

## استخدام الشبكات العصبية والارتداد الخفي

### لتوقعات الطاقة اللازمة للحرث

أ.د./ محمد نبيل العوضي\*  
د.د./ عبد الفضيل جابر القباني\*\*  
د./ محمد حسن أحمد قابيل\*\*\*  
م./ عبد الواحد محمد أبوكريمة\*\*\*\*

### الملخص

تم في هذا البحث استخدام طريقتي الارتداد الخفي المتعدد والشبكات العصبية الاصطناعية في التوقع بمقدار استهلاك الوقود (لتر/فدان) والطاقة اللازمة للحرث (كيلوجول/فدان). تم تقدير هذه الكميات من نتائج سابقة، مامكغ (٢٠٠٢م)، لثلاثة أنواع من المحارث هي: حفار، قلاب مطرحي، وقلاب قرصي تعمل بثلاثة سرعات أمامية هي: ٥، ٧، ٩ كم/س عند عمق حرث ٢٥ سم في تربة طينية طميية (clay loam) متغيرة المحتوى الرطوبي بنسب ٨، ١١، و ١٤% على أساس جاف.

عند استخدام طريقة الارتداد الخفي المتعدد استخدم معامل يعبر عن المحارث، يساوي ١ للمحراث الحفار، و ٢ للمحراث القلاب المطرحي، و ٢,٥ للمحراث القلاب القرصي. وتكونت الشبكة العصبية الاصطناعية المقترحة من ثلاث طبقات، واحدة للمدخلات بعدد ٥ عناصر حسابية هي: سلاح حفار، سلاح مطرحي، سلاح قرصي، المرعة الأمامية، والمحتوى الرطوبي للتربة، وطبقة للمخرجات بعدد ٢ عنصر حسابي هي: استهلاك الوقود والطاقة اللازمة للحرث، وطبقة مختفية بعدد ١٦ عنصر حسابي. وتم استخدام الدالة الحدية (tanh) في كل من طبقة المخرجات والطبقة المختفية كدالة تحويل.

استخدمت بيانات حقلية لنتائج سابقة (١٨ مشاهدة) لإيجاد ثوابت معادلة الارتداد الخفي المتعدد وتدريب الشبكة العصبية الاصطناعية المقترحة باستخدام طريقة الانتشار الخفي بمعدل تعليم قدره ٠,٠٠٩٨ وبمعدل تكرارات ٦٠٠٠٠ مكررة. استخدم الجذر التربيعي لمتوسط مربع الأخطاء (RMSE) كمعيار للدلالة على أن الشبكة العصبية الاصطناعية تدرت بشكل جيد، حيث وصلت أقل قيمة له أثناء مرحلة التدريب إلى ٠,٠٠٠٠٢٤٦، ويسدل هذا الرقم على أن الشبكة العصبية الاصطناعية المقترحة قد تدرت بشكل دقيق. وللتأكد من كفاءة الشبكة العصبية الاصطناعية التي تم تدريبها فقد تم تقدير استهلاك الوقود والطاقة اللازمة للحرث لمدد ٩ مشاهدات لم يسبق للشبكة للتعرض لها من قبل، وقد تم الحصول على نتائج تتوافق جيداً مع قيمتها المقاسة ( $R^2 = 0.98$ ).

أوضحت النتائج تفوق طريقة الشبكات العصبية على طريقة الارتداد الخفي لتوقع استهلاك الوقود والطاقة اللازمة للحرث، حيث كانت قيمة (RMSE) لمقدار الطاقة اللازمة للحرث ٢,٦٩٩ كيلوجول/فدان عند استخدام الشبكات العصبية بينما كانت ٣,٧٢٩ كيلوجول/فدان عند استخدام طريقة الارتداد الخفي المتعدد في التوقع بها. وهذه النتائج توضح أنه يمكن استخدام الشبكات العصبية الاصطناعية بدقة في التوقع بمقدار استهلاك الوقود والطاقة اللازمة للحرث على الرغم من عدم معرفة نوع العلاقة الرياضية بينهما وبين العوامل المؤثرة فيهما.

\* أستاذ الهندسة لآلية المتفرغ، قسم الهندسة الزراعية، ك. الزراعة، ج. عين شمس.

\*\* مدرس الهندسة الزراعية، قسم الهندسة الزراعية، ك. الزراعة، ج. عين شمس.

\*\*\* باحث أول، معهد بحوث الهندسة الزراعية، القلي، الجيزة.

\*\*\*\* باحث مساعد، معهد بحوث الهندسة الزراعية، القلي، الجيزة.

## ١. المنظمة

زاد الاهتمام بتقسيم أداء الجرارات الزراعية أثناء عملية الحرق نظراً لأنها تستهلك أكبر قدر من طاقة الوقود بين العمليات الزراعية. حيث أوضح المشري (١٩٩٥م) أن طاقة الوقود تمثل للشطر الأعظم من إجمالي الطاقة الإجمالية المستهلكة لإنتاج الفدان من الأرز تحت الظروف المصرية، حوالي ٤٦.١% كان نصيب عملية إعداد الأرض منها ٢١.٤%. وأوضح الباحث أن عملية إعداد الأرض لزراعة محصول القمح تحتاج إلى ٣٥.٩% من إجمالي طاقة الوقود الكلية.

ولإجراء عملية تقييم أداء الجرارات الزراعية لابد من قياس عدة متغيرات مثل قوة الشد الأمامية، واستهلاك الوقود ويجري هذا القياس عند ظروف تشغيل مختلفة مثل عمق الحرق، والسرعة الأمامية، ونوع سطح السقوية، والظروف الابتدائية للتربة كالكتافة الظاهرية والمحتوى الرطوبي. ومن ناحية أخرى فإن القياس للمبائر والدقيق لإيجاد استهلاك الوقود أثناء التشغيل الحقلّي يكون مكلف وصعب ( El-Sayed and El-Kilani, 2002)، لذا فإن برامج المحاكاة أو المعادلات المستتبطة إحصائياً تكون أكثر كفاءة في هذه الحالة (Gömaa et al., 1995). ومعظم المعادلات المستخدمة تكون لنوع محراث واحد فقط وظروف التشغيل تشمل السرعة الأمامية، وعمق الحرق.

ونظراً لأن المحتوى الرطوبي للتربة من العوامل المؤثرة على كفاءة تشغيل الجرار أثناء عملية الحرق، حيث المحتوى الرطوبي للتربة المثالي يساعد على إنجاز عملية الحرق بكفاءة عالية وتقليل الطاقة (Kepner et al., 1987)، لذا عند التنبؤ باستهلاك الوقود أثناء عملية الحرق يجب الأخذ في الاعتبار كل المتغيرات التي تؤثر فيه من ناحية أخرى نجد أن تشغيل منظومة الجرار الزراعي والآلة، بشكل مثالي، من الاهتمامات الرئيسية للمعلمين في مجال الهندسة الزراعية، لذا تركز دراساتهم حول تحسين أداء هذه المنظومة بمعرفة ظروف تشغيلها المناسبة مما يؤدي إلى تقليل تكاليف التشغيل والتي يدخل في تقديرها استهلاك الوقود. ومع انتشار الزراعة الآلية ومحدودية مصادر الطاقة التقليدية وأهمها وقود الديزل، أصبح لزاماً ترشيده وذلك بإتباع الأساليب المناسبة للتشغيل في عمليات الحرق.

أوضح الموضي (١٩٩٨م) أنه عند اختيار نظم الميكنة الزراعية والآلات فإن الأساليب الحديثة المعتمدة على الحاسب الإلكتروني (نظم الخبرة) تساعد بالخروج بقرارات لاختيار أنسب الآلات والاحتياجات من كل منها، أو من النظم لتأدية كافة العمليات الزراعية. ومن الأساليب الحديثة التي تساعد في إنشاء النماذج المستخدمة في التنبؤ في مجال الهندسة الزراعية الشبكات العصبية الاصطناعية، والتي أصبحت واقفاً ملموساً نظراً للتطور الهائل في أجهزة الحاسب الآلي والبرمجيات. وهذه الشبكات أثبتت أنها أفضل من الطرق الإحصائية التقليدية عند استخدامها في التنبؤ في مجالات عديدة، حيث نوعية التنبؤ تعتمد على الطريقة المستخدمة واختيار المدخلات المناسبة. والشبكات العصبية الاصطناعية عبارة عن نموذج يحاكي لشبكة العصبية الطبيعية وتستخدم عددًا محدودًا من الطرق الأساسية المستخدمة فيها بمساعدة برمجيات المحاكاة وأساليب المعالجة المتوازية.

يهدف هذا البحث إلى استخدام طريقتي الارتداد الخطي الممتد والشبكات العصبية الاصطناعية في التوقع بمقدار استهلاك الوقود (لتر/فدان) والطاقة اللازمة للحرق (كيلوجول/فدان) لمحاربت مختلفة تحت ظروف مختلفة من التشغيل تشمل السرعة الأمامية والمحتوى الرطوبي للتربة، ثم المقارنة بين هاتين الطريقتين.

درس Morad and El-Shazly (1994) بعض عوامل التشغيل على أداء المحراث الدوراني في تربة طينية طميية (clay loam) فوجدوا أن الطاقة اللازمة للحراث تقل بزيادة المحتوى الرطوبي للتربة وكانت أقل قيمة لها عند محتوى رطوبي مقداره ٢١% على أساس جاف. كما أوضح الجنوبي وهوبي (١٩٩٨م) أن استهلاك الوقود (لتر/س) يزداد بزيادة سرعة وعمق الحراث لتربة رملية طميية (sandy loam).

درس El-Ansary et al. (1995) تأثير المحتوى الرطوبي للتربة على استهلاك الوقود والطاقة اللازمة للحراث، حيث استخدموا ٤ مستويات من المحتوى الرطوبي للتربة ٣٦، ٢٤، ١٥، ٩% وذلك لمحاربت مختلفة عمق ١٦ سم وأوضحوا أن استهلاك الوقود (لتر/فدان) والطاقة اللازمة للحراث (كيلووات.س/فدان) يقل بزيادة المحتوى الرطوبي للتربة ما عدا عند محتوى رطوبي للتربة أكثر من ٢٤% فإنهما يزيدا وأدرجوا معادلة لحساب استهلاك الوقود كدالة في المحتوى الرطوبي للتربة.

أوضح El-Sheikha (1989) أن للسرعة الأمامية تأثير على الاستهلاك النوعي للوقود (لتر/م<sup>٣</sup> من حجم التربة المحروثة) ويقل بزيادتها لمحراث حفار. وأوضح نفس الباحث أنه للتربة الجافة (١٥% محتوى رطوبي) فإن الاستهلاك النوعي للوقود يزيد بالمقارنة مع التربة الرطبة (٣٠% محتوى رطوبي)، حيث استخدم في دراسته ٣ سرعات أمامية و ٤ مستويات من المحتوى الرطوبي للتربة ١٥، ١٦، ٢٢، ٣٠%.


أوضح Kepner et al. (1987) أنه في المناطق الجافة فالري قبل عملية الحراث ربما يقلل الطاقة اللازمة و/أو يزيد من درجة التفتت للتربة. ودرس Mohamed et al. (1995) العوامل المؤثرة على أداء المحراث الحفار تحت الظروف المصرية ومنها عمق الحراث، وسرعة التشغيل، والمسافة بين الأسلحة وأدرجوا في دراستهم معادلة مستنبطت إحصائياً بالارتداد الخطي البسيط لإيجاد الطاقة اللازمة للحراث كدالة في عمق الحراث في المدى المستخدم بين ٣،٤ سم و ١٢،١ سم.

أجرى مامخ (٢٠٠٢م) تجارب بالأردن لتقدير استهلاك الوقود أثناء الحراثة في تربة طينية طميية (clay loam)، مع تغيير المحتوى الرطوبي والسرعة الأمامية ونوع المحراث، وخرجت الدراسة بأن أقل استهلاك وقود كان عند استخدام المحراث الحفار مقارنة مع المطرحي والقرصي عند محتوى رطوبي للتربة مقداره ١٤% وسرعة أمامية ٩ كم/س، غير أن هذه الدراسة لم تحتوي على نموذج رياضي يساهم في الخروج بنظرية عامة.

أوضح Langman (1999) أن الشبكات العصبية الاصطناعية أداة مناسبة لوصف الظواهر غير الخطية والعمليات التي تحدث في مجال الهندسة الزراعية. واستخدم Altendorf et al. (1999) الشبكات العصبية الاصطناعية في التنبؤ بالمحتوى الرطوبي للتربة ومقارنتها بطريقة الارتداد الخطي المتمعد فوجدوا أن طريقة الشبكات العصبية الاصطناعية تتفوق عليها. واستخدم Al-Janobi et al. (2001) الشبكات العصبية الاصطناعية في التنبؤ بمقدار الشد النوعي لعدة محاربت تحت ظروف مختلفة من التشغيل شملت السرعة الأمامية، وعمق الحراث وظروف مختلفة من الخواص الطبيعية للتربة (الكثافة الظاهرية والمحتوى الرطوبي) وكانت نتائجهم المقاسة والمتنبأ بها متوافقة جداً. ووجد عدة باحثين (Kohzadi et al., 1996; Roush and Cravener, 1997; Alhmdan et al., 2001 and Lykins and Chance, 1992) أن طريقة الشبكات العصبية الاصطناعية تتفوق على الطرق الإحصائية التقليدية عند استخدامها كأداة للتنبؤ.

### ٣. المواد والطرق المستخدمة

تتكون الشبكة العصبية الاصطناعية من مجموعة من عناصر المعالجة تتركب بطرق مختلفة وكل عنصر معالجة يستقبل عدد من المدخلات ويمطي إشارة خارجة واحدة، شكل (١). والمدخلات يمكن أن تكون على صورة بيانات خام أو تكون هي المخرجات من عناصر معالجة أخرى. والإشارة الخارجة يمكن أن تكون النتيجة النهائية للمشكلة المطلوب حلها باستخدام الشبكة أو تكون مدخلاً لعنصر معالجة آخر. ويتم تجميع عناصر المعالجة في مجموعات موزعة في طبقات لتكوين الشبكة العصبية الاصطناعية. ولمزيد من التفاصيل عن طبيعة الشبكات العصبية الاصطناعية يمكن الرجوع إلى (Hecht-Nielsen, 1990).



شكل (١): عنصر المعالجة في الشبكة العصبية الاصطناعية.

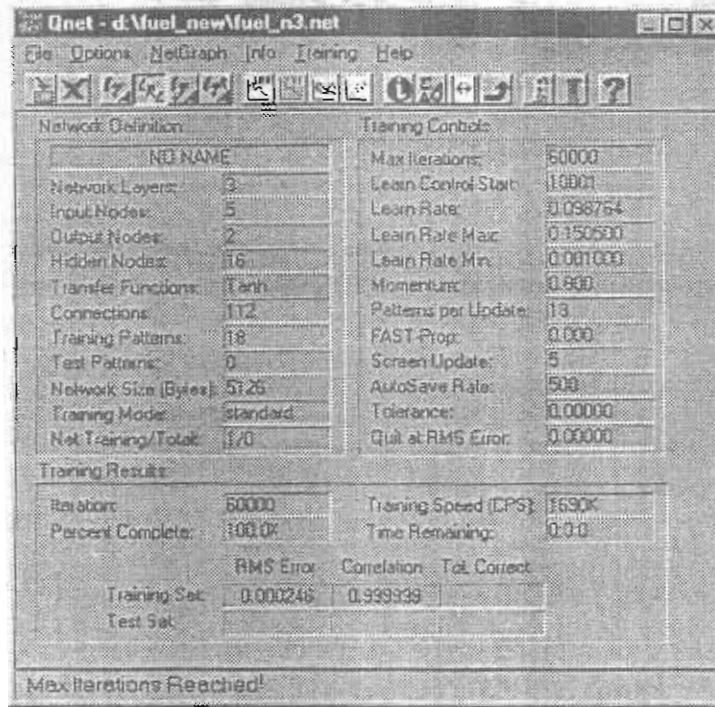
تم حساب الطاقة اللازمة للحث من المعادلة التالية:

$$FE = \frac{nlf \times \rho \times g \times H \times C \times \eta_m \times \eta_i}{10^6} \quad (1)$$


حيث FE = الطاقة اللازمة للحث، ميجا جول/فدان، nlf = استهلاك الوقود، لتر/فدان،  $\rho$  = كثافة وقود الديزل وتساوي ٠.٨٥ كج/لتر، g = عجلة الجاذبية الأرضية وتساوي ٩.٨١ م/ث<sup>٢</sup> = القيمة الحرارية لوقود الديزل وتساوي ١٠٠٠٠ ك.كالوري/كج، C = المكافئ الميكانيكي الحراري وتساوي ٤٢٧ كج.م/ك.كالوري،  $\eta_m$  = الكفاءة الميكانيكية لمحرك الديزل وتساوي ٨٠%،  $\eta_i$  = الكفاءة الحرارية لمحرك الديزل وتساوي ٤٠%، ثابت تحويل.

تم استخدام برنامج حاسب آلي من شركة (Vesta Services (2000) يسمى Qnet2000 وهو يناسب التشغيل مع النوافذ، ويمكن التعامل معه بسهولة من خلال مجموعة من القوائم تعرض كيفية اختيار تركيب الشبكة العصبية الاصطناعية ومتغيراتها المؤثرة في عملية التدريب. في هذا البحث تم تغيير عدد الطبقات المختلفة وعدد عناصرها الحسابية بطريقة المحاولة والخطأ للوصول إلى أنسب تركيب للشبكة العصبية المقترحة بناءً على أقل قيمة يمكن أن يصل إليها الجذر التربيعي لمتوسط مربع الأخطاء (RMSE) ومقدار معامل الارتباط (r)، شكل (٢).

تكونت الشبكة العصبية الاصطناعية المقترحة، شكل (٣)، من ثلاث طبقات، واحدة للمدخلات بعدد ٥ عناصر حسابية هي: سلاح حفار، سلاح مطرحي، سلاح قرصي، السرعة الأمامية، والمحتوى الرطوبي للتربة. وطبقة للمخرجات بعدد ٢ عنصر حسابي هي: استهلاك الوقود (لتر/فدان) والطاقة اللازمة للحث (كيلو جول/فدان)، وطبقة مختلفة بعدد ١٦ عنصر حسابي.



شكل (٢): مكونات الشبكة العصبية الاصطناعية المقترحة والمتغيرات المتحكم في تدريبها كما يعرضها برنامج المحاكاة.



شكل (٣): معمارية الشبكة العصبية الاصطناعية المقترحة.

تم استخدام الدالة الحدية (tanh) في كل من طبقة المخرجات والطبقة المخفية كدالة تحويل وتم استخدام طريقة الانتشار الخلفي لتدريب الشبكة العصبية الاصطناعية المقترحة (التعليم الموجه) بمعدل تعليم قدره ٠.٠٩٨، وتم تدريب الشبكة بس ١٨ مشاهدة من بيانات نتائج سابقة، مامكغ (٢٠٠٢م) بعد أن رتب عشوائياً واستخدم نظام الترميز ١٠٠، لأنواع المحارث، جدول (١). والمحارث المستخدمة هي: محراث حفار، وقلاب مطرحي، وقلاب قرصي ذات عرض تشغيل ٢٠٠ و ٩٠ و ١١٢ سم على الترتيب. وهذه المحارث علفت مع جرار زراعي قدرته ٨٠ حصان وتعمل في تربة طينية طميية (clay loam) متغيرة المحتوى الرطوبي ٨، ١١، ١٤% على أساس جاف، وتعمل بثلاثة سرعات أمامية هي: ٥، ٧، ٩ كم/س عند عمق حرث ٢٥ سم.

جدول (١): البيانات المستخدمة في تدريب الشبكة العصبية الاصطناعية.

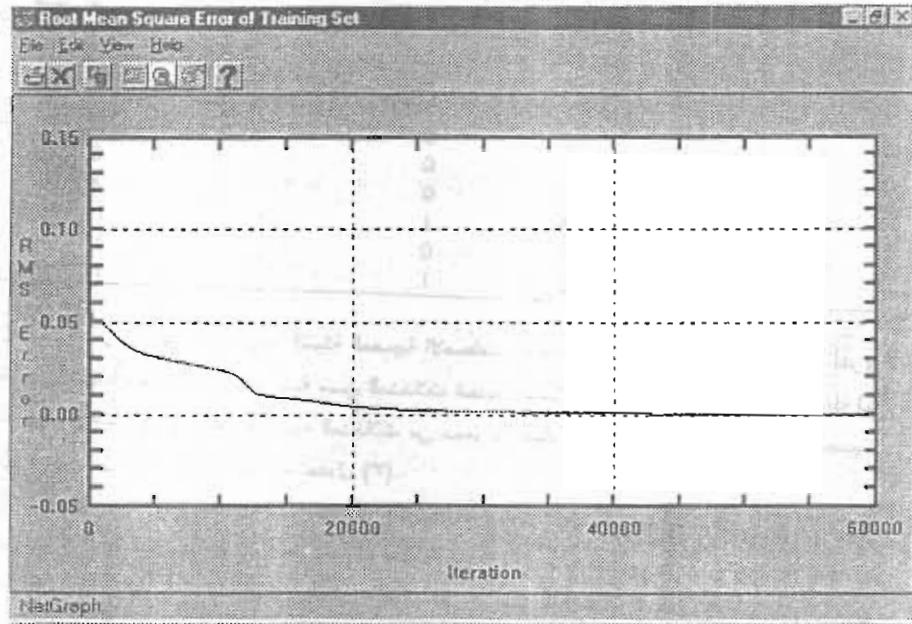
المدخلات					المخرجات	
سلاح	سلاح	سلاح	السرعة	المحتوى الرطوبي	استهلاك	الطاقة اللازمة
حفار	مطرحي	قرصي	الأمامية	للتربة	الوقود	للحرث
			كم/س	أساس جاف، %	لتر/فدان	ميغا جول/فدان
1	0	0	5.5	14	3.78	43.07
0	1	0	5.5	11	5.40	61.49
0	0	1	9.0	8	7.82	89.10
0	1	0	9.0	11	5.41	61.59
0	1	0	9.0	8	6.17	70.25
1	0	0	9.0	8	2.73	31.10
0	1	0	5.5	14	4.86	55.32
1	0	0	7.0	11	2.52	28.71
0	0	1	7.0	11	7.12	81.11
1	0	0	7.0	14	2.27	25.84
0	0	1	5.5	8	7.23	82.36
0	1	0	7.0	14	4.96	56.52
1	0	0	5.5	8	3.07	34.93
0	0	1	9.0	14	5.46	62.21
1	0	0	9.0	11	2.44	27.76
0	0	1	5.5	11	6.63	75.51
1	0	0	9.0	14	2.15	24.50
0	0	1	7.0	8	7.90	90.01

استخدم البرنامج الإحصائي (SPSS 9.0 (1998) لتنفيذ الارتداد الخطي للمتعدد لإيجاد استهلاك الوقود والطاقة اللازمة للحرث بنفس البيانات التي استخدمت في تدريب الشبكة العصبية الاصطناعية وكانت المعادلة المستخدمة كما يلي:

$$FC = \alpha_0 + \alpha_1 \times S + \alpha_2 \times M + \alpha_3 \times I \quad (2)$$

حيث FC = استهلاك الوقود، لتر/فدان أو الطاقة اللازمة للحرث، ميغا جول/فدان، S = السرعة الأمامية، كم/س، M = المحتوى الرطوبي للتربة، % على أساس جاف، I = معامل يعبر عن نوع المحراث، ويساوي ١ للمحراث الحفار، و ٢ للمحراث القلاب المطرحي و ٢.٥ للمحراث القلاب القرصي وتم استنباطه من نفس

البيانات وتقدر قيمته على أنه خارج نسبة متوسط استهلاك الوقود للمحركات المطلوب إلى متوسط استهلاك الوقود للمحركات الحفار،  $\alpha_0, \alpha_1, \alpha_2, \alpha_3$  = معاملات معادلة الارتداد الخطي. تم استخدام الشبكة العصبية الاصطناعية متعددة الطبقات ذات التغذية الأمامية لتنفيذ المحاكاة. وأثناء مرحلة تدريبها تم إجراء 60000 تكررة حتى وصلت قيمة الجذر التربيعي لمتوسط مربع الأخطاء (RMSE) إلى أقل قيمة لها 0.000246 ومعامل الارتباط (r) إلى أقصى قيمة له 0.9999 (شكل (2))، وهاتان القيمتان تدلان على أن الشبكة العصبية الاصطناعية المقترحة قد تدربت بشكل جيد وقادرة على التنبؤ. ويوضح شكل (4) تغير (RMSE) أثناء مرحلة تدريب الشبكة على الترتيب. ولاختبار أداء الشبكة العصبية المقترحة تم استخدام 9 مشاهدات جديدة لم يتم تعريضها لها من قبل.



شكل (4): منحنى التكرارات أثناء تدريب الشبكة العصبية الاصطناعية المقترحة.

#### 4. النتائج والمناقشات

عند تنفيذ المعادلة (2) على بيانات استهلاك الوقود والطاقة اللازمة للحرث تم الحصول على معاملات الارتداد الخطي المتعدد المبينة في جدول (2) ويتضح أن معامل التقدير ( $R^2$ ) لنموذج المعادلة يساوي 0.93 وهذا يعطي دقة كبيرة للمعادلة، كما يتضح أن معامل المحتوى الرطوبي للتربة بالسالب أي أن العلاقة بين المحتوى الرطوبي للتربة واستهلاك الوقود (لتر/فدان) علاقة عكسية ونفس النتيجة بالنسبة للطاقة اللازمة للحرث وهذه النتيجة متفقة مع ما توصل إليه (El-Ansary et al. 1995). ولاختبار معادلة الارتداد الخطي المتعدد تم استخدام 9 مشاهدات، جدول (3)، لم تستخدم في استنباط معاملات المعادلة (2).

جدول (٢): قيم معاملات معادلة الارتداد الخطي المتعدد.

المتغيرات	معاملات معادلة الارتداد الخطي				R <sup>2</sup>
	$\alpha_0$	$\alpha_1$	$\alpha_2$	$\alpha_3$	
استهلاك الوقود ، لتر/فدان	2.69	$-9.51 \times 10^{-2}$	-0.17	2.71	0.93
الطاقة اللازمة للحراثة، ميجا جول/فدان	30.63	-1.08	-1.98	30.82	0.93

جدول (٣): مدخلات اختبار معادلة الارتداد الخطي المتعدد والشبكة العصبية الاصطناعية المقترحة.

رقم المشاهدة	المحتوى الرطوبي للتربة للسرعة الأمامية سلاح قرصي سلاح مطرحي سلاح حفار				أساس جاف، %	كم/س
	0	1	0	1		
1	0	0	1	1	11	9.0
2	0	1	0	0	11	7.0
3	0	1	0	0	8	7.0
4	1	0	0	0	11	5.5
5	0	1	0	0	8	5.5
6	1	0	0	0	8	7.0
7	0	0	1	1	14	5.5
8	0	1	0	0	14	9.0
9	0	0	1	1	14	7.0

بمجرد أن ينتهي تدريب الشبكة العصبية الاصطناعية، فإنه يتم تخزينها ثم استدعاؤها مرة أخرى لاختبار أدائها بـ ٢٠ تمرير من مجموعة من المدخلات الجديدة أمامها للحصول على المخرجات المقابلة لها ومقارنتها مع المخرجات المشاهدة. وهذه المدخلات من مجموعة البيانات التي تدربت عليها الشبكة العصبية، ولكن لم يسبق أن تعرضت لها من قبل، جدول (٣).

نتائج أداء طريقتي الشبكة العصبية الاصطناعية والارتداد الخطي المتعدد عند التنبؤ باستهلاك الوقود والطاقة اللازمة للحراثة عند ظروف مختلفة من التشغيل موضحة في جدول (٤)، ومنه يتبين أن معامل التقدير (R<sup>2</sup>) بين استهلاك الوقود المقاس وقيمته التي تم تقديرها بالشبكة العصبية الاصطناعية يساوي ٠.٩٨. وهذه القيمة تدل على أن هناك ارتباط قوي بين القيم الفعلية والقيم المتنبأ بها بالشبكة العصبية الاصطناعية.


جدول (٤): معايير تقييم الشبكة العصبية الاصطناعية ومعادلة الارتداد الخطي المتعدد أثناء اختبارهما.

المعيار	الوحدة	الشبكة العصبية الاصطناعية	معادلة الارتداد الخطي المتعدد
RMSE	لتر/فدان	0.237	0.313
RMSE	ميجا جول/فدان	2.699	3.729
R <sup>2</sup>	---	0.98	0.96


وتوضح النتائج المعروضة في جدول (٤) أن الشبكة العصبية الاصطناعية تتفوق على طريقة الارتداد الخطي المتعدد في عملية التنبؤ حيث أن قيمة (RMSE) بين القيم الفعلية والقيم المتنبأ بها لاستهلاك الوقود والطاقة اللازمة للحراثة أقل.



يوضح شكل (٥) و (٦) العلاقة بين القيم المتنبأ بها والمقاسة لاستهلاك الوقود والطاقة اللازمة للحرث على الترتيب. ومن الأشكال نجد أن القيم المتنبأ بها لاستهلاك الوقود والطاقة اللازمة للحرث من الشبكة العصبية الاصطناعية (ANN) قريبة من القيم المقاسة بعكس القيم المتنبأ بها من معادلة الارتداد الخطي المتعدد (MLR) وهذا يدل على أن الشبكة العصبية الاصطناعية المقترحة قادرة على التنبؤ باستهلاك الوقود والطاقة اللازمة للحرث تحت مستويات المدخلات المذكورة وتكون أدق من طريقة الارتداد الخطي.



شكل (٥): العلاقة بين القيم المتنبأ بها بالشبكة العصبية الاصطناعية (ANN) والارتداد الخطي المتعدد (MLR) والمقاسة لاستهلاك الوقود.



شكل (٦): العلاقة بين القيم المتنبأ بها بالشبكة العصبية الاصطناعية (ANN) والارتداد الخطي المتعدد (MLR) والمقاسة للطاقة اللازمة للحرث.

٥. المراجع

- الجنوبي، ع. ع.، وهي م. ف. (١٩٩٨م): استهلاك الطاقة لمجموعة من نظم الحراثة والزراعة. م. اتحاد الجامعات العربية للدراسات والبحوث الزراعية، ٦(١): ٣٧-٤٨.
- المعشري، س. ر. (١٩٩٥م): مشروع تقدير استهلاك الطاقة المستخدمة لإنتاج المحاصيل في مصر. التقرير النهائي، مركز البحوث الزراعية، المشروع القوي للأبحاث الزراعية: ٥-٦.
- الموضي، م. ن. (١٩٩٨م): برنامج الخبرة. افتتاحية الممدد ١٥(١) من م. المصرية هـ.ز. ماسخ، ع. م. (٢٠٠٢م): العوامل المؤثرة على استهلاك الجرار الزراعي للوقود أثناء الحراثة. مقبول للنشر، مجلة اتحاد الجامعات العربية للدراسات والبحوث الزراعية.
- Altendorf, C.T.; R.L. Elliott; E.W. Stevens and M.L. Stone (1999): Development and validation of a neural network model for soil water content prediction with comparison to regression techniques. Trans. ASAE, 42 (3):691-699.
- El-Ansary, M.Y.; Z.A. El-Haddad and M.T.M. Tohamy (1995): Minimizing tillage power and cost required to achieve a proper seedbed preparation. Misr J. Ag. Eng., 12(1):3-14.
- Gomaa, A.E; A.E. Ahmed and M.A. Sabbah (1995): Simulation of tillage energy input for Egyptian soils. 3<sup>rd</sup> Conf. of Misr Society of Ag. Eng., 5-6 Oct., 1995:105-127.
- Alhamdan, A. M.; A. Al-Janobi; A. M Aboukarima and Kh. A. Ahmed (2001): Applications of neural networks in predicting rheological properties of milk-dibbs drink. Alex. J. of Agric. Res.,46(2):1-9.
- Hecht-Nielsen, R. (1990): Neurocomputing. Addison-Wesly Pub. Company, Inc.:21-41, 110-162.
- Al-Janobi, A.A.; A. M. Aboukarima and Kh. A. Ahmed (2001): Prediction of specific draft of different tillage implements using neural networks. Misr J. Ag. Eng., 18(3):669-714.
- Kepner, R.A.; R. Bainer and E.L. Barger (1987): Principles of farm machinery, 3<sup>rd</sup> ed. CBS Publishers & Distributors, India: 131.
- Kohzadi, N.; M.S Boyd; B. Kermanshahi and I. Kaastra (1996): A comparison of artificial neural network and time series models for forecasting commodity prices. Neurocomputing, 10 (2): 169-181.
- Langman, L. (1999): Application of artificial neural networks in agricultural engineering. The application of information technology in agriculture, Kazimierza, Poland, 22-23 April, 1998, Inzynieria-Rolnicza, 1999,1:7 : 153-158.

- Lykins, S. and D. Chance (1992): Comparing artificial neural networks and multiple regression for better predictability using correlation and absolute error statistics. Oklahoma Symp. on Artificial Intelligence, November 11-12, 1992, the Univ. of Tulsa, Tulsa, Oklahoma, USA:156-165.
- Mohamed, A.A.I.; M.E-S. M. Metwally and Kh. A.A. Khadr (1995): A study of some factors affecting the performance of chisel plow under Egyptian conditions. *Misr J. Ag. Eng.*, 12(4):895-911.
- Morad, M.M. and M.A. El-Shazly (1994): Effect of some operating parameters on rotary plow performance. *Misr J. Ag. Eng.*, 11(4): 1009-1020.
- Roush, W.B. and T.L. Cravener (1997): Artificial neural network prediction of Amino acid levels in feed ingredients. *Poultry Science*, 76: 721-727.
- El-Sayed, G.H. and R.M.M. El-Kilani (2002): Predicted vs. measured tractor fuel - consumption in soil-working operations. *Misr J. Ag. Eng.*, 19(1):268-284.
- El-Sheikha, M.A. (1989): A quick and effective method to prepare seed-bed for Egyptian farms. *Misr J. Ag. Eng.*, 6(3):213-223.
- SPSS for Windows , Release 9.0 (1998), Standard Version, SPSS Inc.
- Vesta Services, Inc. (2000): Qnet2000 Shareware, Vesta Services, Inc., 1001 Green Bay Rd, STE 196, Winnetka, IL 60093.

# *Development Of Agricultural - Engineering Technologies In The Arab and Islamic World.*

*The 10<sup>th</sup> Conference of the Misr Of Ag. Eng., 16-17 October, 2002 : 115-126*

## **USING NEURAL NETWORKS AND LINEAR REGRESSION FOR PREDICTING ENERGY REQUIREMENTS IN PLOWING**

**Mohamed N. El-Awady\*<sup>\*</sup>; Abdel Fadel G. El-Kabany\*\*<sup>\*\*</sup>  
Mohamed H.A. Kabeel\*\*\*<sup>\*\*\*</sup> and Abdulwahed M. Aboukarima\*\*\*\*<sup>\*\*\*\*</sup>**

In this research work, two methods were utilized to predict both fuel consumption and energy requirements during tillage process under different operation conditions. The first method was multiple linear regression (MLR) and the second one was artificial neural network (ANN). Data of three plows were obtained from (Mamkagh, 2002). The first is plow chisel, the second is moldboard and the third one is disk. These plows performed tillage on clay loam soil surface changing in moisture (8, 11 and 14 %, d.b). Three forward speeds were utilized namely: 5.5, 7.0 and 9.0 km/h. During executing the MLR to obtain the regression coefficients, factors were used as 1 for chisel, 2.5 for disk and 2 for moldboard. These factors are the ratios of the average of fuel consumption of selected plow to fuel consumption of chisel plow.

..tilayer feedforward network with the error backpropagation learning algorithm was used to build the ANN model. The ANN was trained and tested with: plow type (chisel, moldboard and disk), soil moisture and forward speed as input parameters and fuel consumption and energy requirements as output parameters. The training data were 18 observations.

The architecture of the ANN consisted of three layers, the first layer for inputs, the second was hidden layer with 16 processing elements, and the third layer for output. The hidden layer and the output layer had been (Tanh) transfer function. The learning rate was 0.098 and the best results were achieved at 60000 training runs, which gave minimum root mean squared error (RMSE) equals to 0.000246 during training process. The results during testing the ANN showed that the variation of observed and predicted fuel consumption and energy requirements was small and coefficient of determination ( $R^2$ ) and (RMSE) were 0.98 and 2.699 MJ/fed for energy requirements prediction, while these values of  $R^2$  and RMSE were 0.96 and 3.729 MJ/fed using MLR respectively. The study suggests that the ANN approach is very useful for predicting both fuel consumption (lit/fed) and energy requirements (MJ/fed) although the relationship between them and affecting variables is unseen.

---

\* Prof. Ent., Ag. Eng. Dept., Col. Ag., Ain Shams Univ.

\*\* Lecture, Ag. Eng. Dept., Col. Ag., Ain Shams Univ.

\*\*\* S. Res., Ag. Eng. Res. Inst., Dokki, Gizza.

\*\*\*\* Ass. Res., Ag. Eng. Res. Inst., Dokki, Gizza.