكونة من 8 عقد في طبقة الدخل و 6 عقد في الطبقة الخفية وعقدة الخرج واحدة تمثل الشبكة المثلى للتنبؤ بزمن الانتهاء المتوقع للمشروع. وأخيراً تم اختبار الشبكة المثلى على عينات لم تتدرب عليها مسبقاً، وأثبتت نتائج الاختبار دقة الشبكات العصبية في التنبؤ.

**الكلمات المفتاحية:** إدارة القيمة المكتسبة، التنبؤ بالزمن، مشاريع الأبنية، الشبكات العصبية الاصطناعية.

\*مدرسة \_ قسم هندسة وإدارة التشييد \_ كلية الهندسة المدنية \_ جامعة تشرين \_ اللاذقية \_ سورية.

## Forecasting the Estimate Completion Time of Syrian Building Projects Using Earned Value Management and Artificial Intelligence

Dr. Samah MakKieh\*

(Received 11 / 11 / 2020. Accepted 12 / 4 / 2021)

### □ ABSTRACT □

The time factor is one of the most important factors affecting on construction projects, and it needs effective techniques to manage it. The activities during the implementation phase take longer than the expected periods, Projects may fail and stop without being completed. The localization of the EVM methodology is a solution to this phenomenon; As it excels in the field of analyzing and evaluating the current time performance of the project, but its accuracy in forecasting the Estimate completion time of the project is insufficient, so this research aims to improve the performance of the EVM in forecasting the completion time of building projects using artificial neural networks.

The Education College and The Dentistry College at Tishreen University in Lattakia were selected as a case study. The network's inputs were determined based on: the values of performance indicators, the Project's Planned duration, the time variance, the Earned duration and the Earned schedule variables.

The network was trained in several structural designs and the design corresponding to the lowest error was chosen as the best structure.

The training results indicated that the structure (8.6.1) represents the optimal network for forecasting the estimate completion time for the project. Finally, the optimum network was tested on fifteen samples that had not been previously trained. The test results proved the accuracy of the neural networks in forecasting.

**Keywords:** Earned value management, time forecasting, building projects, ANN.

---

\* Assistant Professor, Construction Engineering And Management Department, Faculty of civil Engineering, Tishreen University, Lattakia, Syria. [S.makkieh@tishreen.edu.sy](mailto:S.makkieh@tishreen.edu.sy).

## مقدمة:

يحتاج نجاح أي مشروع انشائي إلى تحقيق التكامل ما بين المراحل التي يمر بها ابتداء من مرحلة التخطيط إلى مرحلة التنفيذ ومن ثم مرحلة المراقبة والتحكم التي تتزامن مع كل مرحلة من تلك المراحل وصولاً إلى مرحلة الانتهاء الأخيرة للمشروع، ويعتبر عامل الزمن من العوامل الهامة المتكاملة في المشروع ويحتاج لتقنيات فعالة لإدارته. إلا أنه من الملاحظ استغراق الأنشطة مدداً زمنية ضمن مرحلة التنفيذ أطول من المدد المتوقعة لإنهائها أو ربما تفشل وتتوقف المشاريع دون إنهائها، لذا تحتاج صناعة البناء في سوريا خلال مرحلة إعادة الإعمار التي نشهد فيها أزمة مالية كبيرة وحاجة ملحة للإنشاء السريع إلى وضع استراتيجيات وبرامج متكاملة تتحقق ضمن إطار زمني محدد.

جميع ما سبق يجعل عملية توطين أحدث المنهجيات الناجحة في المتابعة أمراً ملزماً، وتعتبر منهجية إدارة القيمة المكتسبة ((Earned Value Management (EVM)) من أهمها كونها تشكل نظاماً للتغذية الراجعة عند مقارنة الواقع الفعلي مع المخطط مسبقاً عبر مجموعة من البارامترات كما تشكل نظاماً للإدارة الاستباقية عند توظيف هذه البارامترات للتنبؤ بزمن انتهاء المشروع [Saeed,A,L ; Farhan,K,S,2014].

ووفقاً لهذه الأهمية ازداد استخدام منهجية الـ EVM مؤخراً في قطاع التشييد ونفذت العديد من الأبحاث من أجل التنبؤ بزمن انتهاء المشروع. فقد بحث [Buyse,P. and Vandenbussche,T,2010] عن التأثير التي تضيفه منهجية الـ EVM على تنفيذ عدة مشاريع مختارة من خلال اختبار مجموعة من الفرضيات المتعلقة بكل من استقرار المؤشرات ((CPI, SPI, SPI(t)) وطرق التنبؤ بالزمن وإعادة الجدولة وتأثير خصائص المشروع على دقة التنبؤات وتوصل إلى استقرار مؤشر الـ ((SPI, SPI(t)) بعد انجاز 20% من المشروع ووجد أن إعادة الجدولة مفيدة جداً في المشاريع التي يصعب فيها تحديد الطريقة المناسبة للتنبؤ وأن طول المشروع له تأثير إيجابي على استقرار مؤشر الـ CPI. أما [Azimi,F. and Najafi,A,2016] فقد اقترح طريقتين لتحسين دقة نتائج تحليل الجدول الزمني واختبرهما على مثال مؤلف من سبعة أنشطة؛ تقوم الطريقة التقريبية البسيطة التي اقترحها بحساب وتحليل مؤشرات الـ ((Schedule Variance (SV),SPI)) للمسار الحرج بالإضافة إلى مؤشرات الـ ((SV,SPI)) للمشروع الإجمالي في حين تستخدم الطريقة الدقيقة التي اقترحها الـ ((PV,EV)) والزمن العائم لتحليل الجدول الزمني، استطاع الباحث من خلال الطريقة التقريبية تقليل الأخطاء في تقدير تباين الجدول الزمني وتوصل من خلال الطريقة الدقيقة إلى تقديرات أكثر دقة لتباين الجدول الزمني. أثبت الباحث صحة الطريقتين على مثال بسيط مؤلف من عدة أنشطة مع كون العلاقات بين الأنشطة من نوع نهاية بداية (FS) بينما المشروع في طبيعته أعقد من ذلك.

وقد أدخل [Ghanbari,A. Taghizageh,H. and Iranzadeh,S,2017] نهجاً جديداً على منهجية إدارة المدة المكتسبة ((Earned Duration Management(EDM))، استخدم فيه التعابير اللغوية لوصف تقدم الأنشطة بدلاً من تقييمها بشكل حاسم في الحالات التي يكون فيها مقدار العمل المطلوب لأداء الأنشطة غير مؤكد وخارج نطاق السيطرة، ثم قام بتطوير مؤشر أداء المدة ((Duration performance index(DPI)) ومؤشر المدة المكتسبة ((Earned duration index (EDI)) المرتبطين بتقنية الـ EDM إلى مؤشرات أداء يمكنها قياس أداء المدة في ظل عدم اليقين، واختار الباحث تابعاً لتقييم الأداء الزمني لأنشطة المشروع في ظل عدم اليقين، ثم اختبر النهج المقترح على مشروع بسيط، وأوضحت النتائج نجاح هذه المنهجية لكن غالباً ما تتغير نتائج البحث مع تغير التابع المختار لذا تحتاج مثل هذه الأبحاث إلى إمام دقيق بالمسألة المطروحة.

وهكذا فإنه من الملاحظ تفوق منهجية الـ EVM على الأساليب التقليدية في مجال تحليل وتقييم الأداء الزمني الحالي إلا أن دقتها في مجال التنبؤ بزمن انتهاء المشروع ضعيفة لعدم وجود معادلة واحدة لـ  $EAC(t)$  تعطي تنبؤات مرحلية دقيقة باستمرار حيث تختلف الدقة المرحلية بين هذه المعادلات باختلاف ملامح المشروع وخصوصاً في المراحل المبكرة منه. ومن هنا نبعت مشكلة البحث إذ لا بد من تحسين الأداء التنبؤي للـ EVM واستجابة لذلك يمكن توظيف أحد تقنيات الذكاء الصناعي المعروفة عالمياً في دقة تنبؤها وسرعتها لبلوغ الهدف وهي الشبكات العصبية الاصطناعية (Artificial Neural Network (ANN)).

### أهمية البحث وأهدافه:

تتجلى أهمية البحث في الحاجة الماسة إلى تشييد المشاريع السورية خلال مرحلة إعادة الاعمار ضمن قيود زمنية محددة ودعم الدراسات السابقة النادرة التي ناقشت تطبيق نظام الـ EVM على صناعة التشييد ضمن الواقع السوري، خاصة أن هذا البحث يسلط الضوء على التوقع المستقبلي بزمن انتهاء المشروع والسيطرة على المخاطر المحتملة. يهدف هذا البحث إلى تحسين أداء الـ EVM في التنبؤ بزمن انتهاء مشاريع الأبنية السورية عبر تحقيق الأهداف الفرعية التالية:

1. تحليل وتقييم مؤشر الأداء الزمني ( $SPI, SPI(t)$ ) لمشاريع الأبنية السورية استناداً على البارامترات الأساسية الثلاث (PV, EV, AC) القائمة عليها منهجية الـ EVM.
2. التنبؤ بزمن انتهاء المشروع  $EAC(t)$  على طول مرحلة تنفيذ المشروع اعتماداً على معادلات الـ EVM.
3. التنبؤ بزمن انتهاء المشروع  $EAC(t)$  على طول مرحلة تنفيذ المشروع باستخدام شبكة عصبية اصطناعية تعتمد بارامترات ومؤشرات الـ EVM كمدخلات لها.
4. المقارنة بين نتائج منهجية الـ EVM ونتائج الشبكة العصبية في التنبؤ بزمن انتهاء المشروع.

### طرائق البحث ومواده:

#### منهجية إدارة القيمة المكتسبة.

تعتبر إدارة القيمة المكتسبة أحد أنجح التقنيات المتبعة في مراقبة تقدم العمل بالمشروع والتحكم فيه، إذ أنها تعتمد على قيمة العمل المنجز (EV) لإعطاء دلالات دقيقة عن الحالة الزمنية للمشروع وذلك من خلال دراسة وتقييم مؤشرات متعلقة بالزمن ومعرفة الانحرافات الحاصلة عن الخطة الأساسية الموضوعية قبل التنفيذ ليتم تحديد المشاكل المستقبلية المتوقعة واتخاذ الخطوات التصحيحية في الوقت المناسب [Fleming, Q, W and Koppelman, J, M, 2000].

يعرف معهد إدارة المشاريع (PMI) إدارة القيمة المكتسبة بأنها المنهجية التي تربط بين نطاق المشروع وجدوله الزمني وتكاليفه لتقييم أداء المشروع وتقديمه [Project Management Institute, 2008]. وتعتبر الجدولة المكتسبة (ES) امتداداً لنظرية الـ (EVM) لاستخدامها الوحدات الزمنية بدلاً من الوحدات النقدية أثناء قياس وتقييم الأداء الزمني الحالي للمشروع والتنبؤ بزمن انتهاء الأعمال المتضمنة فيه [Lipke, W. 2013].

## البارامترات الرئيسية الثلاث القائمة عليها منهجية القيمة المكتسبة:

تعتمد منهجية ادارة القيمة المكتسبة على ثلاث متغيرات أساسية يتم قياسها أثناء تخطيط ومراقبة تقدم سير العمل في المشروع [Shaban,M.H, 2012] وهي.

1. Planned Value (PV): القيمة حسب الميزانية للعمل المنجز أو القيمة المخططة ويتم حسابها بشكل تراكمي حتى نقطة معينة من الزمن أو تاريخ التقرير وفق المعادلة التالية:

القيمة المخططة = الميزانية التخطيطية عند الانتهاء \* نسبة الانجاز التخطيطية

$$BCWS = PV = PC(planned) * BAC$$

2. Earned Value (EV): القيمة الفعلية للعمل المنجز أو القيمة المكتسبة حتى تاريخ التقرير وتعتمد على الموازنة المرصودة للعمل المنجز وعلى تقارير تقدم سير العمل ونسب الانجاز المحسوبة وتحسب هذه القيمة كما يلي:

القيمة المكتسبة = الميزانية التخطيطية عند الانتهاء \* نسبة الانجاز الفعلية

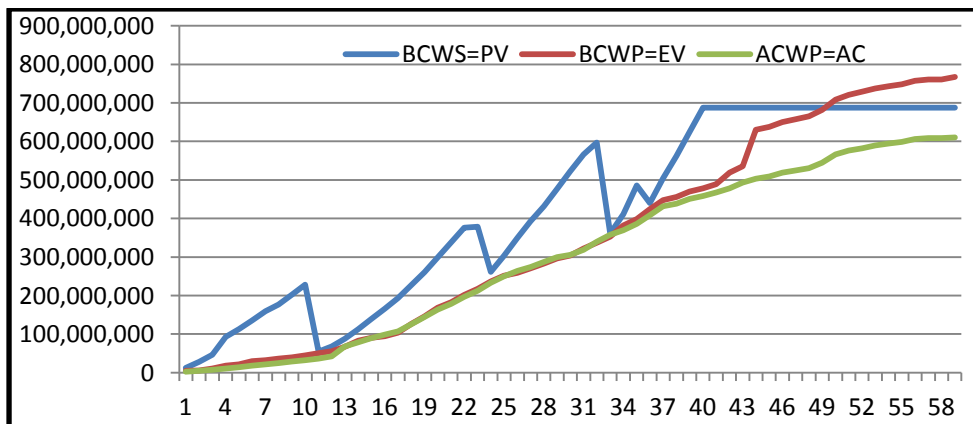
$$BCWP = EV = PC(actual) * BAC$$

3. Actual Cost (AC): القيمة الفعلية للعمل المنجز وهي قيمة ما تم صرفه على العمل الفعلي الذي تم انجازه ويتم تحديد هذه القيمة بجمع الميزانيات الفعلية المصروفة للأعمال المنجزة حتى تاريخ التقرير.

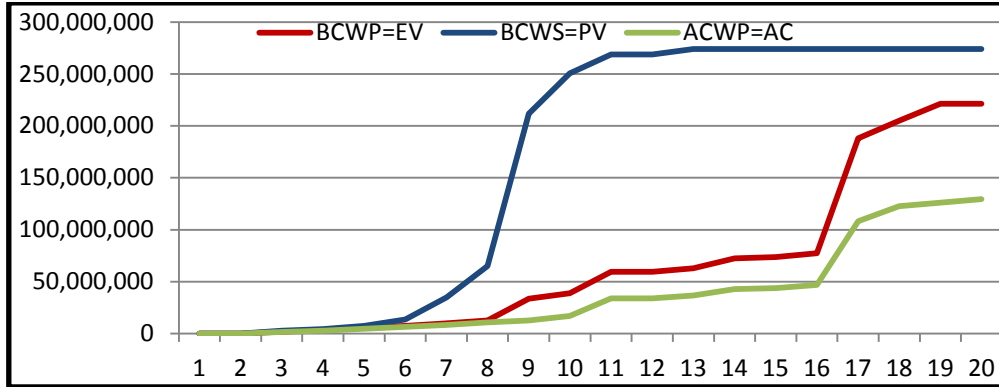
## جمع بيانات عن مشروع حالة دراسية:

تم اختيار مشروع اكاملات كلية التربية ومشروع اكاملات كلية طب الأسنان في جامعة تشرين في اللاذقية كحالة دراسية في هذا البحث. وقد تم تنفيذ هذين المشروعين من قبل الشركة العامة للبناء والتعمير، حيث كانت المدة الزمنية اللازمة لمشروع اكاملات كلية التربية تبعاً للعقد الأساسي وملاحقه محددة بـ 40 شهراً أما التكلفة الاجمالية لعقد التنفيذ مع الملاحق ومع التكاليف مقدرة بـ 767 مليون ليرة سورية، في حين كانت المدة الزمنية اللازمة لمشروع اكاملات كلية طب الأسنان وملاحقه محددة بـ 19 شهراً أما التكلفة الاجمالية لعقد التنفيذ مع الملاحق ومع التكاليف مقدرة بـ 350 مليون ليرة سورية.

تم استخلاص البارامترات الأساسية الثلاث (PV, EV, AC) لمنهجية الـ EVM من التقارير الشهرية للمشاريع والمتوفرة لدى الجهة المالكة جامعة تشرين والبالغ عددها 59 تقريراً لمشروع اكاملات كلية التربية و 94 تقريراً لمشروع اكاملات كلية طب الأسنان وبين الشكل (1) و (2) هذه القيم على طول مرحلة تنفيذ المشروع.



الشكل (1) قيم (PV, EV, AC) طوال فترة تنفيذ المشروع (حالة دراسية / مشروع كلية التربية).



الشكل (2) قيم (PV, EV, AC) أثناء فترة تنفيذ المشروع (حالة دراسية / مشروع كلية طب الأسنان).


إن القفزات الكبيرة المتواجدة على منحنى الـ PV في الشكل (1) تعود لتوفر عدة برامج زمنية خلال مراحل تنفيذ المشروع كما نستنتج من الشكل (2) التقدم المنخفض في نسب الإنجاز وهذا ما يفسر تباعد منحنى الـ EV من منحنى PV وغياب البرنامج الزمني خلال المراحل المتوسطة والأخيرة من المشروع.

#### تحليل وتقييم الأداء الزمني طوال فترة تنفيذ المشروع:

تم تحليل وتقييم الأداء الزمني للمشروع من خلال حساب قيم المؤشران:


$$SPI = \frac{EV}{PV} \quad . \quad SPI(t) = \frac{ES}{AT}$$

تم استخدام الطريقة العملية لإيجاد قيمة الـ ES كما هو كوضح في الشكل (3) عن طريق إسقاط قيمة الـ EV الموافقة لنقطة زمنية معينة (AT) على منحنى الـ PV التراكمي ليتم الحصول على النقطة الزمنية (ES) التي ينبغي أن يكون عندها قد تم اكتساب قيمة الـ EV الحالي بالفعل.




الشكل (3): الطريقة العملية في تحديد قيمة الجدولة المكتسبة (ES) (LIPKE, 2003).

يبين الشكل (4) والشكل (5) المنحني البياني لمؤشرات الأداء ((SPI, SPI(t)) المحسوبة لمشروع اكملات كلية التربية ومشروع اكملات كلية طب الأسنان على التوالي.



الشكل (4): المنحني البياني لمؤشرا الأداء الزمني (SPI,SPI(t)) طوال فترة تنفيذ مشروع اكملات كلية التربية.



الشكل (5): المنحني البياني لمؤشرا الأداء الزمني (SPI,SPI(t)) طوال فترة تنفيذ مشروع اكملات كلية طب الأسنان.

نلاحظ من الشكل (4) وجود قفزات في مؤشر الأداء الزمني لوجود عدة برامج زمنية أما من الشكل (5) فنلاحظ أنّ تقدم سير العمل المنخفض وغياب البرنامج الزمني خلال مراحل معينة من التنفيذ أثرت سلباً على استقرار مؤشر الأداء الزمني.

#### معادلات القيمة المكتسبة في التنبؤ بزمن انتهاء المشروع.

تضم منهجية الـ EVM ثلاث طرق أساسية للتنبؤ بزمن انتهاء المشروع ولكل طريقة ثلاث معادلات مختلفة. يبين

الجدول (1) الطرق الأساسية الثلاث ومعادلاتها المختلفة في التنبؤ بزمن انتهاء المشروع [Buyse,P. and Vandebussche,2010]

الجدول (1) معادلات EVM الأساسية للتنبؤ بزمن الانتهاء المتوقع. [Buyse,P. & Vandebussche,2010].

Planned value method (Anbari)	Earned duration method (Jacob)	Earned schedule method (Lipke)
$EAC(t)_{PV1} = PD - TV$	$EAC(t)_{ED1} = AD + (PD - ED)$	$EAC(t)_{ES1} = AD + (PD - ES)$
$EAC(t)_{PV2} = \frac{PD}{SPI}$	$EAC(t)_{ED2} = AD + \frac{(PD - ED)}{SPI}$	$EAC(t)_{ES2} = AD + \frac{(PD - ES)}{SPI(t)}$
$EAC(t)_{PV3} = \frac{PD}{CR}$	$EAC(t)_{ED3} = AD + \frac{(PD - ED)}{CR}$	$EAC(t)_{ES3} = AD + \frac{(PD - ES)}{CR}$

تم التنبؤ بزمن الانتهاء المتوقع لمشروع اكملات كلية التربية باستخدام الطرق والمعادلات المبين أعلاه وذلك طوال فترة تنفيذ المشروع وهي 59 شهراً ويبين الجدول (2) عينة من هذه النتائج:

الجدول (2): عينة من نتائج التنبؤ بزمن الانتهاء المتوقع لمشروع اكملات كلية التربية  $EAC(t)$  اعتماداً على المعادلات التسعة المختلفة لمنهجية القيمة المكتسبة (EVM).

month	PV1	PV2	PV3	ED1	ED2	ED3	ES1	ES2	ES3	real EAC
...	...	...	...	...	...	...	...	...	...	...
30	53	68.835	69.146	52.567	68.835	69.011	44.991	47.983	55.914	59
31	54	70.291	69.500	53.359	70.291	69.849	45.591	48.802	56.352	59
32	55	70.855	71.488	53.935	70.855	71.202	46.269	49.745	57.501	59
33	40	40.931	41.485	40.751	40.931	41.039	46.915	50.604	47.432	59
34	42	43.034	41.616	42.397	43.034	42.736	41.090	41.325	41.376	59
35	45	48.764	47.255	46.290	48.764	48.338	42.158	42.628	43.456	59
36	41	41.475	39.943	41.281	41.475	41.273	41.825	42.136	41.817	59
37	43	45.034	43.400	44.136	45.034	44.742	41.172	41.308	41.527	59
38	46	49.336	47.481	47.191	49.336	48.910	41.879	42.081	42.604	59
39	49	53.138	50.957	49.642	53.138	52.557	42.527	42.771	43.493	59
40	52	57.550	55.136	52.198	57.550	56.814	43.406	43.723	44.695	59
41	52	56.216	53.684	52.827	57.621	56.873	44.229	44.600	45.334	59
42	50	52.989	48.836	52.295	55.638	54.569	44.739	45.087	45.344	59
...	...	...	...	...	...	...	...	...	...	...

كما تم التنبؤ بزمن الانتهاء المتوقع لمشروع اكملات كلية طب الأسنان باستخدام الطرق والمعادلات المبين أعلاه وذلك طوال فترة تنفيذ المشروع وهي 94 شهراً ويبين الجدول (3) عينة من هذه النتائج:

الجدول (3): عينة من نتائج التنبؤ بزمن الانتهاء المتوقع لمشروع اكملات كلية طب الأسنان  $EAC(t)$  اعتماداً على المعادلات التسعة المختلفة لمنهجية القيمة المكتسبة (EVM).

AT	PV1	PV2	PV3	ED1	ED2	ED3	ES1	ES2	ES3	real EAC
...	...	...	...	...	...	...	...	...	...	...
5	19.110	26.057	22.148	20.354	26.057	22.898	20.545	27.496	23.121	94
6	19.334	34.712	29.505	21.716	34.712	30.405	20.015	22.869	27.764	94
7	20.365	67.827	57.653	24.039	67.827	58.703	20.626	24.749	48.346	94
8	21.846	97.607	82.966	25.443	97.607	84.166	21.154	26.001	65.438	94
12	28.666	119.979	45.132	29.100	119.979	52.618	24.068	32.891	40.666	94
13	30.481	122.577	53.322	29.985	122.577	60.667	24.882	34.701	46.346	94
16	30.357	85.848	48.662	31.459	85.848	55.593	27.187	38.910	44.652	94
17	30.357	85.848	48.662	32.238	85.848	56.026	28.187	41.341	45.652	94
18	30.448	82.686	47.961	32.864	82.686	55.520	29.073	43.144	45.951	94
19	29.937	71.940	42.513	32.982	71.940	50.285	29.803	44.041	43.172	94
20	29.867	70.663	42.030	34.622	74.382	52.346	30.768	46.161	43.820	94
21	29.672	67.377	40.742	36.078	74.469	53.332	31.669	47.893	43.878	94
...	...	...	...	...	...	...	...	...	...	...



درس [Buyse,P. and Vandebussche,2010] فرضية اختلاف دقة التنبؤ بين المعادلات التسعة ، حيث أعطى ترتيباً لدقة تنبؤ المعادلات التسعة في كل مشروع تراوح من 1 إلى 9 (1 لأفضل طريقة في التنبؤ و 9 لأسوأ طريقة في التنبؤ) وأخذ المتوسط الحسابي لدقة تنبؤ كل معادلة وتوصل الى أن المعادلة  $EAC(t)_{ED1}$  أدق معادلة في التنبؤ بزمن الانتهاء المتوقع من أجل المشاريع الثلاثة (Fluxys, JDN, Strabag) التي درسها في إيرلندا. وعند استخدام المنهجية السابقة في هذه الدراسة تبين أن المعادلة  $EAC(t)_{ED2}$  هي المعادلة الأدق في التنبؤ بزمن الانتهاء المتوقع لمشروع إكمالات كلية التربية ومشروع إكمالات كلية طب الأسنان كما هو موضح في الجدولين (4) و(5) على التوالي.

الجدول (4): ترتيب دقة المعادلات التسعة في التنبؤ (حالة دراسية/ مشروع كلية التربية).

Cost forecasting formulas	$EAC(t)_{PV1}$	$EAC(t)_{PV2}$	$EAC(t)_{PV3}$	$EAC(t)_{ED1}$	$EAC(t)_{ED2}$	$EAC(t)_{ED3}$	$EAC(t)_{ES1}$	$EAC(t)_{ES2}$	$EAC(t)_{ES3}$
Average rank	5.14	4.61	5.04	3.83	3.73	4.02	6.02	4.67	4.04

أفضل معادلة في التنبؤ بزمن الانتهاء المتوقع للمشروع

الجدول (5): ترتيب دقة المعادلات التسعة في التنبؤ (حالة دراسية/ مشروع كلية طب الأسنان).

Cost forecasting formulas	$EAC(t)_{PV1}$	$EAC(t)_{PV2}$	$EAC(t)_{PV3}$	$EAC(t)_{ED1}$	$EAC(t)_{ED2}$	$EAC(t)_{ED3}$	$EAC(t)_{ES1}$	$EAC(t)_{ES2}$	$EAC(t)_{ES3}$
Average rank	7.66	2.5	5	5.55	1.27	2.72	7	3.5	4.5

أفضل معادلة في التنبؤ بزمن الانتهاء المتوقع للمشروع

نلاحظ عدم وجود معادلة واحدة لـ  $EAC(t)$  تعطي تنبؤات مرحلية دقيقة باستمرار حيث تختلف الدقة المرحلية بين هذه المعادلات باختلاف ملامح المشروع (نوع المشروع وحجمه، درجة التعقيد، توفر المواد، تكنولوجيا التنفيذ). وخصوصاً في المراحل المبكرة منه، ومن هذا المنطلق تم الاستعانة بالذكاء الصناعي. يوضح الجدول (6) كيفية حساب دقة التنبؤ.

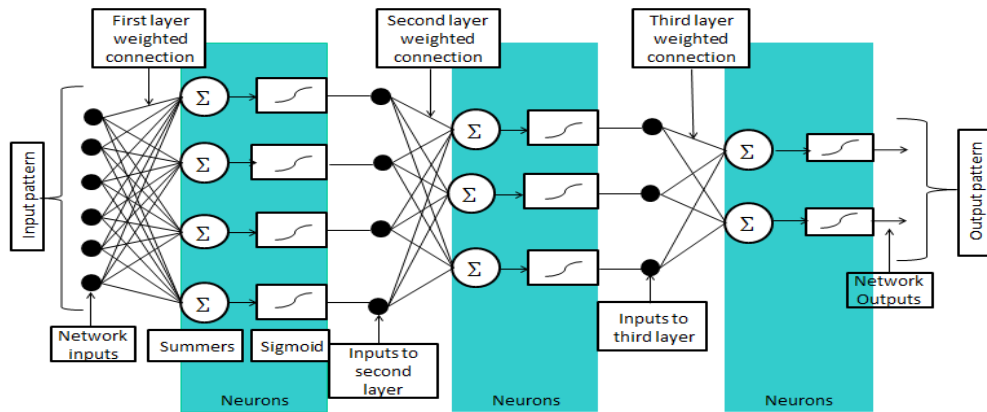
الجدول (6): طريقة حساب دقة التنبؤ.

	condition	Accuracy(%)
A1 Predicted $EAC(t)$	$A1 < A2$	$A1/A2$
A2 Real $EAC(t)$	$A2 < A1$	$A2/A1$

### الشبكات العصبية الاصطناعية:

حققت الشبكات العصبية الاصطناعية في العصر الحديث انتشاراً واسعاً في مختلف المجالات الطبية والهندسية والاقتصادية، إذ أنها تعتمد على آلية التعلم عبر تحليل كميات كبيرة من البيانات التاريخية مكتسبة الخبرة والمعرفة الضروريين في اتخاذ القرارات المستقبلية كما تساعد في حل العديد من المسائل التي تكون العلاقة فيها بين متغيرات الدخل والخرج غير خطية [Waziri,B.and Bustani,S.A,2017]، ما جعلها تتال اهتمام الباحثين للاستفادة من

تطبيقاتها في مجال هندسة البناء وخاصة بعد أن أثبتت قدرتها الكبيرة في التنبؤ بكل من حالة الطقس وتكاليف البناء وتقييم المخاطر وتسوية المنازعات وتوقع الانتاجية وتقدير الجدول الزمني. [Waziri,B.and Bustani,S.A,2017]. تتألف الشبكات العصبية الاصطناعية من وحدات ادخال تشكل طبقة المدخلات ووحدات اخراج تشكل طبقة المخرجات ووحدات معالجة تتوزع على طبقة واحدة أو عدة طبقات مشكلة الطبقات المخفية، تتغير عدد الوحدات وعدد الطبقات من شبكة لأخرى حسب حجم وطبيعة المشكلة المطروحة [ Hagan,M.T; Demuth,H.B; Beale,M.H,1995]. يوضح الشكل (6) هيكلية الشبكة العصبية المتعددة الطبقات [Widrow,B.Greenblatt,A.Kim,Y. and Park,D,2013].



الشكل (6) بنية الشبكة العصبية المتعددة الطبقات. [Widrow,B.Greenblatt,A.Kim,Y. and Park,D,2013].

#### اختيار متغيرات الدخل:

تم الاستناد على قيم الـ EVM الأساسية (PV, EV, AC) لتحليل وتقييم الانحرافات ومؤشرات الأداء الزمنية طوال فترة تنفيذ المشروع، ومن أجل التنبؤ المستمر بزمن انتهاء المشروع تم الاعتماد على كل من: قيم مؤشرات الأداء المحسوبة والمدة المخططة للمشروع ومتغيرات التباين الزمني والمدة المكتسبة والجدولة المكتسبة.

بناء على ما سبق وعلى الدراسة المرجعية [ Hasan,B. Makkieh,S. and Titzian,N. 2020 ] تم تحديد جميع المتغيرات المستخدمة في تشكيل المعادلات التسعة المختلفة كمدخلات للشبكة العصبية التي تنتبأ باستمرار بزمن الانتهاء المتوقع لمشاريع الأبنية السكنية، كي لا يتأثر الخرج الناتج من الشبكة ببارامترات معادلة ما دون الأخرى كالتالي:

1. المدة المخططة (PD).
2. التباين الزمني (TV).
3. مؤشر أداء الجدولة (SPI).
4. مؤشر الأداء الاجمالي للمشروع (CR).
5. المدة الفعلية (AD).
6. المدة المكتسبة (ED).
7. الجدولة المكتسبة (ES).
8. مؤشر أداء الجدولة مقاسا بوحدات زمنية (SPI<sub>(t)</sub>).

**معالجة متغيرات الدخل والخرج:**

غالباً ما تكون متغيرات الشبكة ذو وحدات قياس مختلفة موزعة فيها البيانات على مجالات مختلفة، لذا تحتاج الى معايرة أولية تقلل من انحياز الشبكة نحو المتغيرات ذو وحدات القياس الكبيرة عن طريق منع هيمنتها على المتغيرات ذو وحدات القياس الأصغر. ويتم ذلك عبر ايجاد وحدة قياس موحدة تقوم بتحويل جميع قيم المتغير الى قيم تقع ضمن مجال يتراوح ما بين  $[0,1]$  أو  $[-1,1]$  تساعد في معرفة القيمة الدقيقة لمعدل التعلم التي تسرع زمن التدريب وتتقارب فيها الشبكة نحو الخطأ الأصغري العام [Priddy,K and Keller,P,2005].

يوجد العديد من الأساليب المتبعة لتسوية البيانات أشهرها Min-Max و Z-score و Decimal scaling [Saranya,C. and Manikandan,G,2013].

تم انجاز عملية التسوية في هذا البحث باستخدام طريقة Decimal scaling عن طريق ايجاد القيمة المطلقة العليا للمتغير الواقعة ضمن مجال معين وحساب عدد الأرقام الصحيحة فيه ومن ثم تطبيق المعادلة التالية لتحويل جميع

$$d' = \frac{d}{10^m}$$

الأرقام الى أعداد عشرية. حيث: m هو أكبر عدد للأرقام الصحيحة بحيث  $\max|d'| < 1$ .

**تحديد مجموعة التدريب ومجموعة الاختبار:**

يتم تقسيم العينات المتوفرة الى مجموعتين، مجموعة تدريب ومجموعة اختبار، تقوم مجموعة التدريب بإيجاد القيم النهائية المثلى لحزم الأوزان التي تتقارب عندها تابع الأداء (performance function) نحو القيمة الصغرى المطلقة، وكلما ازدادت كمية العينات المدخلة في التدريب ازداد التكافؤ ما بين الخرج الفعلي والخرج الناتج من الشبكة، وبشكل عام ترتبط حجم عينات التدريب بدرجة تعقيد المسألة المدروسة وطبيعة متغيرات الدخل وتركيب بنية الشبكة والأداء المطلوب تحقيقه من الشبكة [Hagan,M.T; Demuth,H.B; Beale,M.H, 1995]. أشار [Haldar,2015] أن كمية عينات التدريب التي نحتاجها لشبكة جيدة الأداء هي  $10 * \text{عدد متغيرات الدخل}$  المخصصة للشبكة. وتعتمد معظم الأبحاث على نسبة لعينة التدريب تتراوح ما بين % (70-90) من اجمالي العينات المتاحة [Dahhan,M.L,2015]. لذلك تم في هذا البحث استخدام عينة بيانات لـ 69 شهراً مأخوذة من مشروع حالة الدراسة، وتم اختيار 54 عينة منها لتدخل في مرحلة تدريب الشبكة في حين تم استثناء 15 عينة بشكل عشوائي أي ما يعادل 20% لتدخل في مرحلة اختبار قابلية الشبكة على التنبؤ.

**الأداة المستخدمة في البحث:**


قدمت العديد من الشركات برامجا جاهزة للشبكات العصبية كـ (Neu Net Pro2.2, Predicator ,Brain maker) لمساعدة المستخدمين الذين لا تتوافر لديهم مهارات البرمجة في نمذجة مفهوم الشبكة العصبية، الا أن في هذه الدراسة تم الاعتماد على لغة الماتلاب (Matlab V.9) في تصميم معمارية الشبكة وتكويد كل من خوارزمية التغذية الأمامية مع قاعدة الانتشار الخلفي لضبط أوزان الشبكة في مرحلة التدريب و خوارزمية التغذية الأمامية للتأكد من صحة التنبؤ في مرحلة اختبار الشبكة.

**تحديد البنية الهيكلية للشبكة العصبية:****طبقة الدخل وعدد عناصر المعالجة.**

تتألف كل شبكة عصبية من طبقة دخل واحدة تحوي عددا من عناصر المعالجة مساوية لعدد متغيرات الدخل المختارة. وفي هذه الدراسة لدينا 8 متغيرات دخل وهي  $(PD, TV, SPI, CR, AD, ED, ES, SPI(t))$ .

## طبقة الخرج وعدد عناصر المعالجة.

تتألف كل شبكة عصبية من طبقة خرج واحدة تحوي عدداً من عناصر المعالجة مساوية لعدد المخرجات النهائية المطلوبة من الشبكة ولدينا عنصر معالجة واحد يعطي الخرج الذي صممت لأجله شبكة التنبؤ بزمن انتهاء المشروع  $(EAC(t))$ ، وبوجود هذه الشبكة يمكن استبعاد اللجوء إلى أي من المعادلات التسعة السابقة. يوضح الشكل (7): معمارية الشبكة العصبية (حالة الدراسة).



الشكل (7): معمارية الشبكة العصبية (حالة الدراسة).

## توابع التحويل:

تم استخدام تابع التحويل الأسّي (Sigmoid) أثناء معالجة وضبط قيمة الدخل الصافي لكل من عصبونات الطبقة الخفية وعصبون طبقة الخرج، تتمثل وظيفة هذا التابع بأخذ قيم الدخل المحصورة بين  $-\infty$  و  $+\infty$  وجعل قيم الخرج محصورة بين 0 و 1، تلجأ خوارزمية الانتشار العكسي للأخطاء (Back Propagation) الى تطبيق هذا التابع لامتلاكه خصائص هامة، إذ أنه تابعا انسيابيا مستمرا وقابلا للاشتقاق ومشتقه سهل الحساب و يعطى الشكل الرياضي

$$f(X) = \frac{1}{1+e^{-x}} \quad \text{له بالعلاقة التالية:}$$

## تحديد قيمة معدل التعلم:

يقوم ثابت معدل التعلم بتحديد حجم الخطوة وسرعة تغير الميل في قاعدة الانحدار التدريجي والتي على أساسها يتم تعديل أوزان الشبكة، ويقع قيم هذا الثابت ضمن المجال [0.1] ويتأثر بنوع وحجم المشكلة المدروسة، ففي حال اعطاء قيمة صغيرة لمعدل التعلم تتعدل الأوزان ببطء وتأخذ الشبكة وقتاً أطول في التدريب وتنجح في التقارب نحو الخطأ الأصغري. في حال اعطاء قيمة كبيرة لمعدل التعلم تحصل انتقالات مفاجئة في الأوزان ويقل زمن تدريب الشبكة وتفشل الشبكة في التقارب نحو الخطأ الأصغري [Chollet,F,2017]. للحصول على الشبكة المثلى تم فرض عدة قيم لثابت معدل التعلم تراوحت ضمن المجال [0.3-0.7].

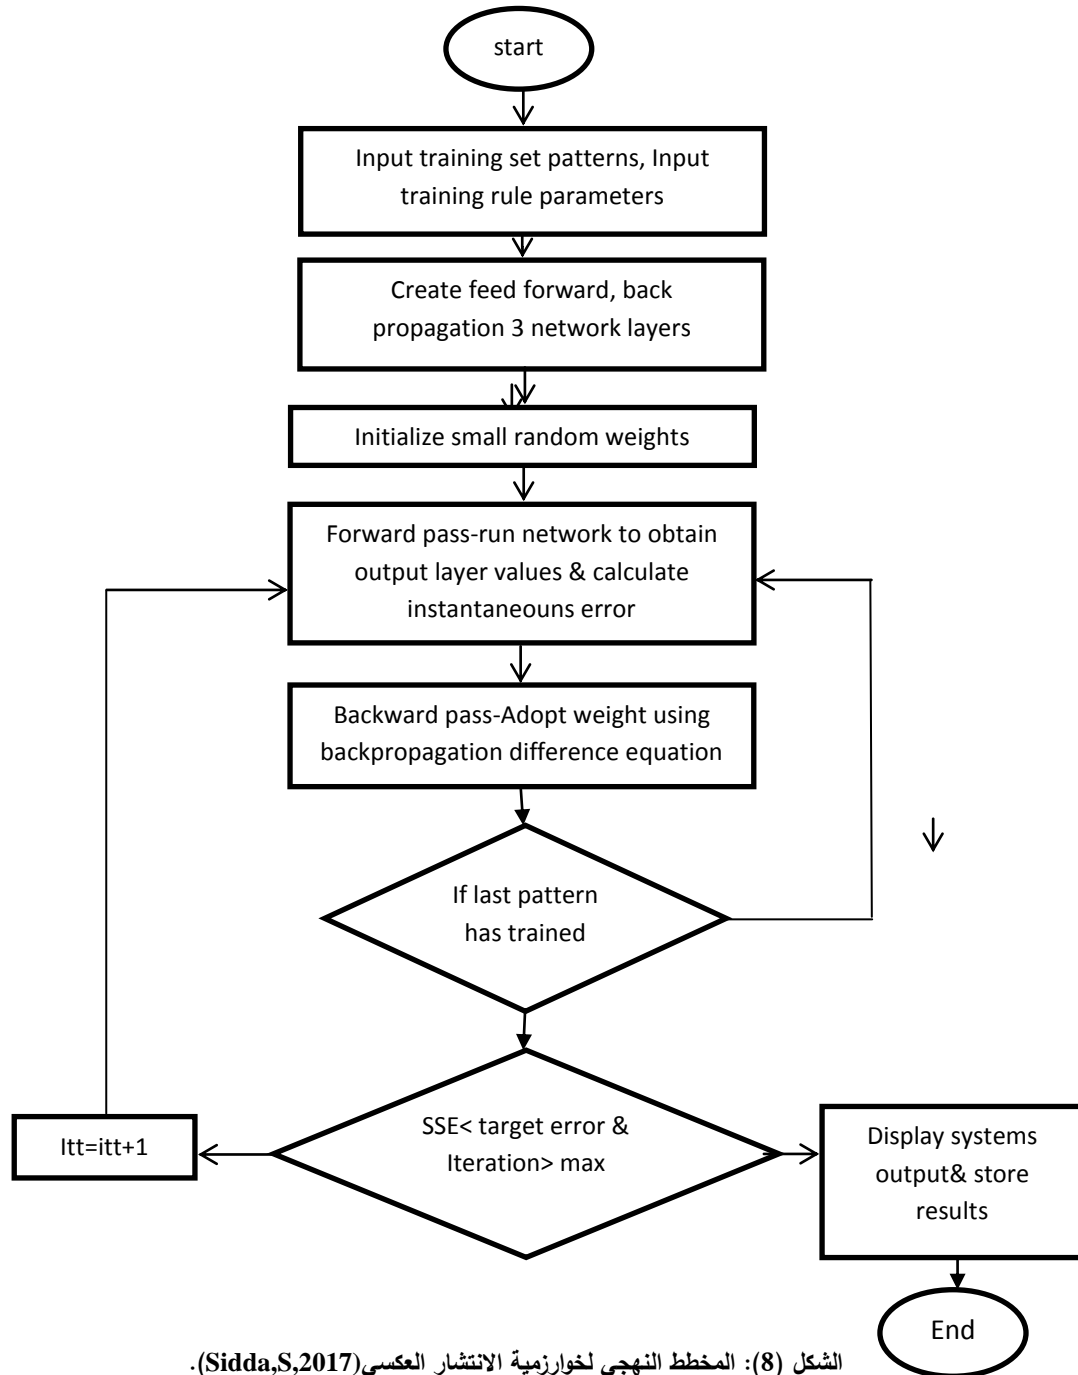
## تحديد قيمة معدل الزخم:

قد تقود عملية تعديل الأوزان وفق قاعدة الانحدار التدريجي تابع الكلفة نحو الخطأ الأصغري المحلي، خاصة عندما يكون لمنحنى تابع الكلفة شكلا معقدا يصعب من خلاله التقارب نحو الخطأ الأصغري العام، لذا اقترح [Rumelhart,D,Hinton.G and Williams,R,1986] اضافة حد جديد لتابع تعديل الأوزان يجعل عملية تعديل كل وزن في دورة تكرار ما يعتمد على الوزن المعدل له في التكرار السابق. للوصول الى الحل الأمثل تم فرض عدة قيم لثابت معدل الزخم تراوحت ضمن المجال [0.15-0.8].

## النتائج والمناقشة:

### مرحلة تدريب الشبكة:

تم تقديم عينات التدريب المتكونة من عدد محدد من الأزواج ممثلاً بالمدخلات والخرج المقابل لها الى الشبكة العصبية وذلك بعد اعطاء قيم عشوائية صغيرة لأوزان الشبكة، ثم من أجل كل عينة تدريب تم تدفق ومعالجة المدخلات من طبقة إلى أخرى بشكل متسلسل وفق مسار أمامي فقط (Feed forward)، والذي منه تم الحصول على خرج الشبكة ومقارنته مع القيمة الأولية المطلوبة من الشبكة وحساب مقدار الخطأ، ثم تم اتباع خطوة تراجعية (Backward) لتعديل الأوزان بهدف تصغير مقدار الخطأ استناداً الى قاعد الانحدار التدريجي لخوارزمية الانتشار العكسي ومعيار معلوم للخطأ. تم تكرار الخطوات السابقة عدة مرات حتى أصبح معيار دالة الكلفة أو دالة الأداء المعبر عنها بمجموع مربعات الأخطاء (SSE) خلال كل عينات التدريب أقل من حد معين معلوم أعطت وفقه الشبكة أفضل نتيجة قريبة من النتيجة المطلوبة. يوضح الشكل (8) المخطط النهجي لخوارزمية الانتشار العكسي.



تم تجريب 35 حالة معمارية مختلفة لشبكة التنبؤ بزمن انتهاء المشروع، تتألف جميعها من طبقة خفية واحدة وتختلف عن بعضها البعض بعدد العقد في الطبقة الخفية وقيمة معدل التعلم وقيمة معدل الزخم وعدد مرات تكرار تدريب الشبكة. يوضح الجدول (7) عينة من نتائج تدريب التصميم المعمارية المختلفة لشبكة التنبؤ بزمن انتهاء المشروع.

الجدول (7) عينة من نتائج تدريب التصاميم المعمارية المختلفة لشبكة التنبؤ بزمن انتهاء المشروع.

رقم المعمارية	عدد الطبقات الخفية	عدد العقد في الطبقة الخفية	معدل التعلم	معدل الزخم	مجموع مربعات الأخطاء (SSE)	عدد مرات تكرار تدريب الشبكة
9	1	3	0.7	0.8	0.0100	900
10	1	3	0.4	0.6	0.3180	100
11	1	4	0.3	0.15	0.4451	100
13	1	4	0.6	0.5	0.0100	600
14	1	4	0.7	0.8	0.0100	900
15	1	4	0.4	0.6	0.0100	900
16	1	5	0.3	0.15	0.4827	100
19	1	5	0.7	0.8	0.0100	600
20	1	5	0.4	0.6	0.0100	900
21	1	6	0.3	0.15	0.3697	100
22	1	6	0.5	0.2	0.0099	900
23	1	6	0.6	0.5	0.0100	700
24	1	6	0.7	0.8	0.0100	900
25	1	6	0.4	0.6	0.0100	800
26	1	7	0.3	0.15	0.0370	300
28	1	7	0.6	0.5	0.0100	700
29	1	7	0.7	0.8	0.0281	100
33	1	8	0.6	0.5	0.0429	100
34	1	8	0.7	0.8	0.0100	300
35	1	8	0.4	0.6	0.0100	900

تم اعتبار مجموع مربعات (SSE) مقياساً يساعد في ايجاد شبكة التنبؤ المثلى من بين التصاميم المعمارية المختلفة التي تم تجربتها خلال مرحلة التدريب.

أظهرت نتائج التدريب أن المعمارية رقم 22 المؤلفة من طبقة خفية واحدة البالغ عدد عقدها 6 عقد مع معدل تعلم 0.5 ومعدل زخم 0.2، تمثل شبكة التنبؤ المثلى بزمن انتهاء المشروع الموافقة للخطأ الأصغري 0.0099 مقابل الحد المسموح للخطأ 0.01 بعد اجراء 900 دورة تدريب للشبكة .

#### مرحلة اختبار الشبكة:

تم اختبار شبكة التنبؤ المثلى التي تم الحصول عليها من مرحلة التدريب على عينات لم تتدرب عليها مسبقاً والبالغ عددها خمسة عشر عينة، في هذه المرحلة تم القيام بحسابات الجمع والتحويل وفق مسار أمامي فقط ليتم الحصول على خرج الشبكة وحساب الفرق بينه وبين الخرج المستهدف، وأخيراً تم ادخال خطأ كل عينة اختبار الى دالة الأداء ليتم الوصول الى مجموع مربعات الأخطاء وأخيراً مقارنة هذا الحد مع المعيار المسموح للخطأ [Dawson,C,2016] للتأكد من امكانية الشبكة في التنبؤ مستقبلاً.

وصل مجموع مربعات الأخطاء (SSE) بالنسبة لعينات الاختبار ومن أجل شبكة التنبؤ بزمن انتهاء المشروع الى القيمة 0.007 مقابل المعيار المسموح للخطأ 0.01 كما هو موضح في الجدول (8).

الجدول (8) نتائج اختبار الشبكة المثلى وحساب الخطأ (SSE).

رقم عينة الاختبار	الخرج الناتج عن الشبكة $O_{ij}$	الخرج الفعلي $T_{ij}$	$T_{ij} - O_{ij}$	$(O_{ij} - T_{ij})^2$
1	0.5928	0.59	-0.0028	$7.84 * 10^{-6}$
2	0.5945	0.59	-0.0045	$2.025 * 10^{-5}$
3	0.9236	0.94	0.0164	$2.6896 * 10^{-4}$
4	0.5701	0.59	0.0199	$3.9601 * 10^{-4}$
5	0.9218	0.94	0.0182	$3.3124 * 10^{-4}$
6	0.5676	0.59	0.0224	$5.0176 * 10^{-4}$
7	0.5799	0.59	0.0101	$1.0201 * 10^{-4}$
8	0.9210	0.94	0.019	$3.61 * 10^{-4}$
9	0.5567	0.59	0.0333	$1.10889 * 10^{-3}$
10	0.5532	0.59	0.0368	$1.35424 * 10^{-3}$
11	0.9522	0.94	-0.0122	$1.4884 * 10^{-4}$
12	0.5458	0.59	0.0442	$1.95364 * 10^{-3}$
13	0.5700	0.59	0.02	$4 * 10^{-4}$
14	0.9540	0.94	-0.014	$1.96 * 10^{-4}$
15	0.5920	0.59	-0.002	$4 * 10^{-6}$
مجموع مربعات الأخطاء (SSE)				<b>0.007</b>

مع التنويه أنه قد تم إجراء عملية التطبيع لمدخلات ومخرجات الشبكة باستخدام طريقة القياس العشري Decimal scaling وتحوّلت جميع الأرقام إلى أعداد كسرية.

قدمت الشبكات العصبية الاصطناعية نتائج دقيقة مقارنة بالأساليب الاحصائية التقليدية التي تستخدمها منهجية ال (EVM) وتوازن بينها لمعرفة الأسلوب الأمثل في التنبؤ بزمن الانتهاء المتوقع للمشروع كما هو موضح في الجدول (9) مما يؤكد قدرة تعميم الشبكة على مشاريع مشابهة.

الجدول (9) المقارنة بين نتائج دقة ال EVM و ANN في التنبؤ بالزمن.

رقم العينة	1	2	3	4	5	6	7	8	9
دقة التنبؤ % (EVM)	28	29	37	96	77	83	82	77	96
دقة التنبؤ % (ANN)	99	99	98	97	98	96	98	98	94
رقم العينة	10	11	12	13	14	15			
دقة التنبؤ % (EVM)	83	88	98	82	79	84			
دقة التنبؤ % (ANN)	94	99	93	97	99	99			



إن العينات رقم (1,2,4,6,7,9,10,12,13,15) مأخوذة من كلية التربية والعيّنات رقم (3,5,8,11,14) مأخوذة من كلية طب الأسنان. وقد لوحظ انخفاض دقة تنبؤ الشبكة العصبية مرة وازديادها مرة أخرى أثناء تقدم سير العمل في المشروع أو اقترابنا من النهاية ويعود ذلك إلى اختلاف جودة البيانات المتاحة خلال الأشهر التي يتم فيها التنبؤ.

## الاستنتاجات والتوصيات:

### الاستنتاجات:

1. تبين بعد استخدام الترتيب المعطى لدقة تنبؤ المعادلات التسعة بالزمن والواقع ضمن المجال (9 → 1) أن المعادلة  $EAC(t)_{ES3}$  التي يأخذ فيها معامل الأداء PF القيمة CR أدق معادلة في التنبؤ بزمن الانتهاء المتوقع لمشروع اكملات كلية التربية، وأن المعادلة  $EAC(t)_{ED2}$  التي يأخذ فيها معامل الأداء PF القيمة SPI أدق معادلة في التنبؤ بزمن الانتهاء المتوقع لمشروع اكملات كلية الطب، وبالتالي: عدم وجود معادلة واحدة لـ  $EAC(t)$  تعطي تنبؤات مرحلية دقيقة باستمرار وخصوصاً في المراحل المبكرة من المشروع.
2. استطاعت منظومة التنبؤ المبنية على الشبكات العصبية اثبات فعاليتها في التنبؤ بزمن انتهاء المشروع، حيث أعطت الهيكلية المثلى (1-6-8) المدربة على خوارزمية الانتشار العكسي (Back propagation) في مرحلة اختبار الشبكة على العينات المستبعدة من مجموعة التدريب القيمة 0.007 لمجموع مربعات الأخطاء مقابل الحد المسموح للخطأ 0.01.
3. أظهرت النتائج توافقاً كبيراً بين القيم الفعلية والقيم الناتجة عن الشبكة مؤكداً قدرة تعميم الشبكة على مشاريع مشابهة.
4. تختلف دقة النتائج باختلاف المشاريع والظروف المحيطة بها وكمية البيانات المتاحة ومدى جودتها ونوعيتها.

### التوصيات:

1. توطين أحدث تقنيات الرقابة المعروفة عالمياً لمتابعة تنفيذ المشاريع الانشائية المختلفة ضمن سوريا.
2. تكوين مؤشرات متعلقة بقياس أداء الجودة ودمجهم الى منهجية الـ (EVM) لتتمكن من قياس أداء مشاريع التشييد من حيث النطاق والجدول الزمني والتكاليف والجودة.
3. اقتراح نظام متكامل لإدارة الوقت والتكلفة (ITCMS) خلال مرحلتي التصميم والتنفيذ.

## References:

1. SAEED,A,L; AND FARHAN,K,S. *Using Earned Value Method in Project Control Applied Research*. Journal of Economics and Administrative Sciences Iraq, Vol.20,NO.80,2014,36-71.
2. BUYSE,P. AND VANDENBUSSCHE,T. *Performance analysis of earned value management in the construction industry*. Faculteit economie en bedrijfskunde,Universiteit of Ghent, Ghent city, Belgium, 2010.
3. AZIMI,F; AND NAJAFI,A. *An Extension of the Earned Value Management to Improve the Accuracy of Schedule Analysis Results*. Iranian Journal of Management Studies (IJMS), Iran, Vo.9, No.1,2016,63-75.
4. GHANBARI,A.; TAGHIZADEH,H.; AND IRANZADEH,S. *Project Duration Performance Measurement by Fuzzy Approach under Uncertainty*. European Journal of Pure and Applied Mathematics, New York Business Global, Vol.10, No.5, 2017, 1135-1147.

5. FLEMING,Q.W.; and KOPPELMAN,J.M. *Earned Value Project Management*. 2<sup>nd</sup> .ed., Project Management Institute, Four Campus Boulevard, Newtown Square, Pennsylvania 19073-3299 USA, United States of America,2000,222.
6. PROJECT MANAGEMENT INSTITUTE . *Project Management Body of Knowledge (PMBOK Guide)*. 4<sup>th</sup> .ed., Project Management Institute, Inc, 4 Campus Boulevard, Newtown Square, Pennsylvania 19073-3299 USA, United States of America, 2008, 506.
7. LIPKE,W. *Earned Schedule-Ten Years After*. The Measurable News, May 2013, 15-21.
8. SHABAN,M.H. *Modern Management of Projects using Earned Values-Concept and Application*.1<sup>st</sup> .ed., Publication of the Research Centre, Institute of Publication Administration, Riyadh Saudi Arabia,2012,409.
9. WAZIRI,B.S.; BALA,K. AND BUSTANI,S.A. *Artificial neural networks in construction engineering and management*. International journal of Architecture, Engineering and Construction, Vol.6, No.1, March 2017, pp.50-60.
10. HAGAN,M.T.; DEMUTH,H.B.; and BEALE,M.H. *Neural Network Design*. Har/Dskt edition, Pws Pub Co, 1995,734.
11. WIDROW,B; GREENBLATT,A; KIM,Y. AND PARK,D. *The No- Prop algorithm: A new learning algorithm for multilayer neural network*. Neural Network Journal, Elsevier Science Ltd, Oxford, UK, Vol.37, January 2013, pp.182-188.
12. Hasan,B; Makkieh,S. ; and Titzian,N. *Forecasting the Final Cost of Infrastructure Projects in Syria Using Earned Value Management and Artificial Intelligence*. Tishreen University Journal for Research and Scientific Studies, Engineering Sciences Series, Syria, Vol.42,No.1, January 2020,pp.197-218.
13. PRIDDY,K.L;KELLER,P.E. *Artificial Neural Network*. 1<sup>st</sup> ed, SPI-The International Society of Optical Engineering, Bellingham, Washington USA,2005,163.
14. SARANYA,C. AND MANIKANDAN,G. *A study on normalization techniques for privacy preserving data mining*. International journal of engineering and technology, Vol.5, No.3, June-jul 2013, pp.2701-2704.
15. <https://medium.com/@malay.haldar/how-much-training-data-do-you-need-da8ec091e956>,Nov 28, 2015.
16. DAHHAN,M.L. *Building a Clustering Model Using Neural Networks for Supporting Electronic Marketing Operation*. Faculty of Economics, Aleppo University, Syria, 2015.
17. CHOLLET,F. *Deep Learning With Python*.1<sup>st</sup>. ed., Manning Publications, Shelter Island, 2017,384.
18. RUMELHART,D.E.; HINTON,G.E. AND WILLIAMS,R.J. *Learning representations by back-propagating errors*. Nature, Vol.323, No.6088, 1986, pp.533-536.
19. SIDDA, S. *A Review on Artificial Intelligence Techniques in Electrical Drives: Neural Networks, Fuzzy Logic, and Genetic Algorithm*. International Conference on Smart Technologies for Smart Nation, REVA University, Bangalore, India, 2017,55-60.
20. DAWSON, C. *Applied Artificial Neural Network*.1<sup>st</sup>.ed., MDPI AG, St. Alban-Anlage 66, Basel, Switzerland, 2016,258.