

# پردازش تصاویر ماهواره‌ای به منظور برآورد میزان تولید برنج

محسن سریانی<sup>۱</sup>، رضا قادری<sup>۲</sup> و مهرداد هاشمی کمانگر<sup>۳</sup>

۱- استادیار دانشگاه علم و صنعت

۲- استادیار دانشگاه مازندران

۳- کارشناس ارشد الکترونیک

نویسنده‌ی عهده‌دار مکاتبات: محسن سریانی

## چکیده

در این مقاله با استفاده از پردازش تصویر و سنجش از دور به تعیین میزان محصول برنج در منطقه‌ای در شمال ایران پرداخته می‌شود. منطقه‌ی مورد بررسی در عرض جغرافیایی  $36^{\circ}, 21'N$  تا  $36^{\circ}, 43'N$  و طول جغرافیایی  $52^{\circ}, 20'E$  تا  $52^{\circ}, 44'E$  در شمال ایران (استان مازندران) واقع شده است. در این تحقیق از چهار تصویر سنسور *LISS-III* ماهواره *IRS-1D* در فصل زراعی ۱۳۸۲ استفاده شده است که دو تصویر از فصل برنج کاری و دو تصویر مربوط به فصل غیر برنج کاری می‌باشد و تصاویر با استفاده از نقاط کنترل زمینی تصحیح هندسی شده‌اند. برای برآورد تولید برنج، ابتدا مزارع برنج از دیگر مناطق با استفاده از شبکه‌ی عصبی *MLP* دوکلاسه تفکیک شده‌اند. شبکه‌ی مورد استفاده، یک لایه‌ی ورودی، دو لایه‌ی مخفی و یک لایه‌ی خروجی دارد. از آنالیز مؤلفه‌های اصلی (*PCA*) برای کم کردن بُعد نمونه‌های ورودی به شبکه استفاده شد. شبکه به‌ازای حالات مختلف (بُعد نمونه‌های ورودی، تعداد نرون‌های لایه‌ی مخفی) آموزش داده و شبکه‌ی بهینه با استفاده از مجموعه‌ی *validation* انتخاب شد. شبکه‌ی بهینه دارای دقت کلی ۹۸ درصد و دارای ضریب کاپا ۰/۹۶ روی مجموعه‌ی *test* است. همچنین با استفاده از شبکه‌ی *MLP* مزارع برنج پرمحصول و کم‌محصول تفکیک شده‌اند. شبکه‌ی *MLP* ایجاد شده دارای دقت کلی ۸۹/۶ درصد و ضریب کاپا ۰/۶۷ است. با شبکه‌ی عصبی *RBF* مدلی ایجاد شده است تا با داشتن بازتاب مزارع در باندهای مادون‌قرمز نزدیک و قرمز در دو تصویر از دوره‌ی رشد برنج، میزان محصول مزارع تخمین زده شود. میانگین خطای نسبی مدل برای برنج پرمحصول ۱۱/۵۲ درصد با انحراف معیار ۷/۱۸۳ می‌باشد و دارای ضریب تخمین ۰/۳۱ است و برای برنج کم‌محصول میانگین خطای نسبی ۹/۹ درصد با انحراف معیار ۹/۲ و ضریب تخمین ۰/۲ می‌باشد. درنهایت با استفاده از مدل سه‌گانه‌ی بالا، میزان تولید هر یک از گونه‌های برنج در منطقه‌ی مورد مطالعه تعیین گردید که میزان تولید برنج پرمحصول ۲۵۶۰۶۱ تن و میزان تولید برنج کم‌محصول ۸۵۱۷۷ تن برآورد گردید.

کلمات کلیدی: تصاویر ماهواره‌ای، شبکه‌ی عصبی *RBF*، شبکه‌ی عصبی *MLP*، تخمین میزان محصول، برنج


## ۱- موضوع

با افزایش جمعیت زمین، تغییر کاربری زمین‌های کشاورزی افزایش یافته است. مدیریت کشاورزی، نیازمند اطلاعات صحیح، دقیق و به‌هنگام از تغییرات مزارع کشاورزی، سطح زیر کشت محصولات، میزان تولید و ... می‌باشد و جمع‌آوری اطلاعات با روش‌های سنتی، نیازمند صرف هزینه و وقت زیاد است.

با گسترش فناوری ماهواره، تصاویر ماهواره‌ای دسترسی به اطلاعات را از منابع زمینی به‌طور گسترده و سریع فراهم

کردند و ماهواره به‌عنوان وسیله‌ای مؤثر برای مدیریت منابع زمینی مورد استفاده قرار گرفت. وجود اطلاعات کامل در مورد سطح زیر کشت برنج و همچنین میزان تولید سالانه‌ی آن در برنامه‌ریزی کشاورزی (واردات و صادرات) کشور، نقش به‌سزایی دارد. به واسطه‌ی کوچک بودن ابعاد زمین‌های برنج کاری در منطقه‌ی شمال کشور و نظام مالکیت اراضی، تهیه‌ی چنین اطلاعاتی بسیار مشکل و نیاز به صرف هزینه و وقت زیادی می‌باشد.

با رشد گیاه برنج، مقدار NDVI افزایش می‌یابد تا برنج به بیشینه‌ی رشد خود برسد؛ سپس هنگامی که برنج به مرحله‌ی رسیدن می‌رسد با زرد شدن برگ‌های برنج، مقدار NDVI کاهش پیدا می‌کند.



شکل ۱ تغییرات NDVI نسبت به زمان کاشت برنج [۱۰]

یانگ و سو [۱۰] یک رابطه‌ی نمایی برای تخمین مشخصه‌های رشد و میزان محصول بر مبنای NDVI پیشنهاد داده‌اند.

مطالعات ویگان<sup>۱۱</sup> و ریچاردسون<sup>۱۲</sup> [۱۲، ۱۱] نشان داد، برای گیاهانی مانند ذرت و گندم که LAI کوچکی دارند، مجموع فصلی توده‌ی گیاهی<sup>۱۳</sup> با میزان محصول همبستگی دارد.

دورایسومی<sup>۱۴</sup> و همکارانش [۳] برای تخمین میزان محصول گندم در *داکوتای آمریکا* از مجموع فصلی NDVI (SUM NDVI) استفاده نموده و مدلی با استفاده از رگرسیون خطی ایجاد کردند. موتی<sup>۱۵</sup> و همکارانش [۱] از روش ترکیب زمانی NDVI (Time Composited NDVI) برای تخمین میزان محصول برنج استفاده کرده‌اند.

در روش ترکیب زمانی، از دوره‌ی رشد گیاه تعدادی تصویر ماهواره‌ای گرفته می‌شود و شاخص NDVI برای هر تصویر محاسبه شده و سپس با استفاده از مقدار بیشینه‌ی NDVI هر پیکسل، یک تصویر جدید حاصل می‌شود.

در این مقاله، با استفاده از شبکه‌ی عصبی RBF<sup>۱۶</sup> و بازتاب مزارع برنج در باندهای طیف الکترومغناطیسی، مدلی برای تخمین میزان محصول ارائه شده است.

در بیست سال گذشته روش‌های طبقه‌بندی آماری، مانند طبقه‌بندی‌کننده‌های کمترین فاصله و بیشترین شباهت به‌طور وسیعی استفاده شده‌اند. این روش‌ها،

استفاده از تصاویر ماهواره‌ای و فناوری‌های سنجش از دور می‌تواند در برآورد سطح زیر کشت و تخمین میزان محصولات، بسیار مؤثر واقع شود.

## ۲- هدف

هدف این تحقیق، این است که با استفاده از بازتاب امواج الکترومغناطیسی از مزارع برنج در باندهای سبز، قرمز و مادون‌قرمز نزدیک طیف الکترومغناطیسی، میزان تولید برنج را در منطقه‌ی مورد مطالعه تعیین نماییم. برای انجام این کار باید با استفاده از مؤلفه‌های بازتابی برنج، مزارع برنج شناسایی شده و گونه‌های کم‌محصول و پرمحصول از هم تفکیک شوند و سپس برای هر یک از این گونه‌ها مدلی ایجاد شود تا میزان محصول هر واحد سطح (یک پیکسل از تصویر ماهواره‌ای) را تخمین زده و سپس کل تولید برنج را در منطقه تعیین نماییم.

## ۳- ادبیات موضوع

مدل‌هایی که برای تخمین میزان محصول ارائه شده‌اند، عموماً بر محاسبه‌ی شاخص‌های گیاهی (مانند NDVI<sup>۱</sup>، RVI<sup>۲</sup> و ...) استوار می‌باشند که با استفاده از این شاخص‌ها و با فرض یک نوع تابع (خطی، نمایی، لگاریتمی و ...)، پارامترهای تابع، محاسبه و میزان محصول، تخمین زده می‌شود [۴، ۳، ۲، ۱]. یانگ<sup>۳</sup> و سو<sup>۴</sup> (۱۹۹۷) [۵] بین شاخص مساحت برگ<sup>۵</sup> (LAI) و بازتاب مادون قرمز نزدیک، رابطه‌ای بر مبنای معکوس تابع Mitscherlich ارائه داده‌اند.

بسیاری از مطالعات در زمینه‌ی تخمین میزان محصول بر مبنای همبستگی بین شاخص تفاضلی نرمالیزه شده‌ی گیاهی (NDVI) و میزان تولید، بنا نهاده شده‌اند که می‌توان به تحقیقات راسموسن<sup>۶</sup> [۶]، لیو<sup>۷</sup> و کوغان<sup>۸</sup> [۷]، گروتن<sup>۹</sup> [۸] و گات<sup>۱۰</sup> و همکارانش [۹] اشاره کرد.

تغییرات NDVI نسبت به زمان کاشت در (شکل ۱) نشان داده شده است.

<sup>1</sup> Normalized Difference Vegetation Index

<sup>2</sup> Ratio Vegetation Index

<sup>3</sup> Yang

<sup>4</sup> Su

<sup>5</sup> Leaf area index

<sup>6</sup> Rasmussen

<sup>7</sup> Liu

<sup>8</sup> Kogan

<sup>9</sup> Groten

<sup>10</sup> Gat

<sup>11</sup> Weigand

<sup>12</sup> Richardson

<sup>13</sup> Biomass

<sup>14</sup> Doraiswamy

<sup>15</sup> Muthy

<sup>16</sup> Radial Basis Function

از قانون یادگیری پس‌انتشار خطا برای آموزش شبکه‌های MLP استفاده می‌شود. قانون پس‌انتشار خطا از دو مسیر اصلی تشکیل می‌شود؛ مسیر اول به مسیر رفت، موسوم است که در این مسیر بردار ورودی به شبکه اعمال می‌شود و تأثیراتش از طریق لایه‌های میانی به لایه‌ی خروجی انتشار می‌یابد. بردار خروجی تشکیل یافته در لایه‌ی خروجی، پاسخ واقعی شبکه‌ی MLP را تشکیل می‌دهد. در این مسیر اوزان شبکه، ثابت و بدون تغییر می‌باشند.

مسیر دوم به مسیر برگشت موسوم است. در این مسیر برعکس مسیر رفت، اوزان شبکه‌ی MLP تغییر یافته و تنظیم می‌گردند. این تنظیم مطابق با قانون اصلاح خطا انجام می‌گیرد.

بردار خطا برابر با اختلاف بین پاسخ مطلوب و پاسخ واقعی شبکه می‌باشد. مقدار خطا، پس از محاسبه، در مسیر برگشت از لایه‌ی خروجی و از طریق لایه‌های شبکه در کل شبکه توزیع می‌گردد. اوزان شبکه، طوری تنظیم می‌شوند که پاسخ واقعی شبکه، هرچه بیشتر به سمت پاسخ مطلوب نزدیک شود. [۲۳].

یک مسئله‌ی مهم در شناسایی آماری الگو، انتخاب یا استخراج مشخصه می‌باشد. انتخاب مشخصه به فرآیندی اشاره دارد که به وسیله‌ی آن، داده‌ها به فضای مشخصه به نحوی انتقال می‌یابند که مجموعه‌ی داده‌ها با تعداد کمتری از مشخصه‌های مؤثر نمایش داده شوند و بیشترین اطلاعات را از محتوای داده‌های اولیه داشته باشند.

اگر بخواهیم  $k$  بُعد از اطلاعات  $P$  بُعدی را انتخاب نماییم و بقیه را حذف کنیم میانگین مربعات خطا برابر مجموع واریانس عناصر حذف شده می‌باشد.

<sup>۱۲</sup>PCA، اطلاعات را به فضای مشخصه انتقال می‌دهد، به طوری که نمونه‌ها دارای بیشترین واریانس در بُعدهای اولیه باشند. حال اگر در فضای مشخصه،  $k$  بُعد از نمونه‌ها را انتخاب نماییم، میانگین مربعات خطا برابر مجموع مقادیر ویژه متناظر با ابعاد حذف شده می‌باشد. چون این مقادیر ویژه، دارای کوچک‌ترین اندازه می‌باشند، پس اطلاعات کمتری از دست داده می‌شود [۲۴].

<sup>12</sup> Principal Component Analysis

محدودیت‌هایی از قبیل فرض وجود یک نوع مخصوص از توزیع دارند.

در دهه‌ی گذشته، استفاده از شبکه‌ی عصبی مصنوعی (ANN) در کاربردهای سنجش از دور، مرسوم و به کار گرفته شدند. مطالعات نشان داد، شبکه‌های عصبی، بسیار قوی‌تر از روش‌های آماری، عمل نموده و نتایج دقیق‌تری تولید می‌کنند [۱۳]. استس<sup>۱</sup> و همکارانش [۱۴] مطالعات اولیه را در استفاده از روش‌های ANN برای اطلاعات سنجش از دور انجام داده و پیشنهاد نمودند که از این روش برای پردازش اطلاعات و طبقه‌بندی آن‌ها استفاده کنند. بندیکتسون<sup>۲</sup> و همکارانش [۱۵] این نتایج را با طبقه‌بندی‌کننده‌ی بیشترین شباهت مقایسه کرده و دریافتند که شبکه‌های عصبی، نسبت به طبقه‌بندی‌کننده‌ی بیشترین شباهت، می‌توانند نتایج دقیق‌تری تولید کنند. تحقیقات دیگر هم، این نتیجه را تأیید می‌کند که می‌توان به تحقیقات کانلویپولس<sup>۳</sup> و همکارانش [۱۶] و پائلو<sup>۴</sup> و شونگرت<sup>۵</sup> و [۱۷] و بروزنه<sup>۶</sup> و همکارانش [۱۸] اشاره کرد.

چن<sup>۷</sup> و همکاران [۱۹] و هارا<sup>۸</sup> و همکاران [۲۰] از شبکه‌ی عصبی برای طبقه‌بندی پوشش سطح زمین در تصاویر رادار استفاده کرده‌اند. بیسچف<sup>۹</sup> و همکاران [۲۱] و هرمان<sup>۱۰</sup> و خازنی<sup>۱۱</sup> [۲۲] اطلاعات چندطیفی را برای طبقه‌بندی پوشش سطح زمین به کار بردند.

## ۴ - روش‌های تحلیلی

### ۴-۱- شناسایی مزارع برنج و گونه‌های

#### محصول

برای شناسایی مزارع برنج و تفکیک گونه‌های کم‌محصول و پرمحصول از یکدیگر، از شبکه‌ی عصبی MLP استفاده شده است. MLP از شبکه‌های عصبی چند لایه‌ی پیشخور می‌باشد که دارای یک لایه‌ی ورودی، یک یا چند لایه‌ی مخفی و یک لایه‌ی خروجی است. هر لایه از تعدادی نرون تشکیل می‌شود و می‌توان از توابع تبدیل متفاوت برای هر لایه استفاده کرد.

<sup>1</sup> Estes	<sup>2</sup> Benediktsson
<sup>3</sup> Benediktsson	<sup>4</sup> Kanellopoulos
<sup>5</sup> Paola	<sup>6</sup> Schowengerdt
<sup>7</sup> Bruzzone	<sup>8</sup> Chen
<sup>9</sup> Hara	<sup>10</sup> Bischof
<sup>11</sup> Heermann	<sup>12</sup> Khazenie

۴-۲-۱- تعداد نرون‌های هر لایه

تعداد نرون‌های لایه‌ی ورودی برابر تعداد متغیرها است که به عنوان ورودی شبکه در نظر گرفته می‌شود؛ تعداد نرون‌های لایه‌ی خروجی برابر تعداد متغیرهای وابسته (خروجی‌ها) می‌باشد که بر اساس تعریف مسئله، تعداد خروجی معلوم می‌گردد و تعداد نرون‌های لایه‌ی مخفی برابر تعداد مراکز می‌باشد که باید تعیین شوند.

۴-۲-۲- توابع مورد استفاده در لایه‌ی مخفی (توابع RBF)

توابع شعاعی، طبقه‌ی ویژه‌ای از توابع هستند و مشخصه‌ی اصلی آن‌ها این است که اندازه‌ی تابع، نسبت به نقطه‌ی مرکز، به‌طور یکنواخت کاهش یا افزایش می‌یابد. توابعی که مورد بررسی قرار گرفته‌اند، عبارتند از:

۱- تابع گوسین:

$$\varphi(d) = e^{-d^2/r^2} \quad (7)$$

۲- تابع Multiquadric:

$$\varphi(d) = \frac{\sqrt{d^2 + r^2}}{r} \quad (8)$$

۳- تابع Inverse Multiquadric:

$$\varphi(d) = \frac{r}{\sqrt{d^2 + r^2}} \quad (9)$$

۴- تابع Logistic:

$$\varphi(d) = \frac{1}{1 + e^{d/r}} \quad (10)$$

۵- تابع Thinplate:

$$\varphi(d) = \frac{d^2}{r^2} \times \log d/r \quad (11)$$


که  $d$ ، فاصله‌ی اقلیدسی از مرکز تابع می‌باشد.

۴-۲-۳- انتخاب مراکز

برای انتخاب مراکز مورد استفاده در شبکه‌ی RBF از روش forward selection (FS) [۲۵، ۲۶] استفاده شده است. در روش FS مراکز به صورت مرحله به مرحله انتخاب می‌شوند؛ بدین‌صورت که از بین نامزدهای مراکز (می‌تواند مجموعه‌ی آموزش یا زیرمجموعه‌ای از آن باشد) یک مرکز که کم‌ترین خطا (برای مثال، مجموع مربعات خطا) را روی مجموعه‌ی آموزش ایجاد می‌کند، انتخاب می‌گردد و سپس مرکز بعدی

۴-۲- ایجاد مدل RBF برای تعیین میزان محصول واحد سطح

برای برازش یک منحنی روی مجموعه داده از شبکه‌ی عصبی RBF استفاده می‌شود که از شبکه‌های عصبی رو به جلو بوده و دارای سه لایه‌ی ورودی، مخفی و خروجی می‌باشد (شکل ۲).



شکل ۲ ساختار شبکه‌ی عصبی RBF

پاسخ شبکه به ورودی به صورت ترکیب خطی از  $m$  تابع ثابت ( $m$  تعداد مراکز) بیان می‌شود.

$$y = \sum_{j=1}^m w_j h_j(x) \quad (1)$$

$$h_j(x) = \varphi\left(\frac{\|x - C_j\|}{r}\right) \quad (2)$$

$\varphi(\cdot)$  از توابع شعاعی می‌باشد و غیر خطی است و  $\|x - C_j\|$ ، فاصله‌ی بردار  $x$  از مرکز  $C_j$  می‌باشد که اغلب این فاصله به صورت فاصله‌ی اقلیدسی بیان می‌شود و  $r$  پهنای (width) تابع می‌باشد.

در فرم ماتریسی، معادله‌ی (۴-۱) داریم:

$$Y = f(X) = Hw \quad (3)$$

$$H = [h_1, h_2, \dots, h_m] \quad (4)$$

با حداقل کردن مجموع مربعات خطا، ضرایب  $w$  محاسبه می‌شوند:

$$e = y - \hat{y} = y - Hw \quad \text{و} \quad E = e^T e \quad (5)$$

$$w = (H^T H)^{-1} H^T y \quad (6)$$

پارامترهایی که باید در شبکه‌ی RBF تعیین گردند، عبارتند از: تعداد نرون‌های هر لایه، تابع مورد استفاده در لایه‌ی مخفی و مراکز شبکه، عرض توابع و پارامتر تنظیمی  $\lambda$ .

<sup>1</sup> regularization


می‌شود. این مراحل چندین بار تکرار می‌شوند تا عرض بهینه تعیین گردد.

برای این که پراکندگی اطلاعات خیلی زیاد نباشد و نیز برای تعیین عرض در ابتدا به طوری که بتوان حدود را در محدوده‌ی مشخصی انتخاب کرد (برای مثال بین ۰/۱ و ۲۰) هر ستون از ماتریس اطلاعات بین ۱- و ۱ نرمالیزه می‌شوند.

## ۵- روش‌های اجرایی

### ۵-۱- منطقه‌ی مورد مطالعه

منطقه‌ی مورد بررسی در عرض جغرافیایی  $36^{\circ}, 21'N$  تا  $36^{\circ}, 43'N$  و طول جغرافیایی  $52^{\circ}, 20'E$  تا  $52^{\circ}, 44'E$  واقع شده است که شامل شهرهای آمل، بابل، بابلسر و فریدونکنار واقع در استان مازندران و به مساحت تقریبی  $36km \times 40km = 1440km^2$  می‌باشد (شکل ۳).



شکل ۳ منطقه‌ی مورد مطالعه

در این منطقه، ارقام برنج به دو گروه عمده‌ی پرمحصول و کم‌محصول تقسیم می‌شوند و فصل زراعی از اوایل اردیبهشت شروع شده و تا اواخر شهریور ادامه می‌یابد. زمان نشا در منطقه، به نوع برنج و مختصات جغرافیایی، وابسته است. زمان نشا در عرض‌های جغرافیایی شمالی، زودتر از بخش‌های جنوبی بوده و همچنین برای ارقام کم‌محصول، زمان نشا زودتر از ارقام پرمحصول می‌باشد. این موضوع، تأثیر مستقیم در پنجه‌زنی بوته‌ی برنج و رشد رویشی گیاه برنج دارد؛ بدین صورت که با تأخیر در زمان نشا، برنج زمان کم‌تری برای پنجه‌زنی و تولید ساقه دارد.

### ۵-۲- تصاویر ماهواره‌ای مورد استفاده

در این تحقیق از تصاویر ماهواره‌ی IRS-1D سنسور LISS-III استفاده شده است که دارای ۳ باند سبز، قرمز و مادون قرمز نزدیک در طول موج‌های ۵۲۰-۵۹۰ nm و ۶۲۰-۶۸۰ nm و ۷۷۰-۸۶۰ nm می‌باشند. این تصاویر در

از بین بقیه‌ی نامزدها به همین نحو انتخاب می‌شود. فرآیند اضافه کردن مراکز که همان نرون‌های لایه‌ی میانی شبکه هستند، ادامه می‌یابد تا هنگامی که خطا روی مجموعه‌ی آموزش نسبت به مرحله‌ی قبلی کاهش نیابد. در این مقاله از معیار Generalized Cross Validation (GCV) [۲۵، ۲۶] برای توقف انتخاب مراکز استفاده شده است.

### ۴-۲-۴- پارامتر $\lambda$ و محاسبه‌ی اوزان شبکه

اگر تعداد مراکز مورد استفاده در شبکه‌ی RBF افزایش یابد شبکه به تغییرات جزئی مجموعه‌ی آموزش، حساس شده و پاسخ شبکه روی مجموعه‌ی آموزش تطبیق می‌یابد و بدین ترتیب خطا به ازای مقادیر مابین نمونه‌های آموزشی افزایش می‌یابد و خطای فوق‌برازش<sup>۱</sup> رخ می‌دهد. برای جلوگیری از خطای فوق‌برازش پارامتر  $\lambda$  به تابع هزینه‌ی معادله‌ی ۴-۵ اضافه می‌شود و تابع هزینه، به صورت زیر بیان می‌گردد:

$$E = \mathbf{e}^T \mathbf{e} + \lambda \mathbf{w}^T \mathbf{w} = \mathbf{y}^T \mathbf{P} \mathbf{y} \quad (12-4)$$

$$\mathbf{P} = \mathbf{I}_p - \mathbf{H}(\mathbf{H}^T \mathbf{H} + \lambda \mathbf{I}_m)^{-1} \mathbf{H}^T \quad (13-4)$$

$$\mathbf{w} = (\mathbf{H}^T \mathbf{H} + \lambda \mathbf{I}_m)^{-1} \mathbf{H}^T \mathbf{y} \quad (14-4)$$

P ماتریس تصویر w و اوزان شبکه و m تعداد مراکز می‌باشند.

برای تعیین پارامتر  $\lambda$  از کمینه کردن معیار GCV استفاده می‌شود. با مشتق‌گیری از GCV نسبت به پارامتر  $\lambda$  و با برابر صفر قرار دادن نتیجه، بهترین مقدار برای  $\lambda$  به دست می‌آید [۲۷].

### ۴-۲-۵- انتخاب عرض توابع [۲۸]

هنگامی که از GCV نسبت به عرض تابع (r) مشتق‌گیری شده و نتیجه برابر صفر قرار داده شود، پارامتر r از طرفین رابطه حذف می‌شود و نمی‌توان رابطه‌ی برای r به ازای کمینه شدن GCV به دست آورد.

برای محاسبه‌ی r دو حد پایین و بالا برای عرض تابع، انتخاب شده و این فاصله به n مقدار تقسیم می‌شود و بر مبنای روش FS، مراکز،  $\lambda$  و GCV به ازای هر یک از n مقدار، محاسبه می‌شوند، و مقداری که به ازای آن، GCV کمینه می‌شود، انتخاب می‌گردد.

حدود جدید، متناسب با مقداری که برای عرض مشخص گردید، محاسبه می‌شود و مرحله‌ی قبلی تکرار

<sup>1</sup> overfit

از این ۶۶ مزرعه، ۴۸ مزرعه، مربوط به برنج پرمحصول و ۱۸ مزرعه مربوط به برنج کم‌محصول می‌باشند. مختصات جغرافیایی مرز مزارع با GPS تعیین شده و محل مزارع بر روی تصاویر ماهواره‌ای مشخص گردید و سپس میانگین بازتاب مزارع در هر یک از باندها با رابطه‌ی


$$\bar{X} = \frac{\sum r_i x_i}{\sum r} \quad (12)$$

محاسبه گردید که  $r_i$  نسبتی از پیکسل  $i$  است که در داخل چندضلعی مزرعه قرار دارند و  $x_i$  مقدار عددی پیکسل  $i$  می‌باشد.

هم‌چنین برای شناسایی مزارع برنج، از نواحی غیربرنج مانند مناطق شهری، جنگل، تالاب‌ها و مناطق با پوشش گیاهی غیربرنج (زمین چمن، باغات، ...) مناطقی انتخاب شده‌اند و مختصات جغرافیایی پیرامون این مناطق با GPS تعیین گردید.



a



b



c



d

شکل ۴ تصاویر مورد استفاده که به صورت ترکیب رنگی کاذب نمایش داده شده‌اند:

(a) ۸ آبان ۱۳۸۱ (b) ۲۲ خرداد ۱۳۸۲ (c) ۱۰ مرداد ۱۳۸۲ (d) ۲۸ بهمن ۱۳۸۲

#### ۶-۱-۱- آموزش شبکه در حالت‌های مختلف

شبکه در حالت‌های مختلف زیر آموزش داده می‌شود، سپس مشخصات شبکه‌ی بهینه از روی نتایج حالت‌های مختلف تعیین می‌گردد:

۱- انتخاب ورودی شبکه:

ورودی شبکه در دو حالت بررسی شده است:

- استفاده‌ی مستقیم از داده‌های فوق (مؤلفه‌های  $r$

،  $g$  و  $b$  تصاویر)

- استفاده از آنالیز مؤلفه‌های اصلی روی مجموعه‌ی

Train و انتخاب  $k$  بردار که بزرگ‌ترین مقدار ویژه را

دارند، هر یک از نمونه‌ها روی این بردارها تصویر شده و

تاریخ‌های ۸ آبان ۱۳۸۱، ۲۲ خرداد ۱۳۸۲، ۱۰ مرداد ۱۳۸۲ و ۲۸ بهمن ۱۳۸۲ اخذ شده‌اند. (شکل ۴) دو تصویر از فصل برنج‌کاری و دو تصویر از فصل غیر برنج‌کاری نشان می‌دهد. این تصاویر با استفاده از نقاط کنترل زمینی که مختصات جغرافیایی آن‌ها به‌وسیله‌ی دستگاه<sup>۱</sup> GPS مشخص گردید، تصحیح هندسی، و تصاویر بر روی هم منطبق شده‌اند.

برای شناسایی مزارع برنج از چهار تصویر برای مدل کردن میزان محصول و تفکیک گونه‌های کم‌محصول و پرمحصول، از دو تصویر مربوط به طی دوره‌ی رشد برنج استفاده شده است.

### ۵-۳- اطلاعات زمینی

در منطقه‌ی مورد مطالعه، تعداد ۶۶ مزرعه‌ی برنج پرمحصول و کم‌محصول انتخاب شده‌اند که عملکرد و نوع محصول به صورت پرسش از کشاورزان مشخص شده است.

## ۶- آموزش مدل‌ها و نتایج

### ۶-۱-۱- مدل شناسایی مزارع برنج و نتایج

هدف اولیه در این مقاله ارایه‌ی مدلی برای تفکیک مزارع برنج از بقیه‌ی نواحی تصویر است که در این بخش به آن می‌پردازیم. شبکه‌ی MLP مورد استفاده، دارای دو طبقه‌ی برنج و غیربرنج بوده و دارای دو لایه‌ی مخفی و یک لایه‌ی خروجی است. هر یک از نمونه‌های ورودی به شبکه برای طبقه‌بندی، ۱۲ بُعد دارند که مؤلفه‌های  $r$ ،  $g$  و  $b$  چهار تصویر هستند که این مؤلفه‌ها به ترتیب باندهای مادون قرمز نزدیک، قرمز و سبز می‌باشند.

<sup>۱</sup> Global positioning system

بردار ورودی شبکه دارای ۱۰ بُعد می‌باشد که با آنالیز مؤلفه‌های اصلی به دست می‌آید. تعداد نرون‌های لایه‌ی مخفی ۱۰ بوده و از تابع Logsig در لایه‌های مخفی و از تابع Purelin در لایه‌ی خروجی استفاده شده است.

طبقه‌ها به صورت  $\begin{bmatrix} 0.25 \\ 0.75 \end{bmatrix}$  برای کلاس برنج و  $\begin{bmatrix} 0.75 \\ 0.25 \end{bmatrix}$  برای طبقه‌ی غیربرنج نمایش داده شده‌اند. در (شکل ۵) نمودار یادگیری شبکه‌ی بهینه، نمایش داده شده است.


یادگیری و بازدهی شبکه به تفکیک طبقه، در (جدول ۱) درج شده‌اند. همچنین کارایی شبکه روی سه مجموعه‌ی اضافی دیگر، آزمایش شد که نتایج در (جدول ۲) آورده شده‌اند.

جدول ۱ یادگیری و راندمان شبکه‌ی بهینه برای شناسایی مزارع برنج

مجموعه	تشخیص صحیح غیربرنج	تشخیص صحیح برنج	دقت کلی (%)	ضریب کاپا
Train	٪۹۹/۱۵	٪۹۹/۶۲	۹۹/۳۷	۰/۹۸۷
Validation	٪۹۸/۴۲	٪۹۷/۴۶	۹۷/۹۷	۰/۹۵۹
Test	٪۹۸/۲۴	٪۹۷/۶۶	۹۷/۹۷	۰/۹۵۹

جدول ۲ نتایج مدل شناسایی مزارع برنج روی ۳ مجموعه‌ی جدید

نوع	تعداد نمونه	غیربرنج	برنج	درصد تشخیص صحیح
غیربرنج	۲۱۱۴	۲۰۵۰	۶۴	٪۹۶/۲۷
غیربرنج	۴۶۲۷	۴۶۱۰	۱۷	٪۹۹/۶۳
برنج	۵۱۴	۵	۵۰۹	٪۹۹/۵۳



شکل ۵ نمودار یادگیری شبکه‌ی بهینه برای شناسایی مزارع برنج

مقدار عددی این تصویر به عنوان داده‌ی جدید در نظر گرفته می‌شود. شبکه به ازای ۱۱ و ۱۰ و ۹ و ۸ و ۷ و ۶ k آموزش داده شده است.

۲- تعداد نرون‌های لایه‌های مخفی:

تعداد نرون‌های اولین لایه‌ی مخفی، برابر بُعد ورودی در نظر گرفته شده است و تعداد نرون‌های دومین لایه‌ی مخفی از ۲ تا ۱۲ نرون تغییر داده شده است.

۳- توابع مورد استفاده در لایه‌ها:

در شبکه‌ی عصبی از تابع Purelin برای لایه‌ی خروجی و در لایه‌های مخفی از تابع Logsig و Tansig در دو حالت مختلف استفاده شده است.

۴- چگونگی نمایش طبقه‌ها:

برای این که الگوریتم پس‌انتشار، هم‌گرایی بهتری داشته باشد مهم است که مقادیر مطلوب طبقه‌ها در محدوده‌ی توابع محرک قرار بگیرند [۱۱] و چون توابع logsig دارای مقادیر بین ۰ و ۱ و tansig دارای مقادیر بین -۱ و ۱ می‌باشد برای حالتی که از تابع Logsig در لایه‌های مخفی استفاده شده است، طبقه‌ها به صورت  $\begin{bmatrix} \alpha \\ 1-\alpha \end{bmatrix}$  برای طبقه‌ی برنج و  $\begin{bmatrix} 1-\alpha \\ \alpha \end{bmatrix}$  برای طبقه‌ی غیربرنج نمایش داده شده‌اند و برای حالتی که از تابع Tansig در لایه‌های مخفی استفاده شده است، طبقه‌ها به صورت  $\begin{bmatrix} -1+\alpha \\ 1-\alpha \end{bmatrix}$  و  $\begin{bmatrix} 1-\alpha \\ -1+\alpha \end{bmatrix}$  نمایش داده شده‌اند که  $\alpha$  مقادیر ۰/۵، ۱، ۱/۱۵، ۰/۲، ۰/۲۵ و ۰/۳ را دارد.

در تمام موارد فوق از روش Levenberg Marquardt Optimization (تابع trainlm در نرم افزار MATLAB) برای یادگیری شبکه استفاده شده است [۲۹].

برای انتخاب بهترین شبکه، میانگین ضریب کاپا در پنج بار آموزش شبکه محاسبه و شبکه‌ای که بالاترین ضریب کاپا را روی مجموعه‌ی Validation داشت، به عنوان شبکه‌ی بهینه انتخاب گردید.

### ۶-۱-۲- مشخصات شبکه‌ی بهینه

پس از آموزش شبکه در حالت‌های مختلفی که در بالا ذکر شد و در هر حالت پارامترهای شبکه تغییر داده شد، مشخصات شبکه‌ی بهینه برای طبقه‌بندی نقاط تصویری به دو طبقه‌ی برنج و غیر برنج به شرح ذیل به دست آمد:

ضریب کاپا را روی مجموعه‌ی Validation دارا بوده، به عنوان شبکه‌ی بهینه انتخاب گردید.


### ۶-۲-۲ - مشخصات شبکه‌ی بهینه

بُردار ورودی شبکه به صورت ۶ بُعدی شامل مؤلفه‌های  $r$ ،  $g$  و  $b$  تصاویر ۲۲ خرداد و ۱۰ مرداد ۱۳۸۲ می‌باشد. تعداد نرون‌های دومین لایه مخفی ۶ نرون بوده و در لایه‌های مخفی از تابع Tansig و در لایه‌ی خروجی از تابع Purelin استفاده شده است. طبقه‌ها به صورت  $[-0.95, 0.95]$  برای کم‌محصول و  $[0.95, -0.95]$  برای پرمحصول نمایش داده شده‌اند.

یادگیری و بازدهی شبکه به تفکیک طبقه در (جدول ۳) درج گردیده‌اند. در (شکل ۶) نمودار یادگیری شبکه‌ی بهینه نمایش داده شده است. شبکه‌ی بهینه تفکیک مزارع برنج به پرمحصول و کم‌محصول دارای ضریب کاپای ۰/۶۷ می‌باشد.

جدول ۳ راندمان شبکه‌ی بهینه برای تفکیک مزارع برنج، به پرمحصول و کم‌محصول

مجموعه	تشخیص صحیح پرمحصول	تشخیص صحیح کم‌محصول	دقت کلی (%)	ضریب کاپا
Train	۹۵/۸۰٪	۸۵/۶۷٪	۹۱/۷۴	۰/۸۲۵
Validation	۹۵/۱۷٪	۷۸/۲۶٪	۹۲/۳۷	۰/۷۳۰
Test	۹۲/۴۰٪	۷۶/۸۲٪	۸۹/۵۹	۰/۶۶۶



شکل ۶ نمودار یادگیری شبکه‌ی عصبی برای تفکیک مزارع برنج، به پرمحصول و کم‌محصول

با ارزیابی نتایج، ملاحظه می‌شود شبکه‌ی بهینه، روی مجموعه‌های (جدول ۲) دارای دقت کلی ۹۸/۸۲ درصد و ضریب کاپا دارای مقدار ۰/۹۱۶ می‌باشد که با تفسیر ارائه شده برای ضریب کاپا توسط landis و koch [۱۵] نتایج شبکه در حد عالی می‌باشد.

### ۶-۲-۲ - مدل تفکیک گونه‌های برنج و نتایج

در بخش ۶-۱ با ارزیابی مدلی مناسب، نقاط تصویری را به دو طبقه‌ی برنج و غیر برنج تفکیک کردیم. حال می‌خواهیم مدلی ارائه کنیم که توسط آن، مزارع برنج به دو طبقه‌ی پرمحصول و کم محصول تفکیک شوند. در این قسمت، مشابه مدل شناسایی مزارع برنج، از شبکه‌ی عصبی MLP استفاده شده است که دارای دو طبقه‌ی برنج پرمحصول و کم‌محصول می‌باشد.

### ۶-۲-۱ - آموزش شبکه در حالات مختلف

هر یک از نمونه‌های ورودی (نقاط تصویری) دارای ۶ بُعد می‌باشند که همان مؤلفه‌های  $r$ ،  $g$  و  $b$  تصاویر ۲۲ خرداد و ۱۰ مرداد ۱۳۸۲ (مراحل رشد برنج) هستند. شبکه در حالت‌های مختلف زیر آموزش داده شده است و با بررسی نتایج آن‌ها پارامترهای مربوط به مدل بهینه انتخاب می‌گردند:

#### ۱- ورودی شبکه

ورودی شبکه در دو حالت بررسی شده است: - استفاده‌ی مستقیم از مؤلفه‌های  $r$ ،  $g$  و  $b$  تصاویر - استفاده از PCA برای کم کردن بعد نمونه‌های ورودی که شبکه به ازای ۵ و ۴ و ۳ ( $n$ ) تعداد بُردارهای ویژه‌ی انتخابی در آنالیز مؤلفه‌های اصلی می‌باشد) آموزش داده شده است.

#### ۲- تعداد نرون‌های لایه‌های مخفی

تعداد نرون‌های اولین لایه مخفی، برابر بُعد ورودی در نظر گرفته شده است و تعداد نرون‌های دومین لایه مخفی از ۲ تا ۸ نرون تغییر داده شد.

۳- توابع مورد استفاده در لایه‌ها و چگونگی نمایش طبقه‌ها مشابه مدل شناسایی مزارع برنج (بخش ۶-۱) می‌باشند.

برای انتخاب بهترین شبکه، میانگین ضریب کاپا در پنج بار آموزش شبکه محاسبه شده و شبکه‌ای که بالاترین



## ۶-۳-۲- انتخاب شبکه‌ی بهینه

با تغییر دادن پارامترهای شبکه - متناسب با آنچه در بالا گفته شد- برای انتخاب شبکه‌ی بهینه از معیار  $\frac{r_s}{E+S}$  استفاده شده است که  $r_s$  ضریب تخمین و  $\bar{E}$  میانگین قدر مطلق خطای نسبی و  $s$  انحراف معیار قدر مطلق خطای نسبی می‌باشند.

شبکه‌ای که روی مجموعه‌ی Validation بزرگ‌ترین مقدار معیار را داشته باشد به عنوان شبکه‌ی بهینه انتخاب می‌گردد.

## ۶-۳-۳- مشخصات شبکه‌ی بهینه برای برنج

## پرمحصول

ورودی‌ها، باندهای مادون قرمز نزدیک و قرمز تصاویر ۲۲ خرداد و ۱۰ مرداد ۱۳۸۲ می‌باشند. شبکه دارای ۹ نرون در لایه‌ی مخفی بوده که از تابع گوسین در لایه‌ی مخفی استفاده شده است. (جدول ۴) نتایج مدل بهینه برای برنج پرمحصول را نشان می‌دهد.

جدول ۴ نتایج مدل برنج پرمحصول

مجموعه	انحراف معیار قدر مطلق خطای نسبی	میانگین قدر مطلق خطای نسبی (%)	Rs
Train	۶/۰۳۲	۶/۸۵۲	۰/۷۴۷
Validation	۸/۵۴۲	۱۱/۸۶۲	۰/۳۶۴
Test	۷/۱۸۳	۱۱/۵۲۰	۰/۳۰۷

## ۶-۳-۴- مشخصات شبکه‌ی بهینه برای برنج

## کم محصول

ورودی‌ها، باندهای مادون قرمز نزدیک و باند قرمز تصاویر ۲۲ خرداد و ۱۰ مرداد ۱۳۸۲ می‌باشند. شبکه دارای پنج نرون در لایه‌ی مخفی بوده که از تابع گوسین در لایه مخفی استفاده شده است. (جدول ۵) نتایج برنج کم محصول را نشان می‌دهد.

جدول ۵ نتایج مدل برای برنج کم محصول

مجموعه	انحراف معیار قدر مطلق خطای نسبی	میانگین قدر مطلق خطای نسبی (%)	Rs
Train	۲/۲۶۵	۲/۶۳۴	۰/۹۲۵
Validation	۵/۴۱۷	۸/۱۹۲	۰/۲۶۰
Test	۹/۲۰۷	۹/۸۹۶	۰/۱۹۵

## ۶-۳-۳- مدل میزان محصول و نتایج

در بخش‌های ۱-۶ و ۲-۶ موفق شدیم با ارایه‌ی دو مدل شبکه‌ی عصبی، مزارع برنج را شناسایی و آن‌ها را به دو طبقه‌ی پرمحصول و کم محصول تفکیک نماییم. هدف از این بخش تهیه‌ی مدلی جهت تخمین میزان محصول برای هر یک از گونه‌های پرمحصول و کم محصول است. همان‌گونه که در بخش ۲-۴ گفته شد از شبکه‌ی عصبی RBF برای مدل نمودن میزان محصول استفاده می‌کنیم.

به دلیل محدودیت نمونه‌های تهیه شده از مزارع برنج (به ترتیب ۴۸ و ۱۸ نمونه برای برنج پرمحصول و کم محصول)، از روش Cross - Validation برای آموزش شبکه استفاده شده است.

در Cross Validation مجموعه‌ی اطلاعات به دو قسمت آموزش و آزمایش تقسیم و سپس مجموعه‌ی آموزش به K قسمت تقسیم می‌گردد و شبکه را K بار آموزش داده که هر بار یک بخش برای Validation در نظر گرفته و با K-1 قسمت دیگر شبکه، آموزش داده می‌شود. در این تحقیق از Cross Validation سه قسمتی استفاده شده است [۲۴].

## ۶-۳-۱- آموزش شبکه

شبکه به ازای حالات مختلف زیر، آموزش داده شده است:

۱- توابع RBF از توابع Multiquadric, Gaussian, Inverse multiquadric و Logistic, Thinplate در لایه‌ی مخفی شبکه‌ی عصبی استفاده شده است.

## ۲- ورودی شبکه

ورودی شبکه در چهار حالت بررسی شده است:

- باندهای مادون قرمز نزدیک و باند قرمز تصویر ۱۰ مرداد ۱۳۸۲ (۲ مشخصه)

- استفاده از هر سه باند تصویر ۱۰ مرداد ۱۳۸۲ (سه مشخصه)

- باندهای مادون قرمز نزدیک و باند قرمز تصاویر ۲۲ خرداد و ۱۰ مرداد ۱۳۸۲ (چهار مشخصه)

- استفاده از هر سه باند تصاویر ۲۲ خرداد و ۱۰ مرداد ۱۳۸۲ (شش مشخصه)

## ۳- تعداد نرون‌های لایه‌ی مخفی

برای برنج پرمحصول تعداد نرون‌های لایه‌ی مخفی از ۲ تا ۱۲ نرون و برای برنج کم محصول تعداد نرون‌ها از ۲ تا ۶ نرون تغییر داده شده‌اند.

جدول ۷ سطح زیر کشت برنج پرمحصول و کم محصول در منطقه مورد مطالعه

سطح زیر کشت برنج (ha)	سطح زیر کشت برنج پرمحصول (ha)	سطح زیر کشت برنج کم محصول (ha)
۸۶۳۶۵	۵۶۱۸۳	۳۰۱۸۲

با استفاده از مدل های سه گانه ی بالا میزان تولید برنج پرمحصول در منطقه ی ۲۵۶۰۶۱ (ton) و تولید برنج کم محصول ۸۵۱۷۷ (ton) برآورد شده است.

### ۷ - نتیجه گیری

استفاده از تصاویر سنجنش از دور در تعیین میزان تولید برنج می تواند ابزاری مهم در برنامه ریزی های اقتصادی کشور باشد.

در این تحقیق با استفاده از تصاویر ماهواره ای، مزارع برنج و سپس گونه های پرمحصول و کم محصول شناسایی شده اند و با استفاده از شبکه ی عصبی RBF میزان تولید برنج در واحد سطح مدل شده است.

با استفاده از تصاویر ماهواره ای در فصول مختلف سال زراعی می توان مزارع برنج را به وسیله ی شبکه ی عصبی MLP با دقت بالایی (ضریب کاپای ۰/۹۶) شناسایی کرد.

- در تفکیک گونه های برنج، با داشتن تنها دو تصویر طی دوره ی رشد برنج، نمی توان تفکیک با ضریب کاپای بالا، بین مزارع برنج پرمحصول و کم محصول ایجاد کرد و به تصاویر ماهواره ای بیشتری در دوره ی رشد برنج نیاز می باشد.

- در مدل میزان محصول در واحد سطح، با استفاده از اطلاعات دو تصویر نسبت به حالتی که از یک تصویر استفاده شده است نتایج بهتری بدست آمده است. همچنین با تابع گوسین نسبت به بقیه ی توابع نتایج مطلوب تری حاصل گردید. چون این نتایج به صورت قدر مطلق خطای نسبی بیان شده اند، حداکثر خطا نشان داده شده است و مسلماً خطا برای برآورد میزان محصول یک منطقه از این اعداد کمتر می باشد.

- این نتایج با استفاده از اطلاعات طیفی دو تصویر طی دوره ی رشد برنج به دست آمده است؛ به دلیل اختلاف زمانی در کاشت برنج در مناطق مختلف شمالی کشور استفاده از تصاویر بیشتر برای پایش دوره ی رشد برنج در مناطق مختلف و نیز افزایش اطلاعات زمینی از مزارع، می تواند در بهبود نتایج حاصله مؤثر باشد.

### ۴-۶ - برآورد میزان تولید برنج در منطقه ی مورد مطالعه

در این بخش با استفاده از مدل های به دست آمده در سه قسمت قبل برای تخمین میزان تولید برنج در منطقه ی مورد بررسی اقدام می کنیم. ابتدا مناطق ابری در تصاویر مشخص شده [۳۰] و با استفاده از مدل بهینه ی شناسایی مزارع برنج که در بخش ۶-۱ ایجاد شد، هر پیکسل غیر ابر به طبقه ی برنج یا غیربرنج نسبت داده می شود.

به دلیل این که مزارع برنج پیوسته بوده و کمتر به صورت منفرد یافت می شوند برای حذف پیکسل های منفردی که به عنوان برنج شناسایی گردیده اند از پنجره های ۳×۳ استفاده شده است. پیکسل مرکزی پنجره ای که به صورت یکی از ماسک های (شکل ۶) نباشد، به عنوان غیربرنج منظور می شود.

r	r	*	*	r	r	*	*	*	*	*	*
r	r	*	*	r	r	*	r	r	r	r	*
*	*	*	*	*	*	*	r	r	r	r	*

شکل ۶ پنجره های مورد استفاده برای حذف پیکسل های متفرق که به عنوان برنج شناسایی شده اند. (۲ نشان دهنده ی پیکسل برنج می باشد)

در مرحله ی بعد با استفاده از مدلی که برای تفکیک مزارع برنج ایجاد شد، هر پیکسل برنج به گونه ای پرمحصول و کم محصول نسبت داده می شود در (جدول ۶)، مساحت مناطق برنج و غیربرنج و در (جدول ۷) سطح زیر کشت هر یک از گونه های برنج درج شده است.

جدول ۶ مساحت مناطق تفکیک شده در منطقه مورد مطالعه

مساحت مناطق ابری (ha)	مساحت مناطق غیربرنج (ha)	سطح زیر کشت برنج (ha)	مساحت ناحیه (ha)
۱۶۸۳	۵۶۳۶۶	۸۶۳۶۵	۱۴۴۴۱۴

در نهایت با استفاده از شبکه ی عصبی RBF بهینه، که برای تخمین میزان محصول دو گونه ی برنج ایجاد گردید، میزان محصول به ازای واحد سطح محاسبه می شود (kg/ha) و مجموع محصول مناطق پرمحصول و کم محصول برابر کل تولید برنج در منطقه می باشد (هر پیکسل ۲۳ m × ۲۳ m می باشد)



- [6] Rasmussen, M. S. (1997). "Operational yield forecast using AVHRR NDVI data: reduction of environmental and inter-annual variability". *International Journal of Remote Sensing*, 18(5), 1059-1077.
- [7] Liu, W. T., & Kogan, F. (2002). "Monitoring Brazilian soybean production using NOAA/AVHRR based vegetation condition indices". *International Journal of Remote Sensing*, 23(6), 1161-1179
- [8] Groten, S. M. E. (1993). "NDVI - crop monitoring and early yield assessment of Burkina Faso". *International Journal of Remote Sensing*, 14(8), 1495-1515.
- [9] Gat, N., Erives, H., Fitzgerald, G. J., Kaffka, S. R., & Maas, S. J. (2000). "Estimating Sugar Beet Yield using AVIRIS-Derived Indices". Retrieved 14/06, 2002, from the World Wide Web: [http://makalu.jpl.nasa.gov/docs/workshops/00\\_docs/Gat\\_web.pdf](http://makalu.jpl.nasa.gov/docs/workshops/00_docs/Gat_web.pdf)
- [10] Yang C.M. and Su M.R., (1999), "Modeling Rice Growth from Characteristics of Reflectance Spectra", ACRS.
- [11] Weigand, C.L. and A.J. Richardson. 1984, "Leaf Area: Light Interception and Yield Estimates from Spectral Components Analysis," *Agronomy Journal*, Vol. 76, pp. 543-548.
- [12] Weigand, C.L. and A.J. Richardson. 1987, "Spectral Components Analysis: Rationale for Results for Three Crops" *International Journal of Remote Sensing*, Vol. 8, pp. 1011-1032.
- [13] Kavzoglu, Taskin, 2001, "An Investigation Of The Design And Use Of Feed-Forward Artificial Neural Networks In The Classification Of Remote Sensed Images", PHD Thesis, School Of Geography, The University Of Nottingham, Nottingham, UK.
- [14] Estes, J. E., Sailer, C. and Tinney, L. R. (1986) "Applications of artificial Intelligence techniques to remote sensing". *The Professional Geographer*, 38, 133-141.
- [15] Benediktsson, J. A., Swain, P. H. and Ersoy, O. K. (1990) "Neural network approaches versus statistical methods in classification of multisource remote sensing data". *IEEE Transactions on Geoscience and Remote Sensing*, 28, 540-551.
- [16] Kanellopoulos, I., Varfis, A., Wilkinson, G. G. and Mégier, J. (1992) "Land-cover discrimination in SPOT HRV imagery using an artificial neural network - a 20-class experiment". *I Sensing*, 13, 917-924.

## ۸- پیشنهادها

۱. بهینه کردن مدل تخمین میزان محصول برنج با استفاده از نمونه‌های بیشتر و همچنین استفاده از تعداد تصاویر بیشتر در طی رشد برنج.
۲. تفکیک گونه‌های برنج با استفاده از تصاویر قبل از کشت برنج (مراحل آماده‌سازی زمین‌های شالیزاری) و تصاویر بیشتری در طی دوره‌ی رشد برنج.
۳. به‌کارگیری تصاویر رادار، علاوه بر تصاویر چندطیفی، به منظور کاهش اثرات منفی غیر قابل استفاده بودن تصاویر ابری.
۴. برنج دارای دو مرحله‌ی رشد رویشی و زایشی است که مرحله‌ی رشد رویشی شامل افزایش مساحت سطح برگ و تعداد ساقه‌ها می‌باشد و رشد زایشی شامل مراحل تشکیل خوشه و دانه‌دهی است. رشد زایشی به دما، تعداد روزهای آفتابی و نوسانات دما در شب و روز وابسته بوده که در میزان عملکرد مؤثر می‌باشد [۳۱]. پیشنهاد می‌شود که از معیارهای رشد زایشی به‌همراه تصاویر ماهواره‌ای برای بهینه‌کردن تخمین میزان محصول برنج استفاده شود.

## ۹- سپاسگزاری

از سازمان فضایی ایران جهت همکاری و در اختیار قرار دادن تصاویر ماهواره‌ای، صمیمانه تشکر و قدردانی به‌عمل می‌آید.

## ۱۰- مراجع

- [1] Thurivengadachori s. And Hokeen K.A., (1994), *Crop Yield Prediction In Command Area Using Satellite Data*, ACRS. Retrieved 4-11, 2002. <http://www.gisdevelopment.net/aars/acrs/1994/ps1014.shtml>.
- [2] Shao, Yun et al (2001), *Rice Monitoring and Production Estimation using Multitemporal RADARSAT, Remote Sensing of Environment*, 76, 3, PP.310-325.
- [3] Doraiswamy P.C. And Cook P.W., (1995), *Spring Wheat Yield Assessment Using NOAA AVHRR Data*, *Canadian Journal Of Remote Sensing*, 21, 1, PP.43-51.
- [4] Sawasawa, Haig L.A., (2003), *Crop Yield Estimation: Integrating RS, GIS, Management And Land Factors*, MS thesis, International Institute For Geoinformation Science And Earth Observation, ENSCHEDE, Netherlands
- [5] Yang, C.M., and Su M.R., (1997). "Analysis of reflectance spectrum of rice canopy". *Chinese Journal of Agrometeorology*, 4, pp.87-95

[۳۱] کاظمی اربط، حمدالله (۱۳۷۴)، "زراعت خصوصی (غلات)", چاپ اول، مرکز نشر دانشگاهی.



**محسن سریانی**، متولد ۱۳۳۵ در مشهد است. او دوره‌ی کارشناسی را در رشته‌ی مهندسی برق - الکترونیک در سال ۱۳۵۹ در دانشگاه علم و صنعت ایران به پایان رساند. در سال ۱۳۶۴ با بورس وزارت علوم، جهت ادامه‌ی تحصیل به انگلستان رفت. مدارک کارشناسی ارشد و دکتری را به ترتیب در سال‌های ۱۳۶۶ و ۱۳۶۹ در رشته‌ی مهندسی الکترونیک با تخصص پردازش تصویر از دانشگاه هریوت-وات در شهر ادینبورگ اسکاتلند اخذ نمود. وی در حال حاضر استادیار گروه سخت افزار دانشکده‌ی مهندسی کامپیوتر دانشگاه علم و صنعت می‌باشد. زمینه‌های تحقیق مورد علاقه‌ی او آنالیز و پردازش تصاویر، پردازش تصاویر ماهواره‌ای، معماری سیستم‌های کامپیوتری و شبکه‌های سنسور بیسیم هستند.

نشانی (رایانامک) پست الکترونیکی ایشان عبارت است از: soryani@iust.ac.ir



**رضا قادری**، درجه‌ی کارشناسی را در رشته‌ی مهندسی برق- الکترونیک در دانشگاه فردوسی مشهد در سال ۱۳۶۸ به پایان رساند. کارشناسی ارشد در رشته‌ی برق- الکترونیک را از دانشگاه تربیت مدرس در سال ۱۳۷۰ دریافت نمود و مدرک دکتری در رشته‌ی برق- الکترونیک را در سال ۱۳۷۹ از انگلستان اخذ کرد. هم اکنون به عنوان استادیار دانشکده‌ی برق دانشگاه صنعتی نوشیروانی به تدریس اشتغال دارد.

نشانی (رایانامک) پست الکترونیکی ایشان عبارت است از: r\_ghaderi@yahoo.co.uk



**مهرداد هاشمی کمانگر**، کارشناسی را در رشته‌ی مهندسی برق- الکترونیک در دانشگاه شهید بهشتی در سال ۱۳۷۹ به پایان رساند. درجه‌ی کارشناسی ارشد را در رشته‌ی برق- الکترونیک از دانشکده فنی و مهندسی دانشگاه مازندران در سال ۱۳۸۳ دریافت نمود. هم اکنون در مؤسسه غیر انتفاعی شمال در دانشکده‌ی فنی و مهندسی به‌عنوان مربی گروه برق به تدریس اشتغال دارد.

نشانی (رایانامک) پست الکترونیکی ایشان عبارت است از: mehr\_kamangar@yahoo.com

[17] Paola, J. D. and Schowengerdt, R. A. (1994) "Comparisons of neural networks to standard techniques for image classification and correlation". Proceedings of the International Geoscience and Remote Sensing Symposium (IGARSS'94), Pasadena, USA, 1404-1406.

[18] Bruzzone, L., Conese, C., Maselli, F. and Roli, F. (1997) "Multisource lassification of complex rural areas by statistical and neural-network approaches". Photogrammetric Engineering and Remote Sensing, 63, 523-533.

[19] Chen, K. S., Huang, W. P., Tsay, D. H. and Amar, F. (1996) "Classification of multifrequency polarimetric SAR imagery using a dynamic learning neural network". IEEE Transactions on Geoscience and Remote Sensing, 34, 814-820.

[20] Hara, Y., Atkins, R. G., Yueh, S. H., Shin, R. T. and Kong, J. A. (1994) "Application of neural networks to radar image classification". IEEE Transactions on Geoscience and Remote Sensing, 32, 100-109.

[21] Bischof, H., Schneider, W. and Pinz, A. J. (1992) "Multispectral classification of Landsat-images using neural networks". IEEE Transactions on Geoscience and Remote Sensing, 30, 482-489.

[22] Heermann, P. D. and Khazenie, N. (1992) "Classification of multispectral remote sensing data using a back-propagation neural network". IEEE Transactions on Geoscience and Remote Sensing, 30, 81-88.

[۲۳] منہاج، محمد باقر (۱۳۷۹)، "مبانی شبکه‌های عصبی"، چاپ اول، تهران، مرکز نشر دانشگاه صنعتی امیرکبیر

[24] Haykin, Simon (1994), "Neural Networks A Comprehensive Foundation", Macmillan College Publishing Company.

[25] Orr Mork J.L. , (1996). Introduction To Radial Basis Function Networks , Center for Cognitive Science , University Of Edinburgh , Scotland.

[26] Ghosh J. And Nag A. (2001) , An Overview Of Radial Basis Function Networks , In Radial Basis Function Networks 2 , Howlet R.J. , Jain L.C.R. (Editors) , Physica-Verlag , PP. 1-36.

[27] Orr M.J.L , (1995) , Regularisation In The Selection Of Radial Basis Function Centers , Neural Computation , 7 , PP. 606-623.

[28] Orr M.J. , (1998) , Optimising The Widths Of Radial Basis Function , In Proc. Of Vth Brazilian Symposium On Neural Networks , Belo Harizonte , Brazil.

[29] Hagan, M. T., and M. Menhaj, (1994), "Training feedforward networks with the Marquardt algorithm," IEEE Transactions on Neural Networks, vol. 5, no. 6, pp. 989-993.

[۳۰] هاشمی کمانگر، مهرداد (۱۳۸۳)، "تخمین میزان محصول برنج با استفاده از تکنیک‌های سنجش از دور" پایان‌نامه‌ی کارشناسی ارشد، دانشکده‌ی فنی و مهندسی، دانشگاه مازندران.