



ارائه شده توسط:

سایت ترجمه فا

مرجع جدیدترین مقالات ترجمه شده

از نشریات معتبر

توسعه شبکه های عصبی برای کاهش نویز

چکیده

این مقاله، توسعه مدل شبکه عصبی برای کاهش نویز را تشریح می کند. این شبکه به منظور ارتقاء عملکرد مدل سازی سیگنال از طریق کاهش اثر نویز مورد استفاده قرار می گیرد. هر دو مدل های شبکه عصبی انتشار بازگشتی و چند لایه بررسی می شوند و در مقایسه با الگوریتم های مختلف آموزش قرار می گیرند. این مقاله برای نشان دادن اثر الگوریتم های آموزش و معماری شبکه بر عملکرد شبکه های عصبی برای یک برنامه معین ارائه شده است.

کلمات کلیدی: کاهش نویز، شبکه های عصبی بازگشتی، انتشار خلفی چند لایه.

1. مقدمه

در سیستم های فیزیکی، سیگنال های انتقال یافته معمولا به صورت جزئی، و یا گاهی اوقات تقریبا به طور کامل، با نویز اضافی از فرستنده، کانال و گیرنده توزیع شده اند. رویکرد مورد بررسی قرار گرفته در این کار، در نظر گرفتن کاهش نویز به عنوان یک فرایند اساسا مورد نیاز به منظور ارتقای روند برآورد بازسازی تصویر از سیگنال گرفته شده است. کاهش نویز به عنوان یک فرایند نگاشت مستمر از داده های ورودی پر نویز به داده های خروجی عاری از نویز در نظر گرفته می شود. سیگنال ارتقا یافته حاصل را می توان برای روند تصویربرداری هولوگرافی اعمال نمود که عملکرد مدل تخمین زده شده را بهبود می بخشد. شبکه های عصبی مصنوعی (شبکه های عصبی) استفاده روزافزون خود را در مسائل کاهش نویز پیدا کرده اند [1]، 2، 3، 4، 7، 8، 12، 13، 16، [17]، و هدف اصلی از طراحی این شبکه های عصبی (NNS)، بدست آوردن یک تقریب خوب برای برخی از نگاشت های ورودی-خروجی است. علاوه بر به دست آوردن یک تقریب معمولی، انتظار می رود NNS از داده های آموزش تعمیم داده شود. این تعمیم، برای استفاده از اطلاعاتی است که NN در مرحله آموزش به منظور سنتز، مشابه ولی نه یکسان، نگاشت ورودی-خروجی آموخته است. [11]

در این مقاله، دو معماری مختلف به کار گرفته می شوند. اینها شبکه های عصبی بازگشتی (RNNs) و شبکه های عصبی چندلایه (MLNNS) هستند. هر دوی این شبکه ها با پنج الگوریتم آموزش دیده اند. توابع آموزش مورد استفاده عبارتند از: پس پراکنی نزولی گرادیان (traingd)، نزولی گرادیان با حرکت پس پراکنی (traingdm)، شیب نزولی با پس پراکنی تطبیقی lr (نرخ یادگیری) (traingda) شیب نزولی w / پس پراکنی حرکتی و تطبیقی (traing DX)، LR و پس پراکنی Marquardt Leverberg (trainlm).

NNS طراحی شده با دنباله های ورودی آموزش می بینند که تصور می شود یک ترکیب سیگنال مورد نظر به همراه یک نویز گوسی افزودنی باشد. انتظار می رود شبکه ها داده های آموزشی پرنویز را با خروجی مربوطه مورد نظر و تعمیم مدل یاد بگیرند. این تحقیقات، تلاشی برای به کار گیری ANN در افزایش سیگنال اندازه گیری خراب شده و کاهش نویز است. سهم اصلی شامل موارد زیر است:

- دنباله های ورودی آموزش برای NNS طراحی شده به عنوان یک ترکیبی از سیگنال مورد نظر به همراه یک نویز گوسی افزودنی در نظر گرفته می شوند. این فرض به روند یادگیری سرعت می بخشد و تقریب مدل مورد نظر را بهبود می بخشد. [15]

- توسعه و مقایسه معماری NN برای استفاده در برنامه های کاهش نویز.
- مقایسه عملکرد مدل سازی با استفاده از چند لایه و NNS بازگشتی
- بررسی رابطه بین عملکرد آموزش و سرعت در الگوریتم های آموزش مورد استفاده برای معماری NN معین

2. شبکه های عصبی مصنوعی

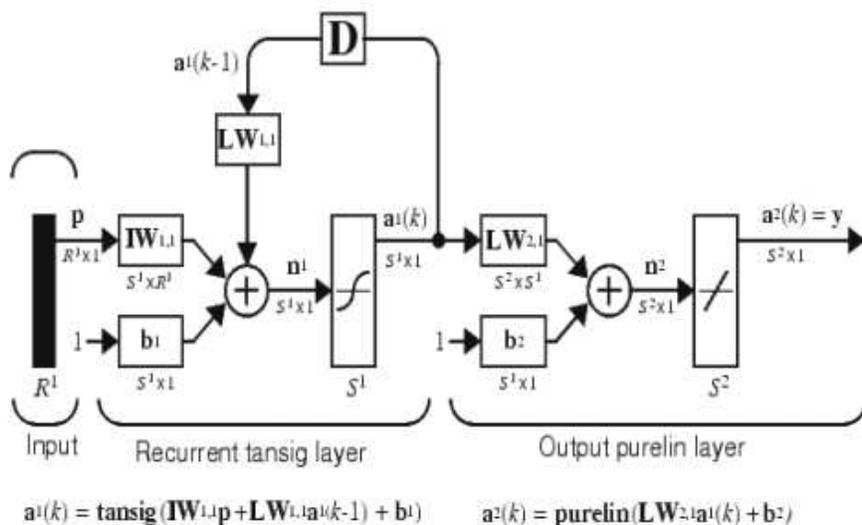
دو فاز اصلی در بهره برداری ANN وجود دارد: یادگیری و آزمایش. آموزش، روند تطبیق یا تغییر اوزان های NN در پاسخ به الگوهای ورودی آموزش ارائه شده در لایه ورودی است. اینکه چگونه اوزان ها در پاسخ به یک مثال یادگیری تطبیق می یابند، با الگوریتم آموزش کنترل می شود. تست، حالت کاربردی است که در آن شبکه یک الگوی ورودی تست شده ارائه شده در لایه ورودی خود را پردازش می کند و پاسخ در لایه خروجی را ایجاد می کند.

طراحی یک ANN برای یک برنامه خاص نیاز به تعیین معماری NN، اندازه بهینه برای شبکه (تعداد لایه ها، تعدادی از واحدهای پنهان در لایه های میانی و تعداد واحدها در لایه های ورودی و خروجی) برحسب شرایط دقت در یک مجموعه آزمون و الگوریتم آموزشی مورد استفاده در مرحله یادگیری دارد. دو نوع از شبکه های عصبی برای انجام استخراج مورد نیاز دانش از مجموعه آموزش های پر نویز برای دستیابی به افزایش بهتر سیگنال استفاده می شود. این ها شبکه RNN و MLNN هستند. معماری هر دو شبکه در بخش زیر ارائه شده است.

2.1. معماری

2.1.1. معماری شبکه های عصبی بازگشتی

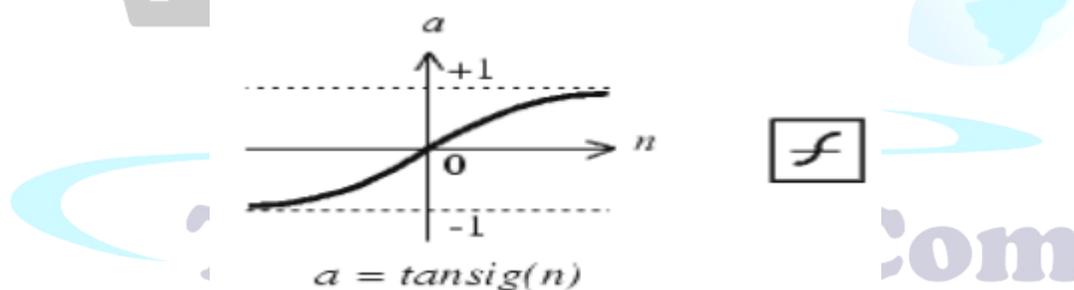
RNN طراحی شده به نام شبکه Elman شناخته می شود. شبکه Elman، شبکه دو لایه ای پس پراکنی، به علاوه یک اتصال بازخورد از خروجی لایه پنهان به ورودی آن است. این مسیر بازخورد برای شبکه Elman، یادگیری برای شناختن و تولید الگوهای زمانی، و همچنین الگوهای فضایی را میسر می سازد. [6] شبکه دو لایه ای Elman در شکل 1 نشان داده شده است.



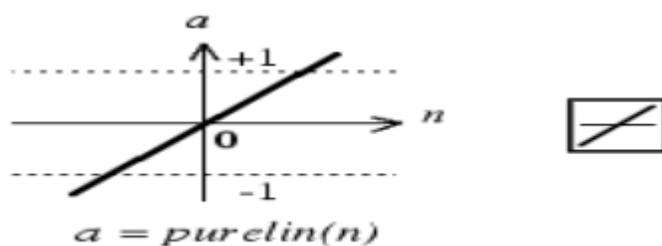
شکل 1. معماری از شبکه Elman. [10]

شبکه Elman ساخته شده دارای نورون های tansig در لایه پنهان (بازگشتی)، و نورون های purelin در لایه خروجی خود است که در شکل 2 و 3 نشان داده شده است. تعداد نرون ها در لایه های پنهان و خروجی، به ترتیب

10 و 1 است. واحد های پنهان و واحد خروجی نیز دارای بایاس هستند. این شرایط بایاس مثل اوزان ها روی اتصالات از واحدها عمل می کند که خروجی ان همواره 1 است. این گرایش به شبکه یک متغیر اضافی را می دهد و بنابراین انتظار می رود شبکه با بایاس قوی تر از شبکه های دیگر بدون ان باشد. [10] این ترکیب به این علت خاص است که در آن شبکه های دولایه با این توابع انتقال می توانند هر تابعی را (با یک تعداد متناهی از ناپیوستگی) با دقت دلخواه تقریب بزنند. تنها شرط این است که لایه پنهان باید سلول های عصبی به اندازه کافی داشته باشد. سلول های عصبی پنهان تر زمانی مورد نیاز هستند که تابع متناسب شده دارای پیچیدگی بیشتر شود. توجه داشته باشید که شبکه Elman متفاوت از شبکه های لایه معمولی است، زیرا لایه اول دارای یک اتصال مکرر است. تاخیر در این اتصال، مقادیری را از مرحله قبلی ذخیره می کند که می تواند در مرحله زمان جاری استفاده شود. بنابراین، حتی اگر دو شبکه Elman، با همان اوزان و بایاس ها، ورودی های یکسان معین در یک مرحله زمان معین باشند، خروجی آنها می توانند به علت های حالات بازخورد مختلف، متفاوت باشند. [5]



شکل 2 تابع انتقال Tansig



شکل 3. تابع انتقال Pureline

شبکه Elman موارد زیر را انجام می دهد:

1. واحدهای ورودی، ورودی اول را دریافت می کنند

2. هر دو واحدهای ورودی و واحدهای زمینه (گروهی از واحدهایی که سیگنال بازخورد را از مرحله قبلی دریافت می کنند [8]) واحدهای پنهان را فعالسازی می نمایند.

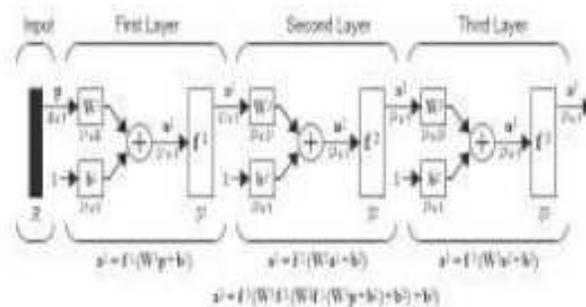
3. واحدهای پنهان نیز بازخورد به فعال سازی واحدهای زمینه را پس می دهند (کپی کردن محتوا از واحد مخفی)

4. واحدهای خروجی در مقایسه با ورودی معلم قرار می گیرند (خروجی مورد نظر) و پس پراکنی خطا برای تنظیم تدریجی قدرت اتصال مورد استفاده قرار می گیرد.

اتصالات های مکرر به واحدهای پنهان شبکه اجازه می دهند تا خروجی قبلی خود را ببینند به طوری که رفتار بعدی می تواند با پاسخ های قبلی شکل بگیرد. ارتباطات بازگشتی چیزی هستند که حافظه شبکه را ارائه می دهند. همچنین واحدهای زمینه، "پنهان" هستند به این معنا که آنها منحصر با گره های دیگر با شبکه داخلی، و نه جهان خارج تعامل دارند [7].

2.1.2. معماری شبکه عصبی چند لایه

MLNN با سه لایه طراحی شده است همانطور که در شکل 4 نشان داده شده است. شبکه بازخورد دارای دو لایه پنهان نورون (F1) و tansig (F2) و پس از آن یک لایه خروجی از نورون های purelin (F3) است. تعداد نرون ها در لایه مخفی اول و دوم 7 و 3 بود. واحدهای پنهان و واحد خروجی نیز دارای بایاس هستند. این شرایط بایاس مثل اوزان ها در اتصالات از واحدهایی است که خروجی آن همواره 1 است. چندین لایه از سلول های عصبی با توابع انتقال غیر خطی شبکه، یادگیری رابطه غیر خطی و خطی بین بردار ورودی و خروجی را میسر می سازد. مدل پس پراکنی، یک مدل چند لایه است زیرا لایه های مجزا دارد. نورون ها در درون هر یک از لایه ها با نورون ها از لایه های مجاور از طریق لبه های جهتدار متصل می شوند. هیچ ارتباط میان نورون در یک لایه وجود ندارد. فقط جهت جریان اطلاعات برای فاز بازخورد عمل نشان داده شده است. در مرحله پس پراکنی آموزش، سیگنال ها را در جهت معکوس فرستاده می شوند.



شکل 4. معماری شبکه عصبی سه لایه. [10]

شبکه عصبی سه لایه ط موارد زیر را انجام می دهد: در طول فاز بازخورد ، واحد ورودی ، یک سیگنال ورودی را دریافت می کند و این سیگنال را به هر یک از واحدهای پنهان در اولین لایه پنهان پخش می کند. هر یک از واحدهای پنهان، فعال شدن خود را محاسبه می کند و سیگنال خود را به واحدهای پنهان در لایه دوم می فرستد. سپس هر یک از واحدهای پنهان در لایه دوم، فعال شدن خود را محاسبه می کند و سیگنال های خود را به واحد خروجی می فرستد. در نهایت، واحد خروجی، فعالیت خود را برای تشکیل پاسخ خالص برای الگوی ورودی داده شده محاسبه می کند. در مدت فاز آموزش، هر واحد خروجی، فعالسازی محاسبه شده خود را با مقدار هدف خود برای تعیین خطا در ارتباط با آن واحد مقایسه می کند. این خطا از لایه خروجی در لایه پایین تر به تمام واحدها توزیع می شود، و نیز برای به روز رسانی اوزان را بین خروجی و لایه دوم مخفی استفاده می شود. خطای محاسبه شده در لایه دوم به تمام واحدها در لایه قبلی توزیع می شود و برای به روز رسانی اوزان بین لایه دوم مخفی و اولین لایه پنهان مورد استفاده قرار می گیرد. خطای محاسبه شده در اولین لایه پنهان، به روز رسانی اوزان بین اولین لایه پنهان و لایه ورودی را استفاده می کند.

2.2. شبکه های آموزش های عصبی

شبکه های عصبی با استفاده از الگوریتم پس پراکنی آموزش دیده می شوند. تغییرات متعددی برای الگوریتم آموزش پس پراکنی NN وجود دارد. این تغییرات، اساس ارزیابی روش های آزمون موثر ترین راه کلی برای مدلسازی سیستم هستند. تفاوت بین آموزش و دقت های تعمیم در الگوهای اتخاذ شده آزمون نهفته است. دقت آموزش خوب را می توان با تشکیل مرزهای تصمیم گیری های پیچیده به دست آورد که به نوبه خود نیاز به یک اندازه شبکه

بزرگ دارد. همچنین، دقت تعمیم خوب نیاز به فشار بیش از حد بر روی دقت و صحت آموزش ندارد؛ تعلیم بیش از حد ممکن است به تعمیم تخریب یافته منجر شود. این مورد در صورتی رخ می دهد که بسیاری از واحدهای پنهان استفاده شوند. [12] تعدادی از معماری های شبکه طراحی و با نمونه های مختلف داده های پر نویز مورد آزمایش قرار می گیرند. هدف، داشتن روند آموزش خوب، برای اجتناب از مشکل تمرین بیش از حد است، و داشتن هدف میانگین مربع خطا (MSE) در فرآیند آموزش است. ثابت شده است [10] که اضافه نمودن نویز تصادفی به سیگنال مورد نظر در فرآیند آموزش از شبکه های عصبی می تواند تعمیم شبکه را بهبود بخشد و می تواند فرآیند یادگیری را از وارد شدن به مینیمم محلی جلوگیری نماید. اجتناب کنند. فرض کنید که XK بیانگر عنصر k ام از بردار ورودی است؛ y_i خروجی i ام از لایه خروجی است. $d_i(t)$ به معنی پاسخ مورد نظر برای خروجی نورون i در زمان t است که در آن t شاخص گسسته در زمان است. سیگنال خطای $EI(T)$ به عنوان تفاوت بین پاسخ هدف $DI(T)$ و پاسخ واقعی (T) تعریف می شود.

$$e_i(t) = d_i(t) - y_i(t) \quad (1)$$

هدف از یادگیری، به حداقل رساندن تابع هزینه بر اساس سیگنال خطا $EI(T)$ ، با توجه به پارامترهای شبکه (اوزان ها) است، به طوری که پاسخ واقعی هر نورون خروجی در شبکه به این پاسخ هدف میل می کند. [6] یک معیار معمولاً استفاده شده برای تابع هزینه، معیار MSE است که به عنوان مقدار متوسط مربع خطای مجموع مربع تعریف می شود:

$$J = E \left[\frac{1}{2} \sum_i (e_i(t))^2 \right] \quad (2)$$

$$= E \left[\frac{1}{2} \sum_i (d_i(t) - y_i(t))^2 \right] \quad (3)$$

که در آن E ، اپراتور انتظار آماری است و مجموع، روی همه نورون های لایه خروجی گرفته می شود. معمولاً تطابق اوزان تنها با استفاده از سیگنال های مورد نظر $d_i(t)$ انجام داد. در [6] بیان می شود که یک سیگنال $DI(t) + ni$

(t) را می توان به عنوان یک سیگنال مورد نظر برای نورون خروجی a به جای استفاده از سیگنال اصلی مورد نظر $DI(t)$ استفاده نمود که در آن عبارت نویز است. فرض می شود که عبارت نویز برای نویز گوسی، مستقل از سیگنال ورودی $XK(t)$ و سیگنال های مورد نظر $di(t)$ باشد. با سیگنال های جدید مورد نظر، MSE از معادله 3 را می توان به صورت زیر نوشت:

$$J = E\left[\frac{1}{2} \sum_i (d_i(t) + n_i(t) - y_i(t))^2\right] \quad (4)$$

در [6] نشان داده می شود که معادله 4 برابرست با

$$J = \frac{1}{2} E\left[\sum_i (y_i(t) - E\{d_i(t) + n_i(t) | x(t)\})^2\right] + \frac{1}{2} E\left[\sum_i \text{var}((d_i(t) + n_i(t)) | x(t))\right] \quad (5)$$

که در آن، این نماد به معنای احتمالات شرطی و "var" مخفف واریانس است. عبارت دوم در سمت راست معادله 5، در خطای کلی J و به عنوان پیشرفت های یادگیری سهم خواهد داشت، اما روی مقدار نهایی اوزان تاثیر نمی گذارد، که دلیل آن است که یک تابع از اوزان شبکه نیست، در حالی که عبارت اول در مورد مقدار مطلوب اوزان تصمیم گیری می نماید. [6] از آنجا که نویز، متوسط صفر باشد و مستقل از هر دو سیگنال مطلوب و ورودی است، بنابراین:

$$\{E\{d_i(t) + n_i(t) | x(t)\} = \{E\{d_i(t) | x(t)\} \quad (6)$$

از معادلات 5 و 6 روشن است که مقادیر اوزان نهایی را می توان بدون وجود نویز در معادله مشخص نمود. آموزش NN برای دنبال نمودن این مدل شرح داده شده توسط معادله زیر را برای پردازش تصویر هولوگراف ساخته می شود:

$$d(x) = A_r^2 + S^2 + 2A_r S \cos \theta \quad (7)$$

که در آن θ ، اختلاف فاز بین Ar و S سیگنال منعکس شده از شی تحت فرآیند تصویربرداری، و AR سیگنال مرجع با توجه به نیاز هولوگرافی خطی است.

3. نتایج تجربی

در این بخش، نتایج تجربی به دست آمده با استفاده از معماری های RNN و MLNN در سیگنال ثبت شده از جسم آزمون است. یک جسم آزمون شامل دو میله فولادی به قطر 2.5 سانتی متر استفاده شده می شود. جدایی بین دو میله، 7 سانتی متر بود. فاصله Z0 بین جسم و صفحات ضبط 90 سانتی متر بود. این جسم توسط دو ماده مات مختلف پوشش داده شد: یک ورق کاغذ و یک ظرف: این شی توسط امواج اولتراسوند با استفاده از مبدل اولتراسونیک انتقالی [2] روشن شد.

سیگنال های دریافتی از جسم با توجه به بازتاب ثبت می شود و به منظور افزایش آنها، و یا به عبارت دیگر، به منظور کاهش اثر محیط مانند پس زمینه نسبتا بالا است که ناشی از مواد مات بود؛ شبکه های عصبی برای افزایش SNR داده های هولوگرافی استفاده می شود. طراحی معماری شبکه های عصبی برای یک برنامه خاص به تعیین اندازه بهینه برای شبکه برحسب دقت در یک مجموعه آزمون، معمولا توسط افزایش اندازه آن نیاز دارد تا زمانی که دیگر کاهش قابل توجهی در خطا وجود ندارد. این تجزیه و تحلیل از طریق برنامه های اجرا شده در نرم افزار MATLAB، انجام شد.

هر دوی شبکه های، کاهش مورد نیاز نويز در سیگنال گرفته شده را انجام دادند، به عنوان مثال، RNN و MLNN. MLNN بهتر از RNN از لحاظ زمان اجرا و همچنین عملکرد میانگین مربع خطا (MSE) عمل می کند. جداول 1 و 2، خلاصه نتایج به دست آمده آموزش NN با مقایسه زمان سپری شده، Epoch ها، MSE RNN و MLNN با پنج الگوریتم آموزش است. این الگوریتم ها Traingd، به Traingdm، Traingda، Trainlm، و Traingdx [5] هستند. همه این الگوریتم ها، از گرادیان تابع عملکرد برای تعیین چگونگی تنظیم اوزان برای به حداقل رساندن عملکرد استفاده می کنند (به عنوان مثال، MSE). همانطور که می توان در جدول 1 و 2 دید،

MLNN آموزش دیده با تابع پس پراکنی TRAINLM به سریع ترین پیاده سازی الگوریتم (90 دوره) با بهترین عملکرد MSE منتج می شود (برابر 0.011228).

Algorithm	Recurrent Neural Network (RNN)		Multilayer Neural Network (MLNN)	
	Elapsed Time (Sec)	Epochs	Elapsed Time (Sec)	Epochs
Traingd	7.563	1800	24.047	7000
Traingdm	8.328	2000	75.235	20000
Traingda	8.656	2000	7.813	2000
Trainlm	4.781	500	1.484	90
Traingdx	4.563	1000	12.593	3500

جدول 1. زمان سپری شده و دوره RNN و MLNN با پنج الگوریتم آموزش

شبکه عصبی چندلایه (MLNN) شبکه عصبی بازگشتی (RNN)

دوره ها زمان سپری شده (ثانیه) دوره ها زمان سپری شده (ثانیه) الگوریتم

Algorithm	Mean Square Error (MSE)	
	Recurrent Neural Network (RNN)	Multilayer Neural Network (MLNN)
Traingd	0.0151797	0.0153542
Traingdm	0.0151767	0.014463
Traingda	0.016874	0.0157362
Trainlm	0.0111192	0.0112285
Traingdx	0.0150799	0.0126875

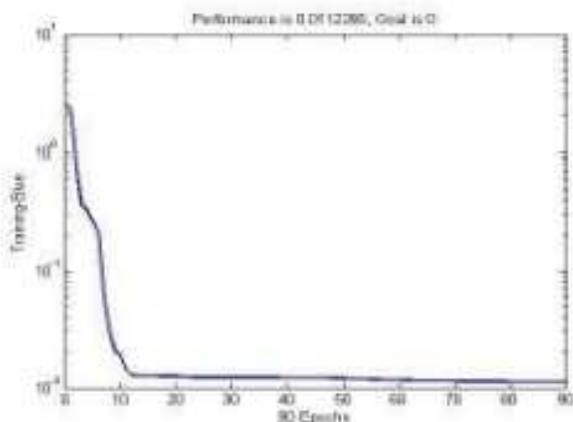
جدول 2. میانگین مربع خطا RNN و MLNN با پنج الگوریتم آموزش.

خطای میانگین مربع (MSE)

شبکه عصبی چندلایه (MLNN) شبکه عصبی بازگشتی (RNN) الگوریتم

تابع trainlm با توجه به روش بهینه سازی لوبنبرگ marquardz [5] کار می کند. شکل 5، عملکرد MLNN در فرایند آموزش را با الگوریتم TRAINLM نشان می دهد. آزمایش های گسترده ای برای بهبود عملکرد MLNN صورت گرفته است. جدول 3، عملکرد MLNN را با دو آزمایش موردی نشان می دهد: ورق کاغذ و مواد اسفنجی

جدا شده. MLNN طراحی شده قادر به کاهش اثر پنهان کردن محیط و نویز در سیگنال گرفته است. شکل 6، نشان دهنده رفتار خروجی شبکه عصبی پس از استفاده از سیگنال گرفته شده $h(n)$ در ورق کاغذ و موارد استایروفوم است.



شکل 5 - شبکه عصبی چند لایه عملکرد MLNN در طی فرایند آموزش با الگوریتم آموزش TRAINLM.

شکل 5. عملکرد شبکه های عصبی چند لایه MLNN در فرایند آموزش با الگوریتم آموزش TRAINLM.

4. نتایج

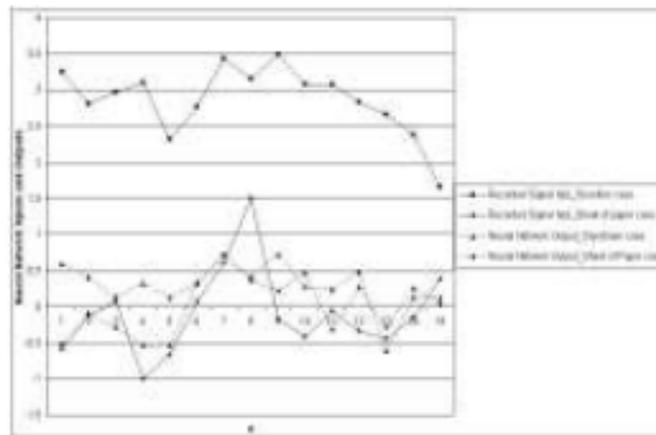
در این مقاله، دو شبکه عصبی مختلف برای به حداقل رساندن اثر نویز در این مدل از یک شی پنهان و افزایش SNR از داده های هولوگرافی مقایسه شده اند. نتایج تجربی نشان می دهد که استفاده از شبکه های عصبی برای تقویت سیگنال گرفته ضبط شده می تواند ردیابی پارامترهای مدل را بهبود بخشد. معماری RNN و MLNN برای به دست آوردن معماری مطلوب از نظر تعداد لایه های پنهان و نرون ها در هر لایه مورد بررسی قرار گرفته اند. نتایج به دست آمده نشان می دهد که در مرحله پیش پردازش، RNN و MLNN قادر به بهبود سیگنال آزمایش ثبت شده و تولید سیگنال خروجی هستند که به دنبال مدل مورد نظر با MSE حداقل (0.0112285) است. اثر اضافه کردن نویز سفید گوسی به سیگنال مورد نظر در هنگام آموزش شبکه عصبی با پس پراکنی مورد بحث قرار گرفته است. هم از نظر تحلیلی و هم به طور تجربی نشان داده شده است که نویز افزوده، تعمیم شبکه بر روی الگوهای تست شده و مسیر آموزش را بهبود می بخشد. نتایج مشابهی در زمان آموزش هر دو RNN و MLNN به دست آمده است.

Training Algorithm	Mean Square Error (MSE)	
	Sheet of Paper Case	Styrofoam Case
Traingd	0.053542	0.177533
Traingdm	0.014463	0.170649
Traingda	0.0157362	0.15886
Trainlm	0.0112285	0.149683
Traingdx	0.0126875	0.164845

جدول 3. عملکرد شبکه های عصبی چند لایه با دو آزمایش موردی: ورق کاغذ و مواد جداکننده Styrofoam

خطای میانگین مربعی (MSE) الگوریتم آموزش

مورد Styrofoam مورد ورقه کاغذ



شکل 6. شبکه های عصبی چند لایه خروجی MLNN پس از استفاده از سیگنال ثبت شده $h(n)$ در دو مورد: ورق

کاغذ و مواد اسفنجی Styrofoam

References

- [1] Badri L. and Al-Azzo M., "Burg-Neural Network Based Holographic Source Localization," *WSEAS Transactions on Signal Processing*, vol. 2, no. 14, pp. 414-422, 2006.
- [2] Badri L. and Al-Azzo M., "Modelling of Long Wavelength Detection of Objects Using Elman Network Modified Covariance Combination," *International Arab Journal of Information Technology (IAJIT)*, vol. 5, no. 3, pp. 265-272, 2008.
- [3] Brueckmann R., Scheidig A., and Gross H., "Adaptive Noise Reduction and Voice Activity Detection for improved Verbal Human-Robot

- Interaction using Binaural Data,” in *Proceedings of the IEEE International Conference on Robotics and Automation*, Italy, pp. 10-14, 2007.
- [4] Chuan W. and Jose P., “Training Neural Networks with Additive Noise in the Desired Signal,” *Transactions on Neural Networks*, vol. 10, no. 6, pp. 1511-1517, 1999.
- [5] Demuth H. and Beale M., *Neural Network Toolbox-for Use with MATLAB User’s Guide*, The Mathworks, Massachusetts, 2002.
- [6] Dorronsoro J., López V., Cruz C., and Sigüenza J., “Autoassociative Neural Networks and Noise Filtering,” *IEEE Transactions on Signal Processing*, vol. 51, no. 5, pp. 1431-1438, 2003.
- [7] Elman J., “Finding Structure in Time,” *Cognitive Science*, vol. 14, no. 2, pp.179-211, 1990.
- [8] Fausett L., *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, Prentice Hall International, New Jersey, 1994.
- [9] Giles C., Lawrence S., and Tsoi A., “Noisy Time Series Prediction Using a Recurrent Neural Network and Grammatical Inference,” *Machine Learning*, vol. 44, no. 1-2, pp. 161-183, 2001.
- [10] Hagan M., Demuth H., and Beale M., *Neural Network Design*, PWS Publishing Company and Thomson Asia, 2002.
- [11] Khairnar D., Merchant S., and Desai U., “Radar Signal Detection In Non-Gaussian Noise Using RBF Neural Network,” *Journal of Computers*, vol. 3, no. 1, pp. 32-39, 2008.
- [12] Kung S., *Digital Neural Network*, Printice Hall, 1993.
- [13] Mastriani M. and Giraldez A., “Neural Shrinkage for Wavelet-Based SAR Despeckling,” *International Journal of Intelligent Technology*, vol. 1, no. 3, pp. 211-222, 2006.
- [14] Parveen S. and Green P., “Speech Enhancement with Missing Data Techniques Using Recurrent Neural Networks,” in *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing*, Canada , pp. 1733-1736, 2004.
- [15] Radonja P., “Neural Networks Based Model of A Highly Nonlinear Process,” in *Proceedings of the IX Telekomunikacioni Forum Telfor’2001*, Beograd, 2001.
- [16] Yoshimura H., Shimizu T., Matumura T., Kimoto M., and Isu N., “Adaptive Noise Reduction Filter for Speech Using Cascaded Sandglass-Type Neural Network,” in *Proceedings of the IEEE International Conference on Robotics and Automation*, Italy, pp. 10-14, 2007.
- [17] Zhang X., “Thresholding Neural Network for Adaptive Noise Reduction,” *IEEE Transactions on Neural Networks*, vol. 12, no. 3, 2001.

neFa.Com

برای خرید فرمت ورد این ترجمه، بدون واتر مارک، اینجا کلیک نمایید.



این مقاله، از سری مقالات ترجمه شده رایگان سایت ترجمه فا میباشد که با فرمت PDF در اختیار شما عزیزان قرار گرفته است. در صورت تمایل میتوانید با کلیک بر روی دکمه های زیر از سایر مقالات نیز استفاده نمایید:

لیست مقالات ترجمه شده ✓

لیست مقالات ترجمه شده رایگان ✓

لیست جدیدترین مقالات انگلیسی ISI ✓

سایت ترجمه فا ؛ مرجع جدیدترین مقالات ترجمه شده از نشریات معتبر خارجی