

# استفاده از شبکه عصبی جهت تخمین درجه متامریزم

محمد امانی تهران

مربی

دانشکده مهندسی نساجی، دانشگاه صنعتی امیرکبیر

سیامک مرادیان

دانشیار

دانشکده مهندسی پلیمر و رنگ، دانشگاه صنعتی امیرکبیر

## چکیده

شبکه های عصبی طی دو دهه اخیر بعنوان مدل سازهای عمومی بشدت مورد توجه تحقیقات مختلف قرار گرفته و بکارگیری آنها در تحقیقات نتایج چشمگیری را به ارمغان آورده است. از سوی دیگر معادلات موجود جهت محاسبه اندیس متامریزم در بهترین شرایط دارای انحرافی برابر ۳۵٪ ( $PF/4=36$ ) با نتایج ارزیابی بصری می باشند. در مقاله حاضر سعی شده است که با بکارگیری فن آوری ارائه شده توسط شبکه های عصبی و بهره گیری از نتایج ارزیابی ۹۸ جفت نمونه واقعی متامریک، انواع معماری و ورودیهای شبکه جهت حصول يك مدل بهینه مورد بررسی قرار گیرد. نتایج بدست آمده مؤید کارایی شبکه عصبی پیشنهاد شده بعنوان جایگزین معادلات مطرح اندیس متامریزم است. بطوریکه همبستگی نتایج شبکه با ارزیابی های بصری تا حد کارایی  $PF/4=20$  بهبود یافته است.

## کلمات کلیدی

شبکه های عصبی، معماری شبکه، آموزش شبکه، اندیس متامریزم، ارزیابی بصری.

## Predicting the Degree of Metamerism Utilizing Artificial Neural Network

S. Moradian

Associate Professor

Textile Engineering Department,  
Amirkabir University of Technology

M. Amani

Lecturer

Polymer-Engineering Departmen.,  
Amirkabir University of Technology

## Abatract

*In the last two decades, Neural Network modelling has become a subject of much interest and its application in research work has provided vast improvements.*

*Metameric indices at their best, deviate by approximately 35% ( $PF/4=36$ ) from visual assessments, In the present article, the application of Artificial Neural Network for quantification of metamerism has been studied. Data from 98 real metmeric pairs with visual assessment values were used for training of network. Many type of networks with different architecture, activation function and input were exassment deviating only by 20% ( $PF/4=20$ ) and can therefore be a good potential candidate as examined to achieve the best results, the final trained network showed a good degree of correlation mith visual assessmet a substitute for previously proposed metmetric indices.*

## Keywords

*Artificial Neural Network, Architecture, Training, Metameric Indices, Visual Assessments.*

پدیده متاماریزم به شرایطی اطلاق می شود که دو نمونه با وجود اختلاف در منحنی های انعکاسی در شرایط معینی دارای مختصات رنگی یکسان باشند و با تغییر این شرایط اختلاف رنگ بین دو نمونه مشاهده می گردد. مهمترین عامل در بروز پدیده متاماریزم، منبع نوری است. تحقیقات مفصلی در ارتباط با ارائه اندیس مناسبی جهت متاماریزم صورت پذیرفته و هدف نهایی ارائه مدلی منطبق بر نتایج بررسی بصری بوده است [۱-۵].

در دو مقاله قبلی از این سری مقالات [۶،۷] جزئیات تهیه ۹۸ جفت نمونه واقعی متاماریک و بررسی صحت عملکرد اندیسهای مطرح در تطبیق با مشاهدات بصری گزارش گردید. نتایج نهایی نشانگر آن بودند که میزان تخمین تا حد کاملاً رضایت بخشی انجام نگرفته است. اثر تصحیح پارامریک نیز بلحاظ وجود اختلاف پایه بین اعداد گزارش شده توسط اندیسها و نتایج مشاهدات چشمی، کمک مثبتی به بهبود راندمان ننمود [۷].

در این مقاله سعی شده است که استفاده از مدل شبکه عصبی در ارائه اندیس متاماریزم مورد بررسی قرار گرفته تا بتوان تصویر روشنی از علل بروز اختلاف بین اندیسهای محاسباتی و نتایج بصری بدست آورد. در ابتدا شرح مختصری از شبکه های عصبی و سپس روش عملکرد ارائه خواهد گردید.

## ۱- شبکه های عصبی بعنوان مدل سازهای عمومی (ANN) Artificial Neural Network

استفاده از مدل شبکه های عصبی مصنوعی در تهیه مدل برای فرایندهای عملی از اواخر دهه ۷۰ به شدت مورد توجه قرار گرفت [۸]، این روند بخصوص با ارائه رایانه های سریع که امکان مدل سازی شبکه را به کمک یکسری محاسبات پی درپی فراهم می نمود، سرعت گرفت [۹].

هم اکنون به کمک نرم افزارهای آماده رایانه ای به راحتی می توان یک شبکه را طراحی نمود، با اطلاعات پایه آنرا آموزش داد و در نهایت عملکرد آنرا بررسی نمود [۱۰]. این مجموعه به عنوان شبکه های عصبی مصنوعی (ANN) بعنوان ابزاری مناسب جایگزین مطرحی برای معادلات قبلی می باشند.

### ۱-۱- اصول و معماری شبکه های عصبی [۸-۱۲]

یک شبکه عصبی مصنوعی یک سیستم پردازش اطلاعات شبیه به شبکه های عصبی حیاتی است و بعنوان یک مدل ریاضی عمومی طبق اصول زیر عمل می نماید.

۱- پردازش اطلاعات در واحدهای کوچک ساده ای بنام عصب

یا گره (Neuron) انجام می شود.

۲- اطلاعات مابین اعصاب توسط اتصالات تبادل می شوند.

۳- هر اتصال دارای یک ضریب وزنه (weight) اختصاصی

است که در داده عبوری ضرب می شود.

۴- هر عصب دارای یک تابع فعال سازی (Activation

Function) است که با اعمال آن به جمع اطلاعاتی که از

شبکه دریافت می کند، مقدار خروجی را می سازد. این

تابع بطور معمول غیر خطی (Nonlinear) است.

طبقه بندی شبکه های عصبی بر حسب ۳ عامل زیر انجام

می شود:

۱- معماری شبکه: نحوه اتصال گره ها به یکدیگر از لایه

ورودی تا لایه خروجی

۲- توابع فعال ساز مورد استفاده

۳- روش بدست آوردن ضرایب وزنه اتصالات (تربیت و آموزش شبکه).

بنابر بحث فوق شبکه عصبی دارای یک سیستم

محاسباتی نسبتاً ساده است که از لایه ورودی (عوامل مؤثر

بر مدل یا متغیرهای مستقل) شروع شده و تا لایه خروجی

(پاسخ مدل) ادامه می یابد. لذا در صورتیکه یک گره مطابق


شکل (۱) دارای سه اتصال به اعصاب لایه قبل باشد، مقدار

خروجی آن بصورت زیر محاسبه می شود.

$$y_{in} = w_1 x_1 + w_2 x_2 + w_3 x_3 + b \quad (1)$$

$$y_{out} = f(y_{in}) \quad (2)$$

$$f(y_{in}) = \frac{1}{1 + \exp(-y_{in})} \quad (3)$$



شکل (۱) نحوه اتصال یک عصب در شبکه.

معادله (۳) همان تابع فعال ساز است که در مثال فوق

بصورت یک منحنی S شکل (Sigmoid Shaped Curves) تعریف شده است.

معروف ترین توابع فعال ساز عبارتند از تابع خطی (معادله ۴)، تابع پله ای (معادله ۵)، تابع S شکل (معادله ۶)، تابع S شکل دو دویی (Binary Sigmoid) (معادله ۶)، تابع S شکل دو قطبی (Bipolar) (معادله ۷) و تابع تانژانت هیپربولیک (معادله ۸).

$$f(y) = y \quad (۴)$$

$$f(y) = \begin{cases} 1 & y \geq \theta \\ 0 & y < \theta \end{cases} \quad (۵)$$

$$f(y) = \frac{1}{1 + \exp(-\sigma y)} \quad (۶)$$

$$f(y) = \frac{1 - \exp(-\sigma y)}{1 + \exp(-\sigma y)} \quad (۷)$$

$$f(y) = \tanh(y) \quad (۸)$$

بسته به نوع کاربرد، انواع مختلف معماری و توابع فعال ساز در شبکه های عصبی به کار گرفته شده اند. تعداد لایه های مورد استفاده و نیز نحوه اتصال هر عصب به لایه های قبلی و بعدی به انواع حالت های متفاوت مطرح و هر یک در مکان خویش جایگاه مناسب دارند.

معمول ترین معماری در شبکه های عصبی، شبکه ای با یک لایه مخفی (Hidden Layer) و با اتصالات کامل (Fully Connected) است، بطوریکه هر گره ورودیهای خود را از کلیه گره های لایه قبل دریافت نموده و خروجی خود را به تمام گره های لایه بر تحویل می دهد.

در مقالات مختلف [۱۱، ۱۲] روش های سرانگشتی و تقریبی برای تخمین معماری، تعداد گره های لازم، نوع توابع فعال ساز و نیز تعداد اعداد تجربی لازم و روش آموزش ارائه شده است. بعنوان مثال برای شبکه تک لایه ای، تعداد گره ها در لایه میانی بین اعداد زیر پیشنهاد شده است.

الف - به تعداد عوامل ورودی تا دو برابر آنها

ب - مربع جمع عوامل ورودی و نتایج خروجی

ج - برابر عوامل ورودی و خروجی

حداقل اطلاعات لازم برای آموزش بین ۳ تا ۱۰ برابر تعداد اتصالات موجود در شبکه پیشنهاد شده است.

انتخاب توابع فعال ساز نیز به طور عمده متأثر از خواسته های مورد انتظار از مدل است. بعنوان مثال یک شبکه

محاسبه گر عملیات منطقی (AND, OR, ...) حتماً باید در لایه خروجی دارای تابع فعال ساز پله ای باشد. اما یک مدل ساز با خروجی پیوسته نمی تواند از چنین توابعی استفاده نماید. از سوی دیگر توابع S شکل منجر به محدود شدن دامنه خروجی در دو مرز مورد نظر می گردند، اما توابع خطی محدودیتی روی خروجی ایجاد نمی کنند.

## ۲-۱- آموزش شبکه و بررسی کارایی

### ۱-۲-۱- آموزش شبکه

مهمترین مرحله در تهیه یک شبکه عصبی پس از تعیین معماری و توابع فعال ساز، مرحله آموزش و بررسی کارایی شبکه است. همانگونه که قبلاً ذکر شده در این مرحله بکمک یک دسته از اطلاعات تجربی، مقادیر ضرایب وزنه و پس ماند ها (Bias) برای تحویل حداقل اختلاف بین خروجی های شبکه و مقادیر تجربی تعیین می شوند.

روش بکار گرفته شده در تعیین ضرایب و سرعت دستیابی به نتیجه مطلوب بسیار مهم و تعیین کننده است و در واقع ارائه روش های جدید آموزش در دهه هشتاد بود [۱۱] که موجب بکار گیری مجدد شبکه های عصبی پس از افول آن بعد از دوران طلایی اول (۱۹۵۰-۱۹۶۰) گردید.

گرچه می توان بدون اغراق ادعا نمود که هر هفته روش جدیدی برای آموزش شبکه های عصبی ابداع و یا روش های قبلی بهینه می شوند اما بطور خلاصه می توان یک شمای کلی از الگوریتم آموزش ارائه نمود.

اولین طبقه بندی روش های آموزش مربوط به آموزش با نظارت و بدون نظارت است (supervised and unsupervised). در آموزش با نظارت، همانگونه که اشاره شد از گروهی از اطلاعات که مقادیر پارامترهای ورودی و نتایج شبکه در آنها مشخص است جهت تعیین ضرایب استفاده می شود و بهترین ضرایب برای دستیابی به کمترین فاصله بین نقاط پیش گویی شده توسط شبکه و مقادیر تجربی (حداقل SSE) جستجو می گردند.

در آموزش بدون نظارت یا خود آموز (Self Organize) شبکه با دسته ای از ورودی بدون وجود خروجی یا مقادیر هدف روبرو است و در این شرایط آموزش در جهتی صورت می گیرد که موجب تولید خروجی های یکستان برای ورودیهای مشابه گردد. مسلم است که مسئله مطرح در این مقاله جزء گروه اول یعنی آموزش با نظارت است.

دسته بندی بعدی مربوط به معماری شبکه می شود بعنوان مثال روش های مورد استفاده در شبکه های دارای پس خور (Feed Back) یعنی اتصال از خروجیهای گره های جلویی به گره های لایه قبلی، متفاوت از روش های مورد

استفاده در شبکه های بدون پس خور (Feed Forward) است.

نظر به استفاده از شبکه های بدون پس خور در این پروژه از پایه ترین روش مطرح برای آموزش این شبکه ها یعنی انتشار به عقب (Back propagation) می توان استفاده نمود [۹]. گرچه به لحاظ استفاده از نرم افزار (Math Lab) [۱۰] و ابزار ویژه آن برای شبکه های عصبی، در عمل روشهای متفاوتی برای حصول نتیجه استفاده شده اند که در جای خود شرح داده خواهد شد.

### ۲-۲-۱- بررسی کارایی شبکه

پس از آموزش و حتی در حین جستجو برای بهترین ضرایب، همواره معیاری بعنوان تابع هدف مورد نیاز می باشد. این تابع معرف کارایی شبکه با پارامترهای مشخص است. میزان کارایی به دو روش بررسی می شود که در عمل بهره وری شبکه در هر دو روش مذکور، لازم و ملزوم، کارایی بالا است.

روش اول بررسی فاکتورهای آماری بین خروجیهای شبکه و اعداد محاسباتی است. مرادیان و امانی [۷] بررسی نسبتاً کاملی را روی این پارامترها انجام داده اند و نشان دادند مقادیر SSE [۱۳] و  $P/4$  [۱۴] در این راستا می توانند فاکتورهای مناسبی باشند.

بدست آوردن فاکتورهای مناسب در این روش نشانگر نحوه تطبیق نتایج شبکه با اطلاعات تجربی است. اما روش دوم معرف توسعه پذیری و قابلیت استفاده از شبکه روی اطلاعاتی است که در گروه داده های آموزشی نبوده اند و به اصطلاح میزان شکل گیری شبکه و مدل در ارائه نتایج روی داده های جدید است.

در این روش نیز از همان فاکتورهای آماری قبل استفاده می گردد اما محاسبات روی اعدادی صورت می گیرد که در گروه آموزش نبوده اند. بدین منظور لازم است ابتدا تعدادی از داده های تجربی جدا شده و در مرحله آموزش بکار نروند و پس از اتمام آموزش بعنوان ابزار آزمون کارایی بهره برداری شوند.

مسلم است در شبکه های عصبی نیز شرایطی مشابه استفاده از چند جمله ای ها (Polynomial) در تولید مدل ریاضی برای داده های تجربی برقرار است، به اینصورت که هر چه درجه چند جمله ای بالاتر می رود، شانس عبور از نقاط تجربی بیشتر می شود، ولی با حدوث پستی و بلندی بین نقاط، میان یابی و برون یابی بسیار ضعیفی حاصل خواهد گردید.

## ۲- طراحی شبکه و روش کار مقدماتی

در این بخش روش تشکیل شبکه و مراحل انجام کار تشریح شده است. در ابتدا به بررسی نحوه انتخاب ورودیها پرداخته می شود. همانگونه که قبلاً در مقدمه ذکر شد، هدف طراحی شبکه ای است که بتواند اندیس متاماریزم را تولید نماید لذا خروجی شبکه یکتا و مشخص است، اما انتخاب ورودی می تواند بسیار متفاوت باشد.

### ۲-۱- انتخاب ورودی های شبکه

در سیستمی که رنگ شیئی پشت پوش حاصل از انعکاس طیفی است، مسلماً پایه ترین پارامتر در تعیین مختصات رنگی مقادیر انعکاس طیفی شیئی (R) در محدوده طول موج مرئی می باشد. مطابق معمول در تکنولوژی رنگ این مقادیر در فواصل ۲۰ نانومتر از طول موج ۴۰۰ تا ۷۰۰ نانومتر اندازه گیری شده و بصورت ۱۶ عدد بین صفر تا یک معرف انعکاس طیفی هر نمونه می باشند.

از سوی دیگر طبق سیستم های رنگ منظم مثلاً CIE، انواع مختلف محورهای سه گانه رنگی داده شده اند که رنگ در سیستمهای CIE [۱۵] و مانسل [۱۶] معرف محرکهای رنگی پس از اثر گذاری منبع نوری و توابع مشاهده کننده استاندارد است.

بنابراین انواع ورودیهای ذیل مد نظر قرار گرفتند:

$$1- ۱۶ \text{ عدد قدر مطلق اختلاف انعکاسها در هر طول موج } -R_{ij}$$

$$2- ۳ \text{ عدد قدر مطلق تفاضل مقادیر محرکهای سه گانه } [۱۵] \text{ CIE } |Z_1 - Z_2| \text{ و } |Y_1 - Y_2| \text{ و } |X_1 - X_2|$$

$$3- ۳ \text{ عدد قدر مطلق تفاضل مقادیر سه گانه } L^*a^*b^* \text{ دکارتی } [۱۶] |b^*_1 - b^*_2| \text{ و } |a^*_1 - a^*_2| \text{ و } |L^*_1 - L^*_2|$$

$$4- ۳ \text{ عدد مقادیر تفاضل نرمال شده مختصات استوانه ای } L^*C^*H^* \text{ مطابق فرمول نرمال سازی CIE94 [۱۷]}$$

$$\frac{L^*_1 - L^*_2}{S_L}, \frac{C^*_1 - C^*_2}{S_C}, \frac{H^*_1 - H^*_2}{S_H}$$

$$5- ۳ \text{ عدد مقادیر مؤثر در محاسبه اندیس متاماریزم MI6 [۱۸]}$$

$$\sum [w_\lambda (\Delta L_\lambda)^2], \sum [v_\lambda (\Delta L_\lambda)^2], \sum [u_\lambda (\Delta L_\lambda)^2]$$

### ۲-۲- انتخاب معماری شبکه

به لحاظ ماهیت اندیس متاماریزم و اینکه همه ورودیها نقش نسبتاً مشابهی در تولید یکتا خروجی شبکه دارند، لذا معماری اتصال همه جانبه و شبکه بدون پس خور مناسبترین مدل انتخابی است.

شبکه مورد نظر برای ورودیهای مختلف با یک تا دو لایه مخفی و تعداد گره های متفاوت آزمون شدند تا بهترین نتایج بدست آید. در عمل جهت احتراز از شبکه ای پیچیده که به همت تعداد بی شمار گره ها و ساختار بتواند یک تطبیق موضعی با نتایج را نشان دهد، از تعداد گره بیش از دو برابر تعداد ورودی استفاده نشده است.

### ۳-۲- روش آموزش و آزمون کارایی

اطلاعات مربوط به ۹۸ جفت نمونه واقعی متماریک که توسط امانی [۱۹] تهیه شده بود، بعنوان پایه اطلاعات واقعی انتخاب شده اند. در این میان ۸ نمونه بصورت تصادفی جدا شده و در مرحله آموزش استفاده نشده اند و به عنوان معیار الگوپذیری شبکه ها به کار رفته اند (آزمون کارایی).

در ابتدا برای بررسی میزان اطمینان به شبکه عصبی، [۲۰] از اعداد محاسباتی \* تحت ۳ منبع نوری TL84,A,D65 [۲۱] استفاده گردید تا پس از انتخاب \* اندیس اختلاف رنگ طبق فرمول CIELAB [۲۰] بهترین ترکیب، سیستم روی نتایج مشاهدات بصری تعمیم داده شود.

علت استفاده از اندیس CIELAB در وهله اول بجای مقیاس خاکستری حاصل از مشاهدات بصری آن است که در ابتدا بتوان بودن حضور خطا در اعداد، بر آورد اولیه ای از سیستم به عمل آورد.

### ۴-۲- نتایج بدست آمده در ارتباط با معماری و نوع ورودیها

از میان پنج پیشنهاد ارائه شده در بخش ۱-۲ جهت پارامترهای ورودی میتوان یک دسته بندی دو حالتی فرض نمود.

#### ۱-۴-۲- گروه ورودی $\Delta R$

#### ۲-۴-۲- گروه ورودیهای سه گانه

نظر به مورد توجه قرار دادن گروه اول در بیشتر مطالعات رنگ همانندی [۲۲]، ابتدا به بررسی عملکرد این گروه می پردازیم. استفاده از  $\Delta R$  بعنوان ورودی نیاز به نرمال سازی نداشته و اعداد در محدوده یک و صفر هستند.

انواع شبکه ها با یک تا دو لایه مخفی و وجود ۲ تا ۳۲ عدد گره در لایه مخفی مورد بررسی قرار گرفت که در آن، ۹۰ داده مقادیر اختلاف رنگ CIELAB تحت منبع نوری A جهت آموزش و ۸ داده جهت آزمون کارایی بکار گرفته شده است و نتایج ذیل حاصل گردید:

الف - عملکرد سیستم تک لایه مخفی (۳ لایه) بهتر از شبکه دو لایه مخفی (۴ لایه) بود.

ب - با تعداد گره کمتر از ۵ عدد در لایه مخفی، خطا قابل کاهش تا سطح قابل ملاحظه ای نبود.

ج - در صورت اعمال ۶ تا ۱۲ گره ر لایه مخفی، شبکه به سرعت آموزش دیده و خطا روی نقاط به مرز دلخواه می رسیدند ( $SSE=0.2$ ). اما الگوپذیری شبکه بسیار ضعیف بوده و نتیجه اندیس روی اطلاعات خارج از آموزش ناامید کننده بود. شکل ۲ نشانگر این نتایج با بهترین شبکه انتخابی است.

نظر به پراکنده بودن نقاط در شکل ۲ می توان علت این پدیده را در دلایل ذیل خلاصه نمود:

الف - زیاد بودن تعداد ورودیها منجر به ازدیاد تعداد ضرایب و ضعیف شدن الگوپذیری شبکه می گردد. بعنوان مثال با داشتن یک لایه مخفی و با ۱۲ گره حداقل ۱۷۰ ضریب باید محاسبه گردند که با حدود ۹۰ داده آموزشی مسلماً نتایج، بسادگی شبیه به خروجی دلخواه می گردند در حالیکه شبکه الگو نپذیرفته است. ب - همانگونه که دانسته است کلیه معادلات اختلاف رنگ بصورت غیر خطی، پیچیده و با در نظر گرفتن مشخصات منبع نوری و مشاهده کننده استاندارد تهیه شده اند که هیچ یک از این عوامل در  $\Delta R$  وجود ندارد. ارائه شبکه ساده ای که بتواند بر کلیه این پیچیدگی ها فائق آید مسلماً مشکل بوده و نیازمند حجم بالای اطلاعات آموزشی می باشد.

### ۲-۴-۲- گروه ورودیهای سه گانه

در این شرایط با تعداد محدودی ورودی مواجه بوده و نتایج بررسی به شرح ذیل طبقه بندی شده اند. الف - سیستم تک لایه مخفی بخوبی قادر به ارائه مدل برای شرایط فوق بود.

ب - تقریباً در تمامی ۴ مورد پیشنهاد شده در بخش ۱-۲ حتی در شرایطی که خطا روی نقاط آموزشی از یک مرز مشخص ( $SSE=20$ ) کاهش نمی یافت ولی الگوپذیری شبکه بسیار مناسب بوده است.

ج - تعداد گره ها بین ۳ الی ۷، نتایج بهینه ای ایجاد می نمودند. د - بهترین عملکرد مربوط به پیشنهاد شماره ۴ یعنی تفاضل مختصات نرمال شده  $I^*C^*H^*$  بودند. گرچه عملکرد بقیه پیشنهادات نیز چندان فاصله ای از این پیشنهاد نداشتند. ه - نتایج پیشنهاد اول و پنجم در صورت استفاده از اطلاعات ۳ منبع نوری چندان مناسب نیستند، زیرا ورودیهای یکسان در این حالت باید خروجیهای متفاوت را پیش بینی نمایند! این پیشنهاد بطور طبیعی برای ارائه اندیس متماریزم که مستقل از منبع نوری است می تواند مورد

توجه قرار گیرد.

شکل ۳ و ۴ نشانگر میزان کارایی شبکه برای پیشنهادهای ۵ و ۴ بر روی ۸ داده بکار رفته جهت آزمون کارایی است.

## ۲-۵- جمع بندی روی آزمون های مقدماتی

از نتایج بدست آمده از قسمت قبل می توان نتیجه گیری نمود که یک شبکه ۳ لایه با ورودیهای سه گانه طبق پیشنهاد ۴ بخش ۱-۲ می تواند الگوی مناسبی جهت بکار گیری در مدل واقعی باشد. در ضمن، در برآورد اندیس متاماریزم میتوان به پیشنهاد ۵ بخش ۱-۲ نیز توجه نمود.

## ۳- نتایج شبکه بر پایه داده های حاصل از مشاهدات بصری

مرادپایان و امانی [۷] نحوه اندازه گیری و محاسبه اندیس متاماریزم بر روی ۹۸ جفت نمونه واقعی متاماریک مورد استفاده قرار گرفته را به کمک مشاهدات بصری گزارش نموده اند. بکارگیری این داده ها مبنای نتایج بدست آمده در این بخش است.

## ۳-۱- بررسی عملکرد شبکه عصبی بر روی مقادیر اختلاف رنگ نمونه ها

در ابتدا با توجه به اینکه مشاهده کنندگان تحت سه منبع نوری TL84, A, D65 اعداد مقیاس خاکستری را گزارش نموده اند، شبکه با ۲۷۰ داده حاصل از ۳ منبع نوری تربیت گردید و راندمان بر روی ۲۷۰ داده آموزشی و ۲۴ داده آزمون کارایی (۸ داده از هر منبع نوری) بررسی گردید.

شبکه مورد نظر بصورت یک لایه ۷ گره ای مخفی با ورودیهای پیشنهاد ۴ بخش ۱-۲، تابع فعال ساز تانژانت هیپربولیک (tansig) برای لایه اول و تابع فعال ساز لایه خروجی خطی (Purelin) انتخاب گردید. روش آموزش (Leven berg - Marquard) (Learning Rate) و سرعت آموزش برابر ۰/۱ مورد استفاده قرار گرفت.

مقدار SSE پس از ۲۰۰ تکرار به حداقل مقدار ۶۲/۷ محدود گردید.

شکل ۵ نشان دهنده نحوه تطبیق داده های آموزشی و شکل ۶ مقایسه مقادیر محاسبه شده شبکه روی داده های آزمون کارایی می باشند.

## ۳-۲- بررسی عملکرد شبکه عصبی جهت تخمین درجه متاماریزم

جهت ایجاد امکان مقایسه و نیز دستیابی به هدف مقاله، شبکه نهایی بر روی اعداد مقیاس خاکستری حداکثر، در بین منابع نوری، طراحی و پیاده سازی گردید.

در این شبکه از دو نوع ورودی پیشنهاد ۴ و ۵ بخش ۱-۲

استفاده شده است.

توابع فعال ساز مختلفی در لایه مخفی استفاده شد که بهترین راندمان، متعلق به تابع (Logsig) و (tansig) بودند. بقیه مشخصات شبکه نیز مشابه بخش ۱-۲ بود.

مقادیر SSE پس از ۲۰۰ تکرار به حداقل مقادیر داده شده در جدول ۴ محدود گردیدند.

شکلهای ۷ و ۸ نشان دهنده نحوه تطبیق نتایج شبکه اول (پیشنهاد ۴ بخش ۱-۲) با داده های آموزشی و داده های آزمون کارایی می باشند.

شکلهای ۹ و ۱۰ نیز بطور مشابه نشانگر رفتار شبکه دوم (پیشنهاد ۵ بخش ۱-۳) می باشند.

نظر به عملکرد بهتر تابع فعال ساز (tansig) روی الگوگیری شبکه از این تابع در محاسبات بعدی استفاده شد.

نتایج مطالعات آماری بر روی دو شبکه مطرح شده در فوق در جدول ۵ ارائه شده است.

مقایسه اعداد گزارش شده در جدول ۵ با نتایج بدست آمده از اندیس های مطرح قبلی که حداقل مقدار PF/4 برابر ۳۶ داشتند [۷] نشانگر عملکرد بهینه شبکه عصبی است.

جدول شماره ۶ و شکل شماره ۱۱ بترتیب نشانگر ضرایب و معماری شبکه نهایی پیشنهاد ۴ بخش ۱-۲ می باشند.

## ۴- نتیجه گیری و پیشنهادات

با توجه به مباحث مطرح شده در مقاله فعلی، روشن است که استفاده از شبکه عصبی با ورودیهایی که تحت تأثیر منبع نوری و مشاهده کننده استاندارد قرار گرفته و نرمال شده اند و یا ورودیهای نرمال شده طبق پیشنهاد ۵ بخش ۱-۲ می توان بهبود مناسبی به عملکرد سیستمهای پیش بینی کننده اندیس متاماریزم داد و در این میان ورودیهای  $\frac{\Delta C^*}{S_C}$ ،  $\frac{\Delta H^*}{S_H}$ ،  $\frac{\Delta L^*}{S_L}$  با اختلاف اندک انتخاب بهتری می باشند.

از سوی دیگر بنظر می رسد اعداد گزارش شده بعنوان میانگین ارزیابی بصری مشاهده کنندگان حتی برای اختلافات بسیار کوچک همواره از یک مقدار حداقل کمتر نمی باشد. (نقاط تراکم در  $\Delta V=2$  در شکل های ۷ و ۵) و بیشترین اختلاف بین ارزیابی بصری و روش شبکه عصبی نیز در این محدوده قرار گرفته است.

شاید بتوان با بکارگیری افراد متخصص در زمینه رنگ و آشنا به ارزیابی های بصری و تکرار آزمون برای هر فرد در جفت نمونه های واقعی با اختلاف رنگ در محدوده حد روداری صنعتی و یا نوعی نرمال سازی ارزیابی افراد مبتنی بر نتایج ارزیابی هر فرد بر روی نمونه های از قبل تهیه شده با اختلاف رنگ دانسته، براین مشکل فائق آمد.

جدول (۴) مقادیر SSE در شبکه اندیس متاماریزم.


نوع ورودی شبکه	SSE Tansig	SSE Losig
پیشنهاد ۴ (L*C*H* نرمال شده)	۲۳/۲	۱۷/۵
پیشنهاد ۵ (MI6)	۳۴/۵	۲۷/۸

جدول شماره (۵) نتایج محاسبات آماری بر روی اندیس متاماریزم حاصل از شبکه.


نوع ورودی شبکه	داده های آموزشی					داده های آزمون کارایی				
	%Err	r	%Cv	$\gamma$	PF/4	%Err	r	%Cv	$\gamma$	PF/4
پیشنهاد ۴ (L*C*H*)	23	0.85	18.6	1.26	21.0	24	0.75	23.8	1.24	23.4
پیشنهاد ۵ (MI6)	24	0.79	19.9	1.26	22.4	35	0.32	35.9	1.43	45

جدول شماره (۶) مقادیر ضرایب وزنه و پس ماند برای شبکه نهایی.


شماره اندیس نام	1	2	3	4	5
Wi1=	-23.3293	13.0064	170.6783	-0.9264	-0.4736
Wi2=	15.8173	67.5764	16.3870	-2.4765	0.3900
Wi3=	-1.2228	-27.9156	-34.1639	-1.3252	0.0613
W0=	-0.4070	0.1853	-1.0534	-1.6193	10.6924
Bi=	6.4228	-46.1614	27.8615	8.2353	1.8199
Bo=	-5.1731				




شکل (۳) مقایسه نتایج خروجی شبکه عصبی با ورودی پیشنهاد ۴ بر روی داده های آزمون کارایی در پیش بینی اختلاف رنگ CIELAB تحت منبع نوری A.



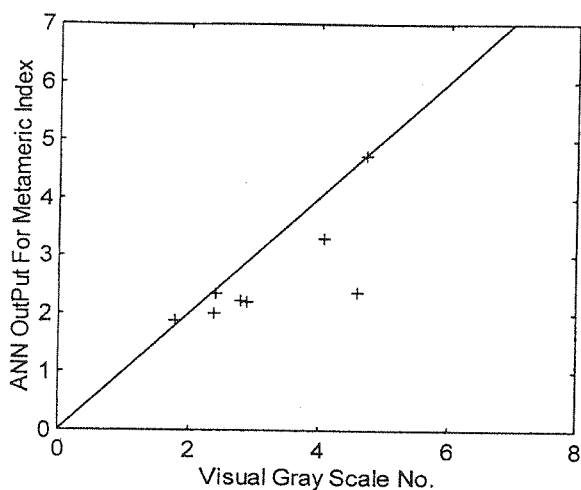
شکل (۲) مقایسه نتایج خروجی شبکه عصبی با ورودی  $\Delta R$  بر روی داده های آزمون کارایی در پیش بینی اختلاف رنگ CIELAB تحت منبع نوری A.



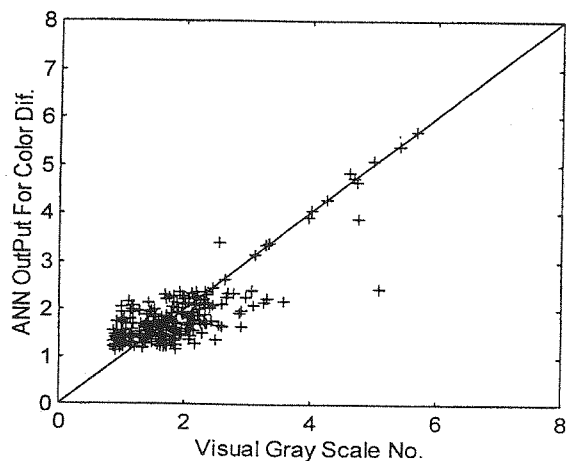
شکل (۷) مقایسه نتایج خروجی شبکه با ورودی شماره ۴  
بر روی اعداد آموزشی اندیس متامریزم



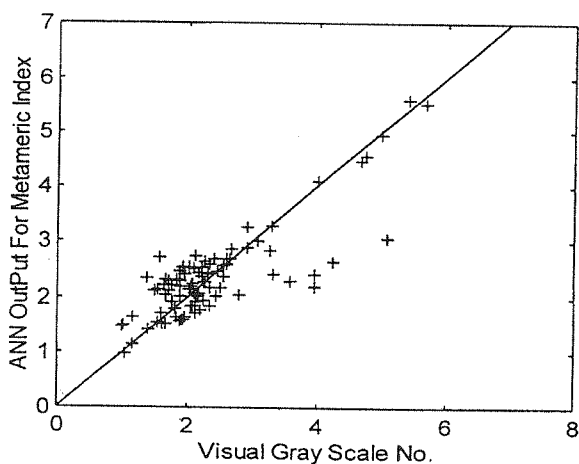
شکل (۴) مقایسه نتایج خروجی شبکه عصبی با ورودی پیشنهاد ۵  
بر روی داده های آزمون کارآیی در پیش بینی  
اختلاف رنگ CIELAB تحت منبع نوری A




شکل (۸) مقایسه نتایج خروجی شبکه با ورودی شماره ۴  
بر روی اعداد آموزشی اندیس متامریزم.



شکل (۵) مقایسه نتایج خروجی شبکه عصبی با ورودی پیشنهاد ۴ بر  
روی داده های آموزشی تحت سه منبع نوری ( $r=0.82, PF/425$ ).




شکل (۹) مقایسه نتایج خروجی شبکه با ورودی شماره ۵ بر روی  
اعداد آموزشی اندیس متامریزم.

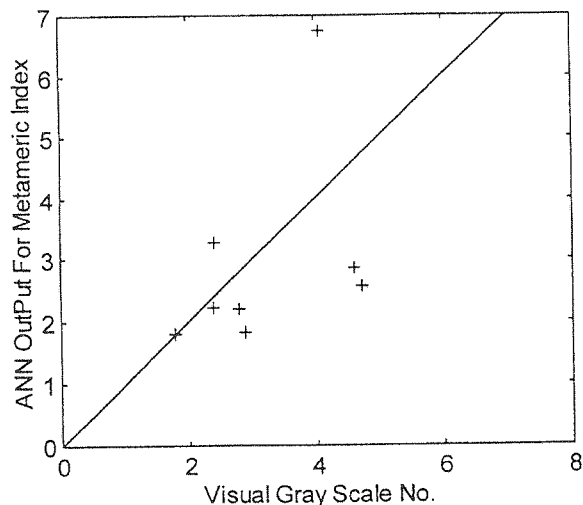


شکل (۶) مقایسه نتایج خروجی شبکه عصبی با ورودی پیشنهاد ۴ بر  
روی داده های آموزشی تحت سه منبع نوری ( $r=0.82, PF/425$ ).





شکل (۱۱) معماری شبکه نهایی.



شکل (۱۰) مقایسه خروجی شبکه با ورودی شماره ۵  
بر روی اعداد آموزشی اندیس متمازیم.

## مراجع

- [1] W.G.Kuo and M.R.Luo, "Methods for Quantifying Metamerism, Path I-Visual Assessment", J.S.D.C., Vol.112, Nov 1996, 312.
- [2] Tracey Badcock, "Accuracy of Metameric Indices in relation to Visual Assessment", J.D.S.C., Vo.31, 1992.
- [3] Saeed Parvaneh, "Metameric Correction With Matrix R", Msc.Thesis, Amirkabir Univ., 1998.
- [4] W.G.Kuo and M.R. Luo, "Methods for Quantifying Metamerism, Path II-Instrumental Methods", J.S.D.C., Vol.112 Dec 1996, 354-360.
- [5] A.K. Roy Choudhury, S.M. Chatterjee, "Evaluation of the performanc of metameric Indices", Color Res. And Appl., Vol.21 No1, 1996.
- [6] S.Moradian, M.Amani, "Perparation and behavior Study of Real Metameric Pairs", Amirkabir Journal of Technology, 2000.
- [7] S.Moradian, M.Amani, "Perparation Study of Metameric Indices and Effectiveness of Parameric Correction on Real Metameric Pairs", Amirkabir Journal of Technology, 2000.
- [8] Laurene Fausett, "Fundamental of Neural Networks", Prentice Hall, 1994.
- [9] H. White, "Learning in Artificial Neural Networks: A statistical Perspective", Neural Computation, 1, 1989, 426-464.
- [10] Math Works Inc., "Math Lab for Windows, ANN Tool Kit", Ver. 4.2cl, Oct.1994.
- [11] S.Gemman, E. Bienenstock, R. Doursat, "Neural Network and the Bias, Variance Dilemma", Neural Computation, 4, 1-58, 1992.
- [12] H. White, "Artificial Neural Networks: Approximation and learning theory", BlackWell, 1992.
- [13] R.H. Myers, RE. Walpole, "Probability and Statistics for Engineers and Scientist", 2Ed. Macmillan Pub.1978.
- [14] E. Coates, K. Fong and B.Rigg, J.S.D.C., 97, 1981, 79.
- [15] CIE "A Uniform Color Space utilizing an Adams-Nickerson cube root formula", CIELABL\*a\*b\* Color Space, 1976.
- [16] Munsell and etc., "Munsell Natural Value Scale", J.Opt. Soc. Am., 23, 1933.
- [17] S. Oglesby, "The Effectiveness of CIE 94 Compare with the CMC equation", J.S.D.C., 111, 1995, 380.
- [18] S. Moradian and B. Rigg, "The Quantification of Metamerism", J.S.D.C., 103, 1987, 209.
- [19] M. AMANI, "Metameric Indices based on Parameric Decomposition in relation to Visual Assessment", Ph.D.thesis, Amirkabir Uni.2000.
- [20] Richard S.Hunter and R.W.Harold, "The Measurement of apperance", 2 ed, John Wiely Pub, 1987.
- [21] CIE, "International Commission on Illumination", Propceedings of the eight session, Cambridge, England, 1931.
- [22] E.Allen, "Colorant Formuation and Shading in Optical Radiation measurement", Vol.2, Academic Press, New York, 1980.