

النمذجة الطيفية العصبونية متعددة الأدلة/المراحل لدقة التنبؤ بإنتاجية القطن
تحت ظروف المناطق الجافة وشبه الجافة

أ.د. ناصر طرّاف إبراهيم

مدير بحوث، الهيئة العامة للاستشعار عن بعد، دمشق، سوريا.

dr.nasseribrahem@gmail.com



**Spectral neural modeling of multi-stage/indices data for accurate
prediction of cotton yield under arid and semi-arid conditions**

Nasser Tarraf Ibrahim

Director of Research, General Organization of Remote Sensing, Damascus, Syria.

dr.nasseribrahem@gmail.com



الملخص

حقق الذكاء الاصطناعي خطوة متقدمة في مجال برامج تقدير انتاجية المحاصيل الزراعية باستخدام تقانة الاستشعار عن بعد التي تسجل بيانات النمو طيفياً خلال جميع المراحل التطورية حتى الحصاد تحت ظروف كافة النطاقات الجغرافية. هدَفَ هذا البحث إلى تطبيق الذكاء الاصطناعي على بيانات استشعارية طيفية متعددة الأدلة/متعددة المراحل؛ لتقدير الإنتاج ثم التنبؤ بالانتاجية المحصولية من مراحل نمو مبكرة تحت تأثير مستويات مرحلية من إجهادي التزود المائي والغذائي لمحصول القطن تحت ظروف زراعته في المناطق الجافة وشبه الجافة، وكذلك من أجل تحديد أفضل النماذج التنبؤية العصبونية ذات عدد بيانات أقل لأدلة طيفية مدخلة وبمراحل نمو نوعية محددة التي تعطي أعلى دقة تنبؤ بالانتاجية المحصولية. تم تقدير وتنبؤ الانتاجية وفق نماذج عصبونية ثلاث: الأول؛ هو النموذج العصبوني التقديرى/الشامل والذي يُقدر الإنتاجية اعتماداً على 231 عامل لبيانات كافة الأدلة الطيفية (21 دليل طيفي) خلال جميع مراحل النمو (البالغ عددها 11 مرحلة)، الثاني؛ النموذج العصبوني التنبؤي/الشامل والذي يتنبأ بالانتاجية اعتماداً على 63 عامل لبيانات كافة الأدلة الطيفية (21 دليل طيفي) من مراحل نمو مبكرة (المراحل الست الأولى)، الثالث؛ النموذج العصبوني التنبؤي/المختصر والذي يتنبأ بالانتاجية اعتماداً على 30 عامل لبيانات عدد من الأدلة الطيفية (17 دليل طيفي محدد) من بعض مراحل النمو المبكرة (المراحل الست الأولى). بلغ متوسط الانتاجية المقدره بالنماذج العصبونية الثلاث: 167.1، 168.4 و 169.3 كغ/1000م² على التوالي، مقابل الانتاجية الفعلية 168.4 كغ/1000م² لمحصول القطن (كمتوسط تحت كافة ظروف الاجهاد). لقد أعطى النموذج الطيفي التنبؤي المصمم بالذكاء الصناعي وفق عدد معين من الأدلة الطيفية النوعية وبمراحل نمو محددة (النموذج العصبوني التنبؤي/المختصر) دقة عالية في التنبؤ بالانتاجية المحصولية مقارنة بكل من النماذج التقديرية والتنبؤية الشاملة تحت تأثير عوامل النمو والإجهادات المائية و/أو الغذائية مقابل الانتاجية المسجلة حقلياً في ظروف المناطق الجافة وشبه الجافة.

الكلمات المفتاحية: الذكاء الصناعي، مراحل النمو، الأدلة الطيفية، التنبؤ بالانتاجية، القطن.

Abstract:

Artificial intelligence has achieved an advanced step in the field of agricultural crop productivity estimation programs using remote sensing technology that records growth data spectrally during all developmental stages until harvest under conditions of all geographical ranges. This research aimed to apply artificial intelligence to multi-indices/multi-stage spectral sensor data. To estimate production and then predict crop productivity from early growth stages under the influence levels of water and nutrient supply stress for the cotton crop under growing conditions in arid and semi-arid areas, as well as in order to determine the best predictive neural models with a smaller number of data for input spectral indices and specific growth stages that It gives the highest accuracy of forecasting crop productivity. Productivity was estimated and predicted according to three neural models: the first: the estimated/comprehensive model: which estimates productivity based on 231 factors of data for all spectral indices (21 indices) during all stages of development (11 stages), the second: the predictive/comprehensive model: which predicts productivity based on 63 factors for the data of all spectral indices /21/ from (first 6 stages of 11). Third: The predictive/abbreviated model: which predicts productivity based on 30 factors for the data of a number of spectral indices /17/ from early stages (first 6 stages of 11). The average productivity estimated by the three neural models was: 167.1, 168.4, and 169.3 kg/1000m², respectively, compared to the actual productivity of 168.4 kg/1000m² for the cotton crop (as an average under all stress conditions). The predictive spectral model designed with artificial intelligence according to a certain number of specific spectral indices and with specific growth stages (the predictive/abbreviated model) gave high accuracy in predicting crop productivity compared to both the estimated and comprehensive predictive models under the influence of growth factors and water and/or nutritional stresses versus the recorded productivity. Field conditions in dry and semi-arid areas.

Keywords: Artificial Intelligence, Growth Stages, Spectral Indices, Productivity Prediction, Cotton.

1. مقدمة

تقوم برامج تقدير إنتاجية المحاصيل باستخدام تكنولوجيا الاستشعار عن بعد في الأساس على مراقبة النمو النباتي طيفياً خلال حياة المحصول ورصد حركية الشواهد الفسيولوجية المحصولية خلال أهم مراحل النمو المؤدية في مجموعها إلى الإنتاجية النهائية؛ وأن الانعكاسات والدلائل الطيفية تسجل تلك الحركية وتطور هاتيك الشواهد الفسيولوجية خلال حياة المحصول الى صورة الانتاجية الاقتصادية وبالتالي تُمكن من تقدير والتنبؤ بالإنتاجية النهائية من مراحل النمو المبكرة باستخدام تكنولوجيا الاستشعار عن بعد. تؤدي الظروف المناخية المتباينة والمتطلبات البيئية المتغيرة خلال مراحل النمو وكذلك اختلاف الترب فيما بينها بمستوى التزود الغذائي الى اختلاف انتاجية المحاصيل المختلفة فيما بينها وصولاً الى الانتاجية الكامنة القصوى لكل نوع محصولي، وبالتالي فان دقة تقدير الانتاجية المحصولية طيفياً تعتمد على دقة النماذج المستخدمة اعتباراً من اعتمادها على مرحلة نمو نباتي واحدة الى النماذج التي تشمل أهم مراحل النمو المؤثرة في مركب الانتاجية تحت تأثير عوامل تكوينها المتغيرة مع الزمن تحت ظروف المناخ والتربة. تؤسس النمذجة الطيفية البرمجية لعمليات تؤمن دقة تقدير الانتاجية والمبنية على معالجة كميات كبيرة وغنية من البيانات الطيفية المتعددة التي تشمل مراحل كثيرة خلال مراحل النمو تحت تأثير عوامل النمو البيئية المحيطة وذلك بإدخال طرق علمية ونماذج رياضية ولغات برمجية.

تم تقدير مساحة ونتاج محصول القطن من بيانات الصور الفضائية ASTER متعددة الأطياف/مرحلية النمو وفق علاقات طيفية مصممة حقلياً ثم مطبقة فضائياً على أراضي من محافظة الرقة / سوريا (إبراهيم، 2015). قدر (Xu, et al. 2021) انتاج محصول القطن باستخدام البيانات الاستشعارية الملتقطة بواسطة الطيران المسير والمعالجة بأسلوب الشبكات العصبونية بلغة التعلم الآلي، حيث بلغت قيمة معامل التحديد (R^2) للإنتاج 0.853 في وحدة مساحة 0.81 م². في مقالة استعرض فيها (Ennouri, et al. 2021) بشكل موسع؛ مساهمة الذكاء الاصطناعي والاستشعار عن بعد في زيادة انتاجية النظم الزراعية، بدء من التعرف على النبات وحالته حتى الحصاد والانتاج. وفي مقالة أخرى استعرض فيها (Bharadiya, et al. 2023) فعالية التنبؤ بإنتاجية المحاصيل باستخدام بيانات الاستشعار عن بعد ومنهجية التعلم الآلي، وخاصة فيما يتعلق بالسياسة الغذائية، والسعرية، الاستيراد والتصدير، والتخزين للحد قدر الإمكان من الآثار الاجتماعية والاقتصادية لخسارة المحاصيل الناجمة عن كارثة طبيعية، مثل الفيضانات أو الجفاف، وتنظيم المساعدات الغذائية الإنسانية. طور باحثوا AKADEMIYA2063، منصة مراقبة الزراعة الأفريقية (AAgWa)(Africa Agriculture Watch) والتي تم إطلاقها عام 2021 على شبكة الإنترنت،

حيث تستخدم تقنيات التعلم الآلي المتطورة وبيانات الاستشعار عن بعد لتقدير الزراعات التنبؤ بإنتاجية العديد من المحاصيل في جميع أنحاء أفريقيا من أجل دعم إدارة الأزمات ورصدها وبالتالي التخفيف من أثارها في المجتمعات المحلية. قام (Klompenburga, et al. 2020) بمراجعة منهجية لأدبيات 567 دراسة ذات صلة بالتنبؤ بإنتاجية المحاصيل باستخدام التعلم الآلي، وقد توصل الى أن خوارزميات التعلم العميق الأكثر تطبيقاً هي على التوالي: Convolutional Neural Networks (CNN)، Long-Short Term Memory (LSTM)، Deep Neural Networks (DNN). قارن (Kale, et al. 2023) عدة خوارزميات التعلم العميق للشبكات العصبونية في تقدير غلة المحاصيل من بيانات صور الأقمار الاصطناعية مع المنهجية المقترحة التي تعتمد إنشاء نظام شامل للتنبؤ بالعائد الزراعي يربط البيانات الأولية بإنتاجية المحاصيل المتوقعة من خلال دمج أسلوبيين للتعلم العميق وفق خوارزميات ذكاء صناعي حتى توصل الى أفضل منهجية لتقدير الانتاج بدقة 97%. كما اختبر (Ilyas, et al. 2023) فعالية التقدير الآلي لإنتاجية المحاصيل باستخدام تقانات الذكاء الاصطناعي والاستشعار عن بعد على بيانات محاصيل القمح والذرة والأرز وقصب السكر بين عامي 2017 و2021.

يُعتبر محصول القطن من أهم المحاصيل الصناعية الصيفية في دعم الاقتصاد الوطني وذلك بتأمين المادة الخام للصناعات الوطنية في سوريا. يُزرع هذا المحصول صيفاً وبمساحات كبيرة مما يجعل استهلاكه كبيراً للماء خلال مراحل النمو ذو الموسم النمو الطويل، ويضاف أيضاً الى العامل المائي العامل الغذائي المتمثل بمستوى الأزوت كعنصر غذائي أساس يحقق كفاءة أعلى في قيم الانتاج.

هدفَ هذا البحث إلى: (1) تطبيق النمذجة العصبونية بمدخلات متعددة الأطياف/متعددة المراحل لتقدير والتنبؤ بإنتاجية محصول القطن من مراحل مبكرة ومتقدمة للنمو تحت ظروف الإجهادات المائية والغذائية. (2) اختبار النماذج العصبونية التنبؤية لأي من الأدلة والمراحل في دقة تقدير الإنتاجية تحت ظروف المناطق الجافة وشبه الجافة.

2. المواد والمنهجية

2-1- مواد البحث

تم زراعة القطن كمحصول صيفي تحت تأثير إجهادي كل من التزود المائي وفق مستويين، والتسميد الأزوتي وفق مستويين، كذلك خلال مرحلتي نمو مبكر و/أو

متأخر تحت ظروف المناطق الجافة وشبه الجافة، وبالتالي تكون عوامل التجربة كما يلي:

- الإجهاد المائي: يتمثل في (1) تأخير الري خلال مرحلة نمو مبكر، (2) تأخير الري خلال مرحلة نمو متقدم.
- الإجهاد الغذائي: يتمثل في (1) تزويد التسميد الأزوتي في مرحلة نمو مبكر، (2) تزويد التسميد الأزوتي في مرحلة نمو متقدم.
- المراحل: تطبيق المعاملة في: (1) مرحلة نمو مبكر (2) مرحلة نمو متقدم (3) في كلا المرحلتين.
- الشاهد: يعطى كافة المتطلبات الموصى بها زراعياً لنمو المحصول وإنتاجه.

2-2- التصميم التجريبي الاحصائي

تم تصميم التجربة وفق التصميم الاحصائي للقطع المنشقة مرة واحدة بثلاث مكررات لعوامل التجربة المذكورة سابقاً (مع العلم أنه يُسجل أربع قراءات طيفية في كل مكرر).

2-3- منطقة الدراسة

تقع منطقة الدراسة في منطقة الصبورة بمحافظة ريف دمشق، سوريا. حيث تتصف تلك المنطقة بصيف حار وشتاء بارد، وبمعدل هطول مطري سنوي 200 ملم.

2-4- البيانات

2-4-1- البيانات الطيفية

تم تسجيل القراءات الراديومترية بواسطة جهاز قياس الطيف سيكتروراديومتر المحمول حقلياً (FieldSpec[®]HandHeld2TM)، الذي يسجل الانعكاسات الطيفية بأطوال موجية من 325 إلى 1075 نانومتر بفاصل طيفي 1 نانومتر وخلال جميع مراحل النمو المحددة.

حساب الأدلة الطيفية

تجميع البيانات فائقة الدقة الطيفية في 21 قناة لتقابل قنوات الأدلة الطيفية التي ستطبق في البحث. حيث تم خلال جميع مراحل النمو حساب كل الأدلة الطيفية وفق

المعادلات المذكورة بجانب كل دليل (الجدول 1). حيث يوضح الجدول (1) أشهر الأدلة الطيفية النباتية الموجودة والبالغ عددها 28 دليل طيفي نباتي مع المجالات الطيفية التي بُني عليها كل دليل وبيان مدى القيم الناتجة والمرجع المعتمد لكل منها. لقد استخدم 21 دليل طيفي لتشمل جميع المجاميع المصنفة في مراقبة الصفات الفسيولوجية النباتية والموضحة بشكل مفصل جانب كل دليل باستخدام نموذج مصمم تحت بيئة Excel2010.

جدول 1. توصيف ومعادلات الأدلة الطيفية النباتية

N	Category	Index	Equation	References
1	Broadband Greenness	Normalized Difference Vegetation Index	$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}}$	Rouse et al. 1973 Tucker 1979 Jackson et al. 1983 Sellers 1985
2		Simple Ratio Index	$SR = \frac{\rho_{NIR}}{\rho_{RED}}$	Rouse et al. 1973 Tucker 1979 Sellers 1985
3		Enhanced Vegetation Index	$EVI = 2.5 \left(\frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + 6\rho_{RED} - 7.5\rho_{BLUE} + 1} \right)$	Huete et al. 1997
4		Atmospherically Resistant Vegetation Index	$ARVI = \frac{\rho_{NIR} - (2\rho_{RED} - \rho_{BLUE})}{\rho_{NIR} + (2\rho_{RED} - \rho_{BLUE})}$	Kaufman and Tanre 1996
5		Sum Green Index	The SG index is the mean of reflectance across the 500 nm to 600 nm portion of the spectrum.	Gamon and Surfus 1999
6	Narrowband Greenness	Red Edge Normalized Difference Vegetation Index	$NDVI_{705} = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705}}$	Gitelson and Merzlyak 1994 Sims and Gamon 2002
7		Modified Red Edge Simple Ratio Index	$mSR_{705} = \frac{\rho_{750} - \rho_{445}}{\rho_{705} - \rho_{445}}$	Sims and Gamon 2002 Datt 1999
8		Modified Red Edge Normalized Difference Vegetation Index	$mNDVI_{705} = \frac{\rho_{750} - \rho_{705}}{\rho_{750} + \rho_{705} - 2\rho_{445}}$	Datt 1999 Sims and Gamon 2002
9		Vogelmann Red Edge Index 1	$VOG1 = \frac{\rho_{740}}{\rho_{720}}$	Vogelmann et al. 1993
10	Vogelmann Red Edge Index 2	$VOG2 = \frac{\rho_{734} - \rho_{747}}{\rho_{715} + \rho_{726}}$	Vogelmann et al. 1993.	

11		Vogelmann Red Edge Index 3	$VOG3 = \frac{\rho_{734} - \rho_{747}}{\rho_{715} + \rho_{720}}$	Vogelmann et al. 1993.
12		Red Edge Position Index	Results are reported as the wavelength of the maximum derivative of reflectance in the vegetation red edge region of the spectrum in microns from 0.69 microns to 0.74 microns.	Curran et al. 1995.
13	Light Use Efficiency	Photochemical Reflectance Index	$PRI = \frac{\rho_{531} - \rho_{570}}{\rho_{531} + \rho_{570}}$	Gamon et al. 1992. Gamon et al. 1997.
14		Structure Insensitive Pigment Index	$SIPI = \frac{\rho_{800} - \rho_{445}}{\rho_{800} - \rho_{680}}$	Penuelas et al. 1995.
15		Red Green Ratio Index	Applications include plant growth cycle (phenology) studies, canopy stress detection, and crop yield prediction. Results are reported as the mean of all bands in the red range divided by the mean of all bands in the green range.	Gamon and Surfus 1999
17	Canopy Nitrogen	Normalized Difference Nitrogen Index	$NDNI = \frac{\log(1/\rho_{1510}) - \log(1/\rho_{1680})}{\log(1/\rho_{1510}) + \log(1/\rho_{1680})}$	Serrano et al. 2002 Fourty et al. 1996
18	Dry or Senescent Carbon	Normalized Difference Lignin Index	$NDLI = \frac{\log(1/\rho_{1754}) - \log(1/\rho_{1680})}{\log(1/\rho_{1754}) + \log(1/\rho_{1680})}$	Serrano et al. 2002 Fourty et al. 1996 Melillo et al. 1982
19		Cellulose Absorption Index	$CAI = 0.5 \left(\frac{\rho_{2000} - \rho_{2200}}{\rho_{2100}} \right)$	Daughtry. 2001 Daughtry et al. 2004
20		Plant Senescence Reflectance Index	$PSRI = \frac{\rho_{680} - \rho_{500}}{\rho_{750}}$	Merzlyak et al. 1999
21	Leaf Pigments	Carotenoid Reflectance Index 1	$CRI1 = \left(\frac{1}{\rho_{510}} \right) - \left(\frac{1}{\rho_{550}} \right)$	Gitelson et al. 2002
22		Carotenoid Reflectance Index 2	$CRI2 = \left(\frac{1}{\rho_{510}} \right) - \left(\frac{1}{\rho_{700}} \right)$	Gitelson et al. 2002
23		Anthocyanin Reflectance Index 1	$ARI1 = \left(\frac{1}{\rho_{550}} \right) - \left(\frac{1}{\rho_{700}} \right)$	Gitelson et al. 2001
24		Anthocyanin Reflectance Index 2	$ARI2 = \rho_{800} \left[\left(\frac{1}{\rho_{550}} \right) - \left(\frac{1}{\rho_{700}} \right) \right]$	Gitelson et al. 2001
25	Canopy Water Content	Water Band Index	$WBI = \frac{\rho_{900}}{\rho_{970}}$	Penuelas et al. 1995 Champagne et al. 2001
26		Normalized Difference Water Index	$NDWI = \frac{\rho_{857} - \rho_{1241}}{\rho_{857} + \rho_{1241}}$	Gao 1995

27	Moisture Stress Index	$MSI = \frac{P_{1599}}{P_{819}}$	Hunt and Rock 1989 Ceccato et al. 2001
28	Normalized Difference Infrared Index	$NDII = \frac{P_{819} - P_{1649}}{P_{819} + P_{1649}}$	Hardisky et al. 1983 Jackson et al. 2004

2-4-2- البيانات المحصولية

تم وزن الانتاجية المحصولية في وحدة المساحة المزروعة لكل قطعة تجريبية عند النضج والحصاد.

2-5- البرمجيات

تم تنفيذ المنهجية باستخدام برامج:

- برنامج تسجيل القراءات الطيفية، المزود به جهاز قياس الطيف (RS³).
- برنامج عرض وتحليل وتصدير القراءات الراديومترية (ViewSpecPro).
- برنامج R للبرمجة والتحليل الاحصائي.
- برنامج التحليل الإحصائي SPSS
- برنامج Excel2010.

3. النتائج

تم تقدير وتنبؤ الانتاجية المحصولية بنماذج الشبكات العصبونية بثلاث صيغ هي النموذج العصبوني التقديري/الشامل، النموذج العصبوني التنبؤي/الشامل والنموذج العصبوني التنبؤي/المختصر، وذلك من أجل اختبار النموذج العصبوني التنبؤي/المختصر والمبني على مراحل النمو المبكرة فقط بقيمتها الطيفية وفق أدلة طيفية معينة للتنبؤ بكمية الإنتاج عند الجني ومن ثم اختباره مع النموذجين الشاملين الآخرين مقابل الإنتاجية الحقلية المحققة عند الجني. ومن الجدير بالذكر أنه قد تم اختيار جميع هذه الأدلة الطيفية (والبالغ عددها 21 دليل) في عمليات النمذجة نظراً لطبيعة اختصاص كل منها في تسجيل صفة نباتية ما ولتتكامل جميعاً في تسجيل جميع الصفات الخضرية والمائية والفسولوجية النباتية تحت كافة الظروف التي يمر

بها النبات، وفق تخصص كل منها في تسجيل قيمة كل صفة والموضحة جميعاً في الجدول (1).

لقد تم في كل صيغة نموذج بيان ما يلي: أ/ حالة المعالجة العصبونية لعدد مدخلات بناء النموذج وتلك التي تم الاختبار بها مع نسبة كل منها، ب/ هيكلية النموذج العصبوني وبه بيان أهمية مساهمة كل مدخل للوصول الى الانتاجية، ج/ مخطط بياني لقيم الانتاجية المقدرة وفق كل نموذج عصبوني مقابل المسجل حقلياً، د/ مخطط بياني لمقدار الخطأ للقيم المقدرة بالنموذج الطيفي العصبوني مقابل القيم الحقلية، هـ/ مخطط بياني لأخطاء كل نموذج، و/ مخطط بياني للأهمية النسبية للمتغيرات المرحلية المدخلة في النموذج العصبوني لتقدير الانتاجية.

3-1- النموذج العصبوني التقديري/الشامل لتقدير إنتاجية القطن

يقوم هذا النموذج العصبوني التقديري/الشامل بتقدير (وليس تنبؤ) انتاج القطن عند الجني اعتماداً على قيم الأدلة الطيفية النباتية المسجلة خلال جميع مراحل النمو، حيث بلغ عدد العوامل المدخلة في النموذج العصبوني التقدير/الشامل 231 عامل ناتجة عن بيانات 11 مرحلة نمو لقيم الأدلة الطيفية 21 التالية:

SG	ARVI	EVI	SR	NDWI	NDGI	NDVI
REP	PRI	VOG2	VOG1	mNDVI705	mSR705	NDVI705
WBI	ARI2	ARI1	SRI2	SRI1	RSRI	SIPI

يُلخّص الجدول (2) حالة المعالجة العصبونية لعدد مدخلات بناء النموذج العصبوني التقديري/الشامل وتلك التي تم الاختبار بها مع نسبة كل منها. بينما يبين الجدول (3) ملخص أخطاء المعالجة لذلك النموذج، على أن الشكلين (1 و 2) يوضحان قيم الانتاجية المقدرة وكذلك قيم الخطأ وفق النموذج العصبوني التقديري/الشامل مقابل المسجلة لمحصول القطن، على التوالي. أما الجدول (4) يبين الأهمية النسبية (%) لقيم النموذج العصبوني التقديري/الشامل خلال كل مرحلة نمو ولكل دليل طيفي، على أن يوضح الشكل (3) الأهمية النسبية لكل مرحلة نمو في

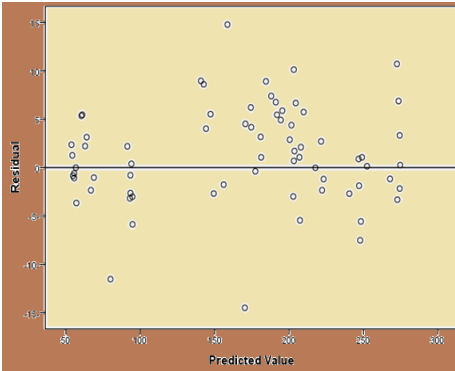
مساهمة تأثيرها بقيم كل دليل نباتي وبشكل مرتب حسب الأهمية من الأعلى الى الأدنى.

جدول 3، ملخص أخطاء النموذج العصبوني التقدير/الشامل

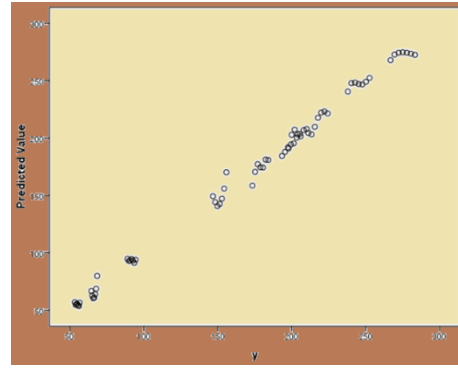
Model Summary		Value
Training	Sum of Squares Error	0.101
	Relative Error	0.004
Testing	Sum of Squares Error	0.067
	Relative Error	0.009

جدول 2، ملخص حالة المعالجة للنموذج العصبوني التقدير/الشامل

		N	Percent
Sample	Training	160	70%
	Testing	71	30%
Valid		231	100%
Excluded		0	
Total		231	



شكل 2، قيم الخطأ للنموذج العصبوني التقدير/الشامل في تقدير الانتاجية



شكل 1، قيم الانتاجية المقدرة وفق النموذج العصبوني التقدير/الشامل مقابل المسجلة لمحصول القطن

جدول 4، الأهمية النسبية (%) في النموذج العصبوني التقدير/الشامل لقيم كل دليل طيفي وفي كل مرحلة نمو.

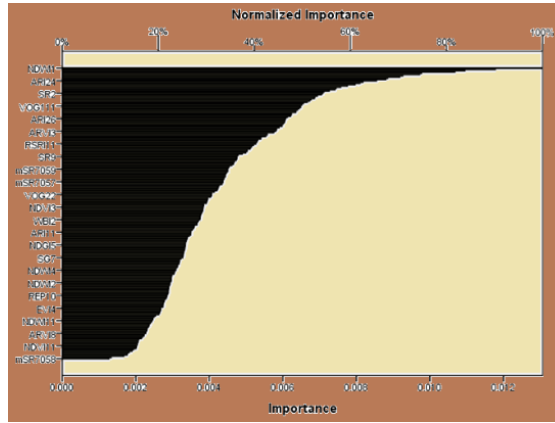
SN	Independent Variable	Normalized Importance	SN	Normalized Importance	Independent Variable	SN	Independent Variable	Normalized Importance
1	NDVI1	32.7%	81	NDVI7054	24.4%	161	SIP17	18.9%
2	NDVI2	34.2%	82	NDVI7055	20.3%	162	SIP18	27.5%
3	NDVI3	29.4%	83	NDVI7056	22.6%	163	SIP19	31.7%
4	NDVI4	22.8%	84	NDVI7057	48.6%	164	SIP110	30.1%

5	NDVI5	21.2%	85	NDVI7058	40.4%	165	SIPI11	58.0%
6	NDVI6	22.4%	86	NDVI7059	24.0%	166	RSRI1	13.6%
7	NDVI7	81.7%	87	NDVI70510	21.0%	167	RSRI2	62.0%
8	NDVI8	44.0%	88	NDVI70511	22.7%	168	RSRI3	18.1%
9	NDVI9	26.8%	89	mSR7051	34.0%	169	RSRI4	36.2%
10	NDVI10	25.5%	90	mSR7052	41.3%	170	RSRI5	15.8%
11	NDVI11	15.5%	91	mSR7053	20.1%	171	RSRI6	28.9%
12	NDGI1	46.4%	92	mSR7054	45.8%	172	RSRI7	49.9%
13	NDGI2	28.8%	93	mSR7055	23.3%	173	RSRI8	12.8%
14	NDGI3	26.4%	94	mSR7056	35.6%	174	RSRI9	22.1%
15	NDGI4	21.8%	95	mSR7057	33.5%	175	RSRI10	30.0%
16	NDGI5	25.6%	96	mSR7058	9.7%	176	RSRI11	40.3%
17	NDGI6	33.7%	97	mSR7059	34.5%	177	SRI11	22.1%
18	NDGI7	15.6%	98	mSR70510	57.0%	178	SRI12	44.7%
19	NDGI8	23.4%	99	mSR70511	16.7%	179	SRI13	31.1%
20	NDGI9	45.8%	100	mNDVI7051	24.3%	180	SRI14	14.8%
21	NDGI10	27.0%	101	mNDVI7052	22.7%	181	SRI15	23.2%
22	NDGI11	32.4%	102	mNDVI7053	62.6%	182	SRI16	17.7%
23	NDWI1	100.0%	103	mNDVI7054	36.6%	183	SRI17	13.5%
24	NDWI2	22.4%	104	mNDVI7055	28.7%	184	SRI18	83.8%
25	NDWI3	33.9%	105	mNDVI7056	40.8%	185	SRI19	55.6%
26	NDWI4	23.7%	106	mNDVI7057	29.3%	186	SRI110	25.9%
27	NDWI5	34.6%	107	mNDVI7058	36.3%	187	SRI111	14.5%
28	NDWI6	32.3%	108	mNDVI7059	22.2%	188	SRI21	47.7%
29	NDWI7	49.0%	109	mNDVI70510	15.3%	189	SRI22	26.1%
30	NDWI8	21.7%	110	mNDVI70511	24.3%	190	SRI23	20.5%
31	NDWI9	67.8%	111	VOG11	30.3%	191	SRI24	51.8%
32	NDWI10	53.1%	112	VOG12	74.4%	192	SRI25	46.0%
33	NDWI11	18.7%	113	VOG13	21.3%	193	SRI26	27.3%
34	SR1	21.1%	114	VOG14	46.3%	194	SRI27	31.1%
35	SR2	54.2%	115	VOG15	21.0%	195	SRI28	29.5%
36	SR3	10.2%	116	VOG16	39.1%	196	SRI29	36.4%
37	SR4	17.7%	117	VOG17	30.3%	197	SRI210	20.5%

38	SR5	49.6%	11 8	VOG18	29.3%	19 8	SRI211	18.3%
39	SR6	21.5%	11 9	VOG19	26.0%	19 9	ARI11	26.8%
40	SR7	22.1%	12 0	VOG110	22.8%	20 0	ARI12	34.4%
41	SR8	25.1%	12 1	VOG111	49.6%	20 1	ARI13	38.2%
42	SR9	36.4%	12 2	VOG21	17.0%	20 2	ARI14	34.8%
43	SR10	42.7%	12 3	VOG22	31.1%	20 3	ARI15	47.5%
44	SR11	25.5%	12 4	VOG23	22.1%	20 4	ARI16	39.9%
45	EVI1	48.7%	12 5	VOG24	37.5%	20 5	ARI17	20.3%
46	EVI2	25.7%	12 6	VOG25	22.4%	20 6	ARI18	24.4%
47	EVI3	28.4%	12 7	VOG26	30.9%	20 7	ARI19	45.2%
48	EVI4	20.5%	12 8	VOG27	15.4%	20 8	ARI110	15.9%
49	EVI5	17.0%	12 9	VOG28	15.6%	20 9	ARI111	51.0%
50	EVI6	41.4%	13 0	VOG29	25.2%	21 0	ARI21	59.4%
51	EVI7	13.9%	13 1	VOG210	22.7%	21 1	ARI22	32.5%
52	EVI8	18.9%	13 2	VOG211	74.8%	21 2	ARI23	35.7%
53	EVI9	49.3%	13 3	PRI1	33.6%	21 3	ARI24	65.4%
54	EVI10	27.5%	13 4	PRI2	15.8%	21 4	ARI25	22.0%
55	EVI11	30.2%	13 5	PRI3	28.7%	21 5	ARI26	46.5%
56	ARVI1	33.9%	13 6	PRI4	19.2%	21 6	ARI27	16.5%
57	ARVI2	38.5%	13 7	PRI5	33.2%	21 7	ARI28	24.0%
58	ARVI3	44.4%	13 8	PRI6	25.6%	21 8	ARI29	17.6%
59	ARVI4	26.7%	13 9	PRI7	40.6%	21 9	ARI210	29.4%
60	ARVI5	24.7%	14 0	PRI8	54.5%	22 0	ARI211	26.8%
61	ARVI6	32.2%	14 1	PRI9	23.9%	22 1	WBI1	70.3%
62	ARVI7	17.4%	14 2	PRI10	29.2%	22 2	WBI2	28.6%
63	ARVI8	17.4%	14 3	PRI11	38.5%	22 3	WBI3	29.0%
64	ARVI9	44.6%	14 4	REP1	29.1%	22 4	WBI4	21.0%
65	ARVI10	28.1%	14 5	REP2	25.3%	22 5	WBI5	28.2%
66	ARVI11	25.7%	14 6	REP3	25.2%	22 6	WBI6	54.0%
67	SG1	67.3%	14 7	REP4	42.6%	22 7	WBI7	35.9%
68	SG2	42.3%	14 8	REP5	33.5%	22 8	WBI8	51.5%
69	SG3	61.0%	14 9	REP6	52.5%	22 9	WBI9	46.3%
70	SG4	18.1%	15 0	REP7	39.5%	23 0	WBI10	35.3%

النمذجة الطيفية العصبونية متعددة الأدلة/المراحل لدقة التنبؤ....

71	SG5	19.5%	15	REP8	18.6%	23	WBI11	46.9%
72	SG6	33.4%	15	REP9	47.7%	1		
73	SG7	25.1%	15	REP10	21.8%			
74	SG8	90.2%	15	REP11	28.1%			
75	SG9	52.6%	15	SIP1	39.2%			
76	SG10	70.9%	15	SIP2	22.1%			
77	SG11	23.7%	15	SIP3	25.8%			
78	NDVI7051	25.5%	15	SIP4	17.9%			
79	NDVI7052	34.5%	15	SIP5	56.8%			
80	NDVI7053	25.3%	16	SIP6	50.2%			



شكل 3، الأهمية النسبية (%) لكل مرحلة نمو بقيم كل دليل نباتي (بشكل مرتب) في أداء النموذج العصبوني التقديري/الشامل

2-3- النموذج العصبوني التنبؤي/الشامل للتنبؤ بإنتاجية القطن


يقوم هذا النموذج العصبوني التنبؤي/الشامل على التنبؤ (وليس تقدير) من مراحل نمو مبكرة لنمو القطن بكمية الانتاج عند الجني اعتماداً على قيم الأدلة الطيفية النباتية المسجلة خلال فقط خلال مراحل النمو المبكرة (وهي الست مراحل الأولى من عمر النبات)، حيث بلغ عدد العوامل المدخلة في النموذج العصبوني التنبؤي/الشامل 63 عامل ناتجة عن بيانات 6 مرحلة نمو لقيم الأدلة الطيفية 21 السابقة الذكر.

يُلخّص الجدول (5) حالة المعالجة العصبونية لعدد مدخلات بناء النموذج العصبوني التنبؤي/الشامل وتلك التي تم الاختبار بها مع نسبة كل منها. بينما يبين الجدول (6) ملخص أخطاء المعالجة لذلك النموذج، على أن الشكلين (4 و 5) يوضحان قيم الانتاجية المقدرة وكذلك قيم الخطأ وفق النموذج العصبوني التنبؤي/الشامل مقابل المسجلة لمحصول القطن، على التوالي. أما الجدول (7) يبين الأهمية النسبية (%) لقيم النموذج العصبوني التنبؤي/الشامل خلال كل مرحلة نمو ولكل دليل طيفي، على أن يوضح الشكل (6) الأهمية النسبية لكل مرحلة نمو في مساهمة تأثيرها بقيم كل دليل نباتي وبشكل مرتب حسب الأهمية من الأعلى الى الأدنى.


جدول 5، ملخص حالة المعالجة للنموذج العصبوني التنبؤي/الشامل

جدول 6، ملخص أخطاء النموذج العصبوني التنبؤي/الشامل

Model Summary		Value			N	Percent
Training	Sum of Squares Error	0.028	Sample	Training	44	70%
	Relative Error	0.001		Testing	19	30%
Testing	Sum of Squares Error	0.002	Valid		63	100%
	Relative Error	0	Excluded		0	
			Total		63	



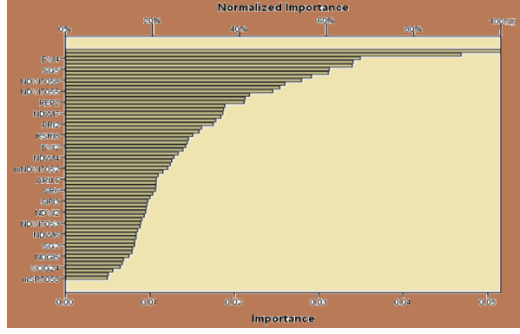
شكل 5، قيم الخطأ للنموذج العصبوني التنبؤي/الشامل في تقدير الانتاجية



شكل 4، قيم الانتاجية المقدرة وفق النموذج العصبوني التنبؤي/الشامل مقابل المسجلة

جدول 7، الأهمية النسبية (%) في النموذج العصبوني التنبؤي/الشامل لقيم كل دليل طيفي وفي كل مرحلة نمو.

SN	Independent Variable	Normalized Importance	SN	Normalized Importance	Independent Variable
1	NDVI2	18.5%	33	VOG18	13.4%
2	NDVI5	50.4%	34	VOG22	90.9%
3	NDVI7	16.6%	35	VOG24	12.6%
4	NDGI4	21.3%	36	VOG26	65.9%
5	NDGI5	14.6%	37	PRI2	34.0%
6	NDGI6	30.7%	38	PRI5	15.9%
7	NDWI4	25.0%	39	PRI6	100%
8	NDWI6	16.3%	40	REP2	41.1%
9	NDWI7	36.2%	41	REP4	16.2%
10	SR4	56.6%	42	REP8	17.2%
11	SR6	20.7%	43	SIPI2	18.8%
12	SR7	34.6%	44	SIPI3	19.0%
13	EVI2	27.6%	45	SIPI7	19.5%
14	EVI4	67.7%	46	RSRI4	24.4%
15	EVI7	36.7%	47	RSRI6	31.3%
16	EVI11	20.8%	48	RSRI8	29.3%
17	ARVI6	10.9%	49	SRI11	18.1%
18	ARVI7	20.8%	50	SRI15	22.4%
19	SG2	15.9%	51	SRI18	15.4%
20	SG5	60.6%	52	SRI21	27.0%
21	SG8	15.3%	53	SRI24	36.3%
22	NDVI7053	17.3%	54	SRI28	35.7%
23	NDVI7055	47.6%	55	ARI14	60.4%
24	NDVI7058	54.3%	56	ARI15	20.9%
25	mSR7051	49.3%	57	ARI16	9.9%
26	mSR7056	66.1%	58	ARI22	41.3%
27	mSR7058	9.7%	59	ARI25	20.1%
28	mNDVI7052	23.5%	60	ARI26	17.6%
29	mNDVI7057	28.0%	61	WBI2	28.3%
30	mNDVI7058	24.1%	62	WBI6	42.3%
31	VOG13	18.6%	63	WBI7	25.9%
32	VOG17	13.1%			



شكل 6، الأهمية النسبية (%) لكل مرحلة نمو بقيم كل دليل نباتي (بشكل مرتب) في أداء النموذج العصبوني التنبؤي/الشامل

3-3- النموذج العصبوني التنبؤي/المختصر للتنبؤ بإنتاجية القطن

يقوم هذا النموذج العصبوني التنبؤي/المختصر على التنبؤ (وليس تقدير) من مراحل نمو مبكرة لنمو القطن بكمية الإنتاج عند الجني اعتماداً على قيم أدلة طيفية معينة ومسجلة فقط خلال مراحل النمو المبكرة، حيث بلغ عدد العوامل المدخلة في النموذج العصبوني التنبؤي/الشامل 30 عامل ناتجة عن بيانات 6 مرحلة نمو لقيم أدلة طيفية 17 منها.



يُخصّص الجدول (8) حالة المعالجة العصبونية لعدد مدخلات بناء النموذج العصبوني التنبؤي/المختصر وتلك التي تم الاختبار بها مع نسبة كل منها. بينما يبين الجدول (9) ملخص أخطاء المعالجة لذلك النموذج، على أن الشكلين (7 و 8) يوضحان قيم الانتاجية المقدرة وكذلك قيم الخطأ وفق النموذج العصبوني التنبؤي/المختصر مقابل المسجلة لمحصول القطن، على التوالي. أما الجدول (10) يبين الأهمية النسبية (%) لقيم النموذج العصبوني التنبؤي/المختصر خلال كل مرحلة نمو ولكل دليل طيفي، على أن يوضح الشكل (9) الأهمية النسبية لكل مرحلة نمو في مساهمة تأثيرها بقيم كل دليل نباتي وبشكل مرتب حسب الأهمية من الأعلى الى الأدنى.

جدول 9، ملخص أخطاء النموذج العصبوني التنبؤي/المختصر

جدول 8، ملخص حالة المعالجة للنموذج العصبوني التنبؤي/المختصر

Model Summary		Value
Training	Sum of Squares Error	0.022
	Relative Error	0.001
Testing	Sum of Squares Error	0.007
	Relative Error	0.001

		N	Percent
Sample	Training	30	75%
	Testing	10	25%
Valid		40	100%
Excluded		0	
Total		40	



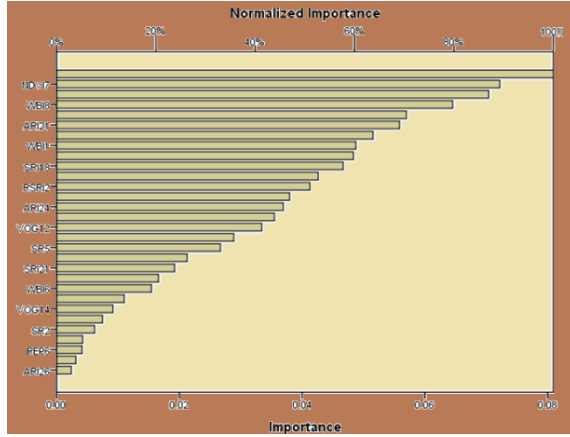
شكل 8، قيم الخطأ للنموذج العصبوني التنبؤي/المختصر في تقدير الانتاجية

شكل 7، قيم الانتاجية المقدرة وفق النموذج العصبوني التنبؤي/المختصر مقابل المسجلة لمحصول القطن

جدول 10، الأهمية النسبية (%) في النموذج العصبوني التنبؤي/الشامل لقيم كل دليل طيفي وفي كل مرحلة نمو.

SN	Independent Variable	Normalized Importance	SN	Independent Variable	Normalized Importance
1	ARI15	70.4%	16	SG1	26.3%
2	ARI21	69.0%	17	SG3	20.5%
3	ARI24	45.6%	18	SG8	13.6%
4	ARI26	3.0%	19	SIPI5	52.7%
5	EVI1	3.9%	20	SIPI6	59.8%
6	mNDVI7053	46.9%	21	SR2	7.6%
7	NDGI1	43.8%	22	SR5	33.0%
8	NDVI7	89.2%	23	SRI18	57.7%
9	NDVI7057	9.2%	24	SRI21	23.7%
10	NDWI1	5.3%	25	SRI24	87.0%
11	NDWI7	63.7%	26	VOG12	41.3%
12	PRI8	100%	27	WBI1	60.2%
13	REP6	5.1%	28	WBI6	19.1%

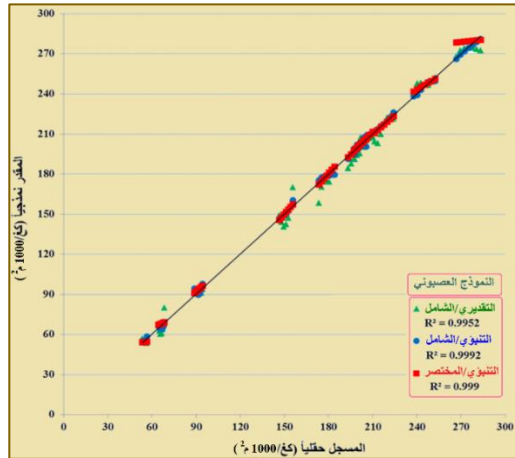
14	RSRI2	51.0%	29	WBI8	79.7%
15	RSRI7	35.7%	30	VOG14	11.3%



شكل 9، الأهمية النسبية (%) لكل مرحلة نمو بقيم كل دليل نباتي (بشكل مرتب) في أداء النموذج العصبوني التنبؤي/المختصر

3-4- اختبار دقة النماذج العصبونية في التقدير والتنبؤ بإنتاجية القطن

يبين الشكل (10) قيم الانتاجية المقدره بالنماذج العصبونية الثلاث: التقديري/الشامل، التنبؤي/الشامل والتنبؤي/المختصر، موقعة مقابل الانتاجية الفعلية لمحصول القطن.



شكل 10، قيم الانتاجية المقدره بالنماذج العصبونية الثلاث: التقديري/الشامل، التنبؤي/الشامل والتنبؤي/المختصر مقابل الحقلية لمحصول القطن

حيث يتبين من الشكل (10) تقارب نتائج النماذج العصبونية الثلاث مقابل الحقلي وقيم معامل انحدار مرتفعة ومتقاربة وبدرجة معنوية احصائية عالية جداً للنماذج الثلاث؛ مما يعني إمكانية الوصول الى النتائج الفعلية من تطبيق أي من النماذج الطيفية العصبونية بدقة عالية في التنبؤ بانتاجية محصول القطن.

كما يوضح الجدول (11) البيانات والمؤشرات الاحصائية للنماذج العصبونية الثلاث: التقديري/الشامل، التنبؤي/الشامل والتنبؤي/المختصر موقعة مقابل الانتاجية الفعلية (حقلياً) لمحصول القطن. بينما يوضح الجدول (12) قيم الخطأ والخطأ النسبي لتلك النماذج العصبونية، وعلى التوالي.

جدول 11، البيانات والمؤشرات الاحصائية لنتائج النماذج العصبونية الثلاث مقابل الانتاجية

الحقلية لمحصول القطن

النموذج	عدد المراحل	عدد الأدلة	عدد العوامل	المتوسط	القيمة العظمى	القيمة الصغرى	الانحراف القياسي	معامل الانحدار	الخطأ القياسي	الخطأ القياسي النسبي	متوسط نسبة الخطأ المقدر
التقديري/الشامل	11	21	231	167.1	274.7	53.73	71.17	0.9952	5.23	1.85	0.70
التنبؤي/الشامل	6	21	63	168.4	280.9	54.50	71.61	0.9992	2.02	0.71	-0.03
التنبؤي/المختصر	6	17	30	169.3	280.1	53.95	72.28	0.9990	2.48	0.88	-0.50
الإنتاج الحقلي				168.4	283.3	53.35	71.83	1.0000			

جدول 12، الخطأ والخطأ النسبي للنماذج العصبونية الثلاث في تقدير انتاجية محصول القطن

الخطأ		النموذج العصبوني
RE	SSE	
0.009	0.067	التقديري/الشامل
0.0001	0.002	التنبؤي/الشامل
0.001	0.007	التنبؤي/المختصر

وحسب تلك النماذج العصبونية فقد بلغ متوسط الانتاجية المقدر 167.1 ، 168.4 و 169.3 كغ/1000م² لنماذج التقديري/الشامل، التنبؤي/الشامل والتنبؤي/المختصر، على التوالي، مقابل الانتاجية الفعلية 168.4 كغ/1000م² لمحصول القطن. تراوحت قيم متوسط نسبة الخطأ المقدر للنماذج العصبونية الثلاث بين 0.7 الى -0.5% عن الانتاج الفعلي وبخطأ قياسي نسبي تراوح بين 1.85 الى

0.71%. كما ترافقت قيم الخطأ النسبي (الجدول 12) مع قيم الخطأ القياسي لكل نموذج عصبوني؛ فكانت قيم ذلك الخطأ 0.009 ، 0.0001 و 0.001 % لنماذج التقديري/الشامل، التنبؤي/الشامل والتنبؤي/المختصر، على التوالي.

4. الخلاصة

لقد أعطت النماذج العصبونية الطيفية سواء التقديرية أم التنبؤية دقة عالية -وفق المؤشرات الاحصائية- في تقدير إنتاجية محصول القطن من البيانات الطيفية المسجلة خلال مراحل النمو تحت تأثير الإجهادات المائية و/أو الغذائية وذلك مقابل الإنتاجية الفعلية المسجلة حقلياً. وبالتالي يتبين أن النموذج العصبوني التنبؤي/المختصر يمكن استخدامه بكفاءة عالية في التنبؤ بإنتاجية محصول القطن بناء على مراحل النمو المبكرة لقيم أدلة طيفية نوعية ترتبط بالصفات النباتية المباشرة ذات العلاقة بمركب الإنتاجية تحت ظروف النمو سواء الطبيعية أم المجهدة في المناطق الجافة وشبه الجافة.

5. المراجع

1. إبراهيم، ناصر طرّاف (2015). تقدير إنتاجية حقول القطن من مرحلة نمو مبكرة باستخدام الصور الفضائية في منطقة اختبارية/محافظة الرقة. مجلة جامعة دمشق للعلوم الزراعية، 31 (1) دمشق.
2. Ceccato, P., S. Flasse, S. Tarantola, S. Jacquemoud, and J. Gregoire, 2001. Detecting Vegetation Leaf Water Content Using Reflectance in the Optical Domain. Remote Sensing of Environment 77:22-33.
3. Curran, P.J., Windham, W.R., and H.L. Gholz, 1995. Exploring the Relationship Between Reflectance Red Edge and Chlorophyll Concentration in Slash Pine Leaves. Tree Physiology 15:203-206.
4. Datt, B., 1999. A New Reflectance Index for Remote Sensing of Chlorophyll Content in Higher Plants: Tests Using Eucalyptus Leaves. Journal of Plant Physiology 154:30-36.
5. Daughtry, C.S.T., 2001. Discriminating Crop Residues from Soil by Short-Wave Infrared Reflectance. Agronomy Journal 93:125-131.
6. Daughtry, C.S.T., E.R. Hunt Jr., and J.E. McMurtrey III. 2004. Assessing Crop Residue Cover Using Shortwave Infrared Reflectance. Remote Sensing of Environment 90:126-134.
7. Fourty, T., F. Baret, S. Jacquemoud, G. Schmuck, and J. Verdebout, 1996. Leaf Optical Properties with Explicit Description of Its Biochemical Composition: Direct and Inverse Problems. Remote Sensing of Environment 56:104-117.

8. Gamon, J.A. and J.S. Surfus, 1999. Assessing Leaf Pigment Content and Activity with a Reflectometer. *New Phytologist* 143:105-117.
9. Gamon, J.A., J. Penuelas, and C.B. Field, 1992. A Narrow-Waveband Spectral Index That Tracks Diurnal Changes in Photosynthetic Efficiency. *Remote Sensing of Environment* 41:35-44.
10. Gamon, J.A., L. Serrano, and J.S. Surfus, 1997. The Photochemical Reflectance Index: An Optical Indicator of Photosynthetic Radiation Use Efficiency Across Species, Functional Types and Nutrient Levels. *Oecologia* 112:492-501.
11. Gao, B.C., 1995. Normalized Difference Water Index for Remote Sensing of Vegetation Liquid Water from Space. *Proceedings of SPIE* 2480: 225-236.
12. Gitelson, A.A. and M.N. Merzlyak, 1994. Spectral Reflectance Changes Associated with Autumn Senescence of *Aesculus Hippocastanum* L. and *Acer Platanoides* L. Leaves. Spectral Features and Relation to Chlorophyll Estimation. *Journal of Plant Physiology* 143:286-292.
13. Gitelson, A.A., M.N. Merzlyak, and O.B. Chivkunova, 2001. Optical Properties and Nondestructive Estimation of Anthocyanin Content in Plant Leaves. *Photochemistry and Photobiology* 71:38-45.
14. Gitelson, A.A., Y. Zur, O.B. Chivkunova, and M.N. Merzlyak, 2002. Assessing Carotenoid Content in Plant Leaves with Reflectance Spectroscopy. *Photochemistry and Photobiology* 75:272-281.
15. Hardisky, M.A., V. Klemas, and R.M. Smart, 1983. The Influences of Soil Salinity, Growth Form, and Leaf Moisture on the Spectral Reflectance of *Spartina Alterniflora* Canopies. *Photogrammetric Engineering and Remote Sensing* 49:77-83.
16. Huete, A.R., H. Liu, K. Batchily, and W. van Leeuwen, 1997. A Comparison of Vegetation Indices Over a Global Set of TM Images for EOS-MODIS. *Remote Sensing of Environment* 59(3):440-451.
17. Hunt Jr., E.R. and B.N. Rock, 1989. Detection of Changes in Leaf Water Content Using Near- And Middle-Infrared Reflectances. *Remote Sensing of Environment* 30:43-54.
18. Jackson, R.D., P.N. Slater, and P.J. Pinter, 1983. Discrimination of Growth and Water Stress in Wheat by Various Vegetation Indices Through Clear and Turbid Atmospheres. *Remote Sensing of the Environment* 15:187-208.
19. Jackson, T.L., D. Chen, M. Cosh, F. Li, M. Anderson, C. Walthall, P. Doriaswamy, and E.R. Hunt, 2004. Vegetation Water Content Mapping Using Landsat Data Derived Normalized Difference Water Index for Corn and Soybeans. *Remote Sensing of Environment* 92:475-482.
20. Kaufman, Y.J. and D. Tanre, 1996. Strategy for Direct and Indirect Methods for Correcting the Aerosol Effect on Remote Sensing: from AVHRR to EOS-MODIS. *Remote Sensing of Environment* 55:65-79.
21. Melillo, J.M., J.D. Aber, and J.F. Muratore, 1982. Nitrogen and Lignin Control of Hardwood Leaf Litter Decomposition Dynamics. *Ecology* 63:621-626.
22. Merzlyak, J.R., A.A. Gitelson, O.B. Chivkunova, and V.Y. Rakitin, 1999. Non-destructive Optical Detection of Pigment Changes During Leaf Senescence and Fruit Ripening. *Physiologia Plantarum* 106:135-141.

23. Penuelas, J., F. Baret, and I. Filella, 1995. Semi-Empirical Indices to Assess Carotenoids/Chlorophyll-a Ratio from Leaf Spectral Reflectance. *Photosynthetica* 31:221-230.
24. Penuelas, J., I. Filella, C. Biel, L. Serrano, and R. Save, 1995. The Reflectance at the 950-970 Region as an Indicator of Plant Water Status. *International Journal of Remote Sensing* 14:1887-1905.
25. Rouse, J.W., R.H. Haas, J.A. Schell, and D.W. Deering, 1973. Monitoring Vegetation Systems in the Great Plains with ERTS. Third ERTS Symposium, NASA SP-351 I: 309-317.
26. Sellers, P.J., 1985. Canopy Reflectance, Photosynthesis and Transpiration. *International Journal of Remote Sensing* 6:1335-1372.
27. Serrano, L., J. Penuelas, and S.L. Ustin, 2002. Remote Sensing of Nitrogen and Lignin in Mediterranean Vegetation from AVIRIS Data: Decomposing Biochemical from Structural Signals. *Remote Sensing of Environment* 81:355-364.
28. Sims, D.A. and J.A. Gamon, 2002. Relationships Between Leaf Pigment Content and Spectral Reflectance Across a Wide Range of Species, Leaf Structures and Developmental Stages. *Remote Sensing of Environment* 81:337-354.
29. Tucker, C.J., 1979. Red and Photographic Infrared Linear Combinations for Monitoring Vegetation. *Remote Sensing of the Environment* 8:127-150.
30. Vogelmann, J.E., B.N. Rock, and D.M. Moss, 1993. Red Edge Spectral Measurements from Sugar Maple Leaves. *International Journal of Remote Sensing* 14:1563-1575.
31. Xu, W.; Chen, P.; Zhan, Y.; Chen, S.; Zhang, L.; Lanm Y. Cotton yield estimation model based on machine learning using time series UAV remote sensing data. *International Journal of Applied Earth Observations and Geoinformation* 104 (2021) 102511. <https://doi.org/10.1016/j.jag.2021.102511>
32. Ennouri, K.; Smaoui, S.; Gharbi, Y.; Cheffi, M.; Ben Braiek, O.; Ennouri, M.; Ali Triki, M. Usage of Artificial Intelligence and Remote Sensing as Efficient Devices to Increase Agricultural System Yields. *Journal of Food Quality*. Volume 2021, Article ID 6242288, 17 pages. <https://doi.org/10.1155/2021/6242288>
33. Bharadiya, J.; Tzenios, N.; and Reddy, M.. Forecasting of Crop Yield using Remote Sensing Data, Agrarian Factors and Machine Learning Approaches. *Journal of Engineering Research and Reports*. Volume 24, Issue 12, Page 29-44, 2023. DOI: 10.9734/JERR/2023/v24i12858
34. Ilyas, Qazi M.; Ahmad, M.; and Mehmood, A.. Automated Estimation of Crop Yield Using Artificial Intelligence and Remote Sensing Technologies. *Bioengineering* 2023, 10, 125. <https://doi.org/10.3390/bioengineering10020125>
35. Kale, N., Gunjal S., N. Manoj, H. E. Khodke, S. Gore, B. J. Dange. Crop Yield Estimation Using Deep Learning and Satellite Imagery. *International Journal of Intelligent Systems and Applications in Engineering IJISAE*, 2023, 11(10s), 464–471.
36. Klompenburga T. van; Kassahuna A.; Catalb C.; Crop yield prediction using machine learning: A systematic literature review. *Computers and Electronics in Agriculture journal*. 177 (2020) 105709.