

# ارزیابی شبکه‌های عصبی انعطاف‌پذیر باساختار قابل بازسازی در حین آموزش جهت تخمین هارمونیکهای جریان استاتور ژنراتور آسک نیروگاه ری بر اساس الگوریتم CFE/SS

محمد رضا یوسفی نجف‌آبادی<sup>(۱)</sup> - محمد تشنه لب<sup>(۲)</sup>

(۱) کارشناسی ارشد گروه برق - دانشکده برق - دانشگاه آزاد اسلامی واحد نجف آباد

(۲) استاد گروه کنترل - دانشکده برق - دانشگاه صنعتی خواجه نصیر الدین طوسی

تاریخ پذیرش: زمستان ۱۳۸۷ تاریخ دریافت: پاییز ۱۳۸۸

**خلاصه:** یکی از روش‌های تشخیص خطای ژنراتور در حین کار، آنالیز هارمونیکهای جریان استاتور می‌باشد. در این مقاله از شبکه‌های عصبی انعطاف‌پذیر با قابلیت بازسازی خود در حین آموزش برای تعیین هارمونیکهای جریان استاتور ژنراتور، در بارهای مختلف استفاده شده است. داده‌های آموزش دهنده شبکه عصبی با استفاده از مدل سازی ژنراتور و استفاده از روش المان محدود (FE) و فضای حالت (SS)، در نقاط مختلف بار روی منحنی بهره برداری ژنراتور برای سه سطح مختلف ولتاژ پایانه به دست آمده است. شبکه عصبی که با استفاده از این داده‌ها آموزش داده شده است، یک شبکه پرسپترون با یک لایه پنهان و با قانون یادگیری پس انتشار خطا می‌باشد. نتایج نشان می‌دهد که شبکه عصبی انعطاف‌پذیر آموزش داده با خطای کمتر از ده درصد می‌تواند هارمونیکهای جریان را برای نقاط بار دلخواه روی منحنی بهره‌برداری، نسبت به نتایج حاصل از الگوریتم CFE-SS به دست آورد. پارامترهای نامی ژنراتور آسک عبارتند از: 43950 کیلو ولت آمپر، 11 کیلو ولت، 3000 رادیان بر دقیقه، 50 هرتز و ضریب توان 0.8.

**کلمات کلیدی:** روش المان محدود، شبکه عصبی انعطاف‌پذیر، منحنی بهره برداری و ژنراتور سنکرون.

است یا خیر؟ از آنجا که استاتور ساده‌ترین مشخصه ژنراتور بوده که به صورت به هنگام قابل اندازه‌گیری می‌باشد، لذا از هارمونیکهای جریان استاتور برای تشخیص خطای مختلف استفاده می‌شود. در این مقاله هدف، به دست آوردن هارمونیکهای شکل موج جریان استاتور در شرایط بدون خطای برازیل می‌باشد. این داده‌ها برای تخمین آنکه در اثر بروز خطای از مدار خارج شود، می‌توانند مانشین را قابل از کار کنند. در این مقاله هدف آن است که می‌تواند تغییر هارمونیکهای جریان نسبت به شرایط بدون خطای برازیل را در مورد روی دادن خطای برازیل تخمین کند. در این مقاله هدف آن است که می‌تواند تغییر هارمونیکهای جریان نسبت به شرایط بدون خطای برازیل را در مورد روی دادن خطای برازیل تخمین کند. در این مقاله هدف آن است که می‌تواند تغییر هارمونیکهای جریان نسبت به شرایط بدون خطای برازیل را در مورد روی دادن خطای برازیل تخمین کند. در این مقاله هدف آن است که می‌تواند تغییر هارمونیکهای جریان نسبت به شرایط بدون خطای برازیل را در مورد روی دادن خطای برازیل تخمین کند.

**۱- مقدمه**  
به دست آوردن پارامترهای ژنراتور سنکرون در نقاط مختلف کاری با توان، ولتاژ و ضریب توانهای مختلف، از اهمیت زیادی برخوردار است. یکی از مهمترین اهداف بهره‌برداران ماشین به دست آوردن روشی است تا بتوانند ماشین را قابل از کار کنند. در اثر بروز خطای از مدار خارج شود، بالاگهله بعد از رخ دادن خطای برازیل، برای تعمیرات خارج سازند. یافتن محل خطای نیز از اهمیت بالایی برخوردار است. در این مقاله هدف آن است که بتوان به هنگام به وجود آمدن خطای برازیل، تغییرات پارامترهای ماشین را دنبال نمود و از روی آنها به محل خطای برازیل لازم است مشخصه‌هایی را که می‌توان به صورت به هنگام در ماشین اندازه‌گیری نمود، تحت شرایط مختلف کاری ماشین، در شرایط بدون خطای از طریق تئوری محاسبه نمود و سپس با مقدار اندازه‌گیری شده از ماشین در حالت خطدار مقایسه کرد، تا بتوان تشخیص داد که آیا خطایی صورت گرفته

(۳) نقاط آموزش دهنده شبکه را در سطوح مختلف ولتاژی نشان می‌دهد. به این ترتیب مدل (CFE-SS) برای این ۵۴ نقطه کار اجرا و از روی آن هارمونیکهای جریان به دست آمد. از آنجا که هارمونیکهای فرد برای ما دارای اهمیت بالاتری هستند و هارمونیکهای زوج نیز آنقدر کوچک هستند که می‌توان از آنها صرف‌نظر نمود، فقط هارمونیکهای فرد ۱ تا ۷ در جدول‌های (۱)، (۲) و (۳) آورده شده است. (هارمونیکهای فرد ۷ به بالا دارای مقادیر خیلی کوچکی بودند که از آنها صرف نظر شده است). در شکل (۲) نیز تغییرات دامنه هارمونیکها بر حسب نمونه برای هر چهار هارمونیک نشان داده شده است.

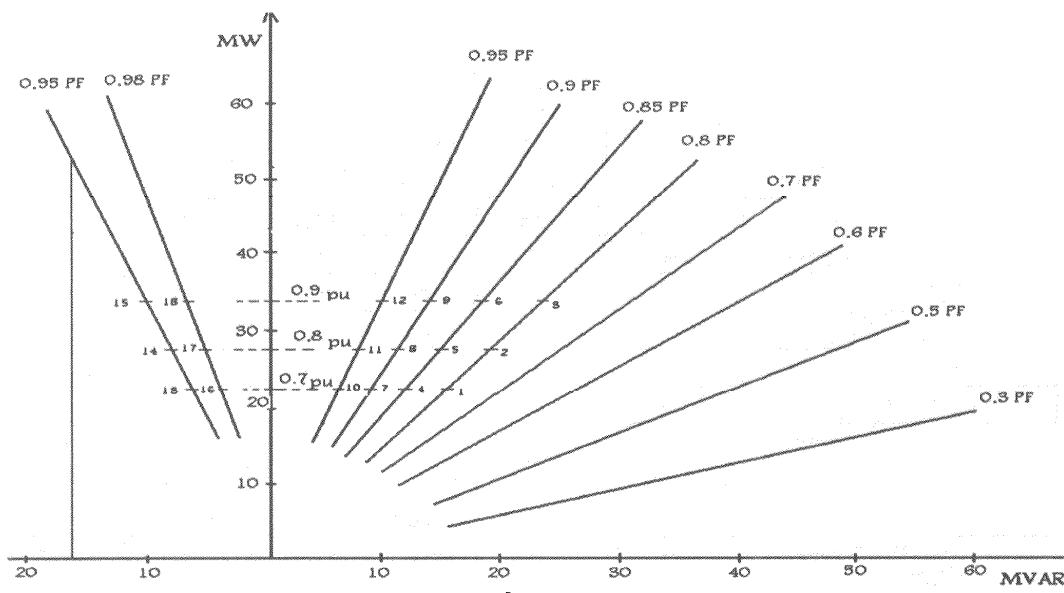
### ۲- ساختار مدل شبکه عصبی

هنگامی که داده‌های آموزش دهنده شبکه عصبی فراهم شدند، قدم بعدی تعیین ساختار شبکه عصبی می‌باشد که عبارت است از: تعیین تعداد نرونها لایه ورودی و لایه خروجی، تعیین تعداد لایه‌های پنهان و سپس تعیین تعداد نرونها هر یک از لایه‌های پنهان به سادگی دیده می‌شود که هر نقطه کار از روی سه پارامتر ولتاژ، جریان و ضربیت توان از بقیه نقاط مجزا می‌گردد که این امر نشان دهنده تعداد نرونها لایه ورودی می‌باشد. لذا لایه ورودی دارای سه نرون و سه بردار ورودی ولتاژ، جریان و ضربیت توان خواهد بود. تعداد نرونها لایه خروجی نیز از روی تعداد خروجی‌های مورد نظر که هارمونیکهای جریان می‌باشد، به دست می‌آید. در مدل مورد نظر تعداد این نرونها برابر چهار خواهد بود زیرا خروجی‌های شبکه دارای چهار هارمونیک می‌باشد.

انجام می‌شود. سپس همین کار با شبکه عصبی با ساختار ۳ لایه انعطاف پذیر انجام خواهد شد و در پایان نتایج این دو روش با هم مقایسه خواهد شد.

### ۲- داده‌های آموزش دهنده شبکه عصبی

همانطور که گفته شد با توجه به اینکه نقاط کاری ژنراتور نامحدود است به دست آوردن هارمونیکهای جریان استاتور تنها با استفاده از ترکیب دو مدل المان محدود و فضای حالت (CFE-SS) مشکل و زمانبر است، لذا از شبکه عصبی استفاده می‌شود. در ابتدا باید شبکه عصبی به وسیله یک مجموعه از اطلاعات آموزش دهنده شبکه عصبی قانونی تعداد اعضای مجموعه داده‌های آموزش دهنده شبکه عصبی قانونی وجود ندارد ولی باید طوری در نظر گرفته شود که به نحو مناسب، کلیه نقاط کاری ژنراتور را پوشش دهد. مجموعه نقاط کار را می‌توان از روی منحنی بهره برداری ژنراتور نمونه تعیین نمود. شکل (۱) منحنی بهره برداری ژنراتور آسک را در سطح ولتاژ یک پریونیت نشان می‌دهد. ژنراتور آسک در شرایط پس فاز دارای ضربیت توان بزرگتر از ۰.۸ و در شرایط پیش فاز نیز دارای ضربیت توان بزرگتر از ۰.۹۵ می‌باشد. همچنین در این ژنراتور در توان ۰.۷، ۰.۶ و ۰.۹ پریونیت برای تغییرات توان استفاده شده است. به این ترتیب نقاط شماره گذاری شده در شکل (۱) به عنوان نقاط آموزش دهنده شبکه، برای سطوح ولتاژ یک پریونیت در نظر گرفته شده است. از آنجا که ژنراتور دارای تغییرات ولتاژ حدود ۵% می‌باشد، از سه سطح ولتاژ ۱، ۰.۹۵ و ۰.۹۰۵ پریونیت برای ولتاژ پایانه استفاده شده است. جدول‌های (۱) و (۲) و



شکل (۱): منحنی بهره برداری ژنراتور آسک در سطح ولتاژ یک پریونیت

Fig. (1): The graph of Ask generator vectorial gain in the voltage level of one perunit

Table (1): The working points at voltage level of one perunit  
 جدول (۱): نقاط کار در سطح ولتاژ یک پریونیت

نقطه کار	جریان فاز (pu) *10 <sup>-5</sup>	a	p توان *10 <sup>-1</sup>	ضریب توان *10 <sup>-2</sup> cosΦ	اول هارمونیک *10 <sup>-1</sup>	سوم هارمونیک *10 <sup>-2</sup>	پنجم هارمونیک *10 <sup>-2</sup>	هارمونیک *10 <sup>-2</sup> هفتم
1	70000		7	80	23977	20990	11760	15770
2	80000		8	80	26885	25860	13690	18370
3	90000		9	80	29785	30010	14470	19980
4	66000		7	85	22988	24150	11770	16020
5	75300		8	85	25849	23540	13540	18520
6	84700		9	85	28861	29314	14660	20410
7	62200		7	90	21980	19750	10830	14960
8	71200		8	90	24776	22780	13214	17430
9	80000		9	90	27646	28560	14218	20340
10	58900		7	95	21095	20050	10346	14760
11	67400		8	95	23800	25420	12290	16118
12	75800		9	90	26340	25140	12790	19890
13	58900		7	-95	19747	19020	10810	13870
14	67400		8	-95	22204	20610	11130	14890
15	75800		9	-95	24590	21530	12760	14530
16	57143		7	-98	19030	17990	10060	12960
17	65306		8	-98	21495	22390	10900	15260
18	73469		9	-98	24075	25200	13310	15990

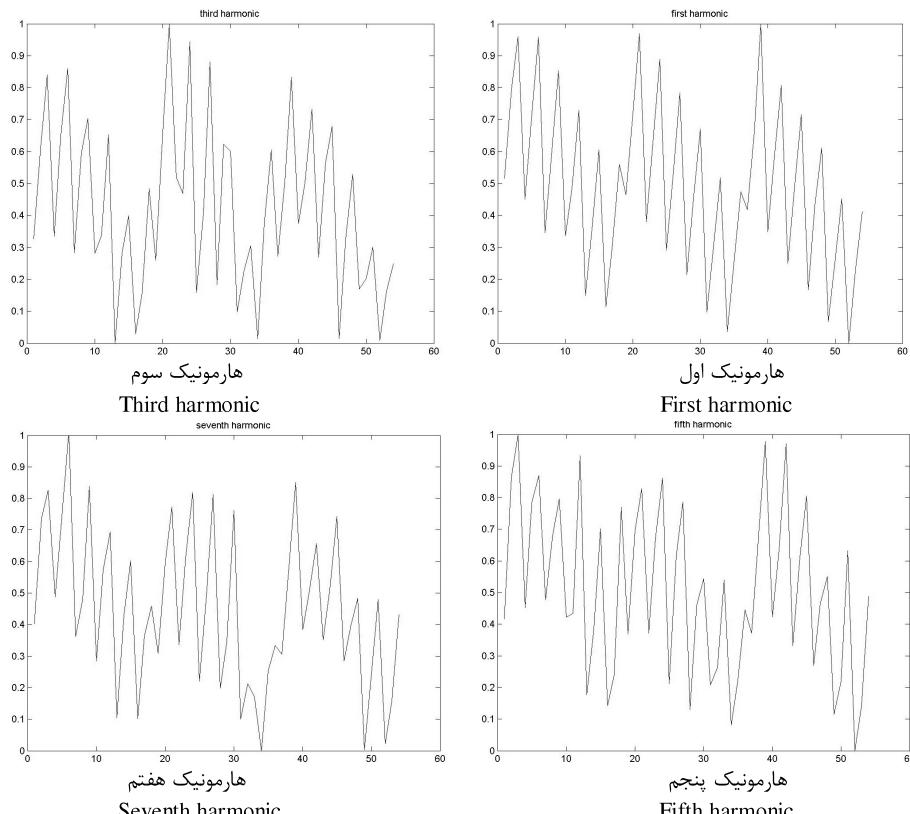
Table (2): The working points at voltage level of 0.95 perunit

جدول (۲): نقاط کار در سطح ولتاژ ۰.۹۵ پریونیت

نقطه کار	جریان فاز (pu) *10 <sup>-5</sup>	a	p توان *10 <sup>-1</sup>	ضریب توان *10 <sup>-2</sup> cosΦ	اول هارمونیک *10 <sup>-1</sup>	سوم هارمونیک *10 <sup>-2</sup>	پنجم هارمونیک *10 <sup>-2</sup>	هارمونیک *10 <sup>-2</sup> هفتم
1	73700		7	80	25071	23710	14120	17130
2	84200		8	80	22183	19750	11000	16270
3	94700		9	80	19939	18170	10420	13890
4	69500		7	85	25585	22690	13720	18430
5	79300		8	85	22894	21250	11850	16870
6	89200		9	85	20348	17820	10620	13910
7	65500		7	90	27013	25780	15080	19270
8	74800		8	90	24208	21940	12140	18160
9	84200		9	90	22490	21260	12070	15540
10	62000		7	95	28443	26400	14280	20580
11	70900		8	95	25578	25080	13590	17330
12	79800		9	95	22596	21270	12390	16250
13	-62000		7	95	29657	21800	14710	22050
14	-70900		8	95	24574	25290	14210	19710
15	-79800		9	95	27780	28060	12250	17390
16	-60150		7	98	29670	21900	15480	20470
17	-68743		8	98	23817	25760	14690	19650
18	-77330		9	98	26742	28300	12040	16630

Table (3): The working points at voltage level of 1.05 perunit  
جدول (۳): نقاط کار در سطح ولتاژ ۱.۰۵ پریونیت

نقطه کار	حریان فاز ( $\text{pu} \times 10^{-5}$ )	توان $P \times 10^{-1}$	ضریب توان $*10^{-2} \cos\Phi$	همونیک اول $*10^{-1}$	همونیک سوم $*10^{-2}$	همونیک پنجم $*10^{-2}$	همونیک هفتم $*10^{-2}$
1	66600	7	80	23440	21140	11770	15750
2	76200	8	80	26233	24000	13620	18280
3	89100	9	80	30137	27970	15350	20690
4	62800	7	85	22632	22390	12080	16450
5	71700	8	85	25318	23940	13330	17570
6	80760	9	85	27911	26760	15310	18930
7	59200	7	90	21511	21100	11540	16150
8	67700	8	90	24327	24710	13190	17720
9	76200	9	90	26856	26100	14330	19710
10	56100	7	95	20550	17990	11170	15550
11	64200	8	95	23583	21810	12330	16540
12	72200	9	95	25660	24260	12830	17360
13	56100	7	-95	19399	19890	10260	12990
14	64200	8	-95	21657	20290	10880	18190
15	72200	9	-95	23831	21490	13310	17320
16	54422	9	-98	18620	17930	09580	13170
17	62196	8	-98	21210	20850	10410	14410
18	69971	7	-98	23350	19780	12460	16890



شکل (۲): تغییرات دامنه هارمونیکها بر حسب نمونه (محور افقی نقاط آموزش دهنده است)

Fig. (2): The variations of harmonic amplitudes as a function of the sample (The horizontal axis is the training points)

$$f(x) = \tanh(x) = \frac{1-e^{-x}}{1+e^{-x}} = \frac{2}{1+\exp(-2x)} - 1 \quad (1)$$

دلیل این انتخاب منفی شدن ورودیهای شبکه است، بدین معنا که محدوده تغییرات ورودی هم در ناحیه مثبت و هم در ناحیه منفی می‌باشد. برای یادگیری شبکه، تک تک داده‌ها به شبکه داده شد تا وزنهای شبکه را آموزش دهند و اینکار برای هر 18 مورد داده در هر یک از ولتاژها انجام می‌شود یعنی شبکه با 54 داده آموزش یافته است. همچنینتابع هدف برای اصلاح وزنهای و باساهای شبکه، مینیمم کردن مجموع مربیات خطای ما بین خروجی مطلوب و خروجی شبکه عصبی می‌باشد. در این طراحی از نرخ آموزشی برابر 0.03 استفاده شده است.

استفاده از این نرخ آموزش برای دسترسی به خطای کمتر و به صورت سعی و خطأ بوده است. نتایج نهایی این تست در شکل‌های (۵)، (۶) و (۷) آورده شده است. در شکل (۵) خروجی شبکه، در شکل (۶) خطای خام شبکه ( $y=0$ ) و در شکل (۷) درصد خطای خام پس از 40 مرتبه آموزش نمایش داده شده است.

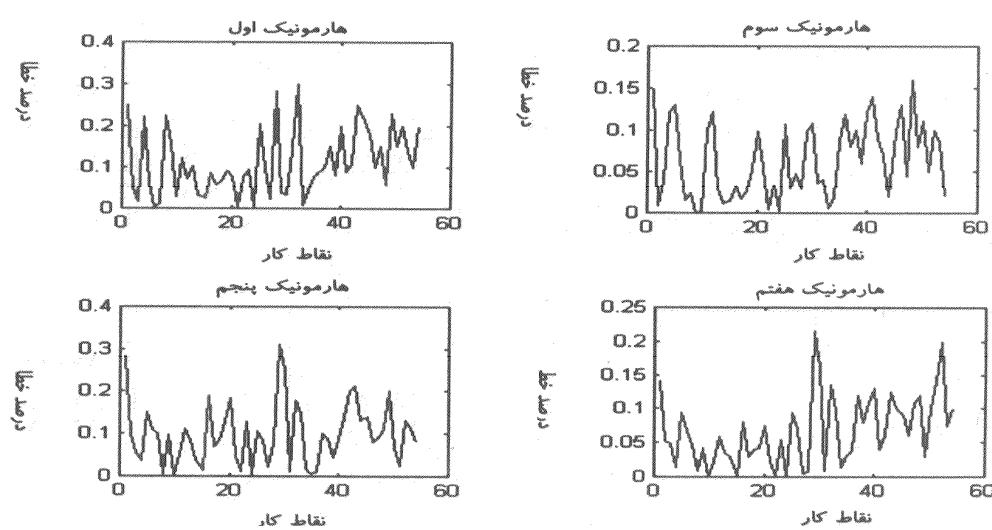
این چهار مورد برای هر چهار هارمونیک برسی شده‌اند. همان طور که ملاحظه می‌گردد در بدترین حالت میزان خطای شبکه طراحی شده برای هارمونیک اول به میزان 45% برای هارمونیک سوم به میزان 53.05% برای هارمونیک پنجم به میزان 63.33% و برای هارمونیک هفتم به میزان 40.08% بوده است. در طراحی سوم برای آموزش نیز شبکه و حل مشکل تعیین تعداد نرونها و کمتر شدن خطای خروجی از شبکه عصبی انعطاف پذیر استفاده شده است. ساختار شبکه همانند همان شبکه قبلی از سه لایه تشکیل شده است. تعداد نرونها در لایه‌های ورودی و خروجی نیز همانند قبل می‌باشد، ولی تعداد نرونها در لایه میانی متغیر است. نرونهای لایه میانی دارای تابع محرک از نوع سیگموئید دو قطبی انعطاف‌پذیر می‌باشد که به صورت رابطه (۲)

معرفی می‌شوند.

در تعیین تعداد لایه‌های پنهان و تعداد نرونهای آنها برای شبکه عصبی معمولی قانون خاصی وجود ندارد ولی به طور کلی طبق تجربیات گذشته تقریباً یک لایه پنهان، برای هر مسئله غیر خطی ورودی به خروجی جوابگو بوده است [۱].

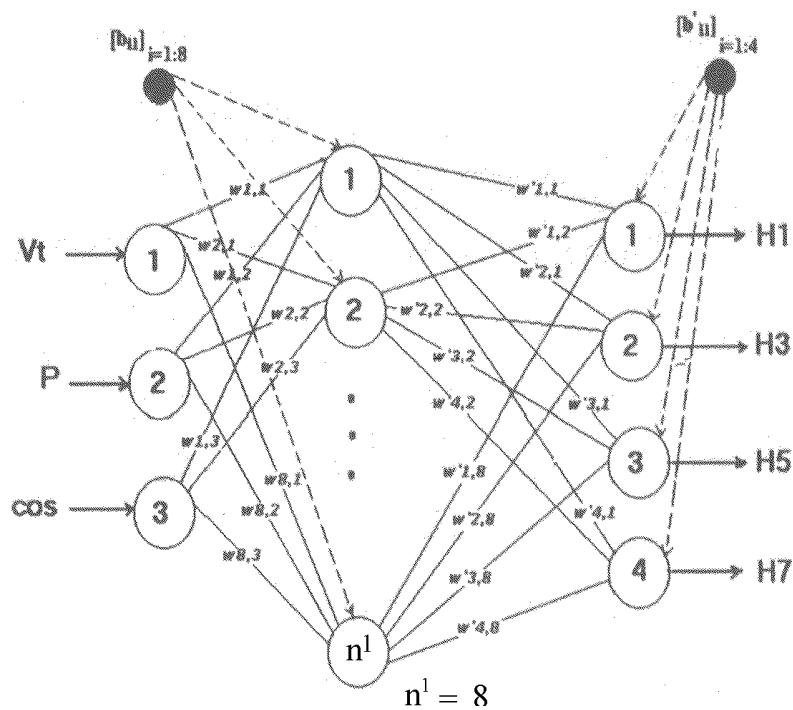
همچنین در تعیین تعداد نرونهای لایه میانی نیز باید آن چنان تعداد آنها را تغییر داد تا بتوان به درصد خطای پایین برای نتایج به دست آمده از شبکه عصبی رسید. برای تشخیص مناسب بودن تعداد نرونهای لایه میانی به بررسی صحت الگوهای ورودی و پیش‌بینی اطلاعات خارجی می‌پردازند.

در قدم اول یک عدد به صورت دلخواه بین یک تا ده به عنوان تعداد نرونها در نظر گرفته می‌شود و سپس چک می‌گردد که آیا شبکه فوق همگرا می‌شود یا خیر؟ بعد از همگرایی، شبکه را با همان الگوهای آموزش‌دهنده تست و سپس خروجیهای حاصل از شبکه را با خروجیهای واقعی مقایسه می‌کنیم، در صورت پایین بودن درصد اختلاف (عمدتاً زیر ۰.۲%) شبکه با آن تعداد نرون در مرحله اول قابل قبول است در غیر این صورت باید تعداد نرونها را آنچنان تغییر داد تا بتوان به نتیجه مطلوب رسید. در مورد شبکه آموزش داده شده نتایج تست فوق در شکل (۳) آورده شده است. همانگونه که ملاحظه می‌گردد در بدترین حالت میزان خطای نرمالیزه شده شبکه (خطا تقسیم بر خروجی مطلوب) طراحی شده به میزان 35 درصد بوده است. به این ترتیب با توجه به تست اول، اعتبار شبکه برای الگوهای ورودی تصدیق گردید و به شبکه‌ای با لایه ورودی با سه نرون، لایه خروجی با چهار نرون و لایه میانی با هشت نرون دست یافتیم که ساختار این شبکه در شکل (۴) آورده شده است. شبکه مورد نظر از نوع پرسپترون و با قانون یادگیری پس انتشار خطای می‌باشد. تابع محرک شبکه، تابع سیگموئید دو قطبی می‌باشد که به صورت رابطه (۱) تعریف می‌شود:

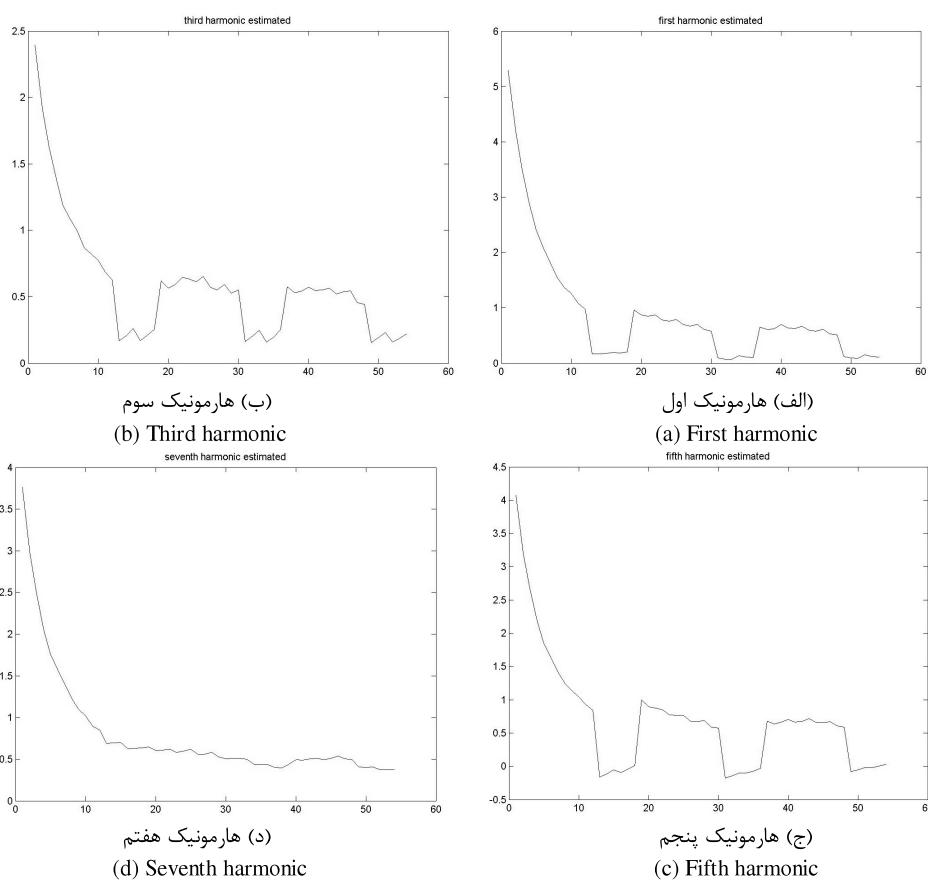


شکل (۳): منحنی درصد خطای بین الگوریتم CFE-SS و شبکه عصبی معمولی برای هارمونیکهای ۱ و ۳ و ۵ و ۷ جریان

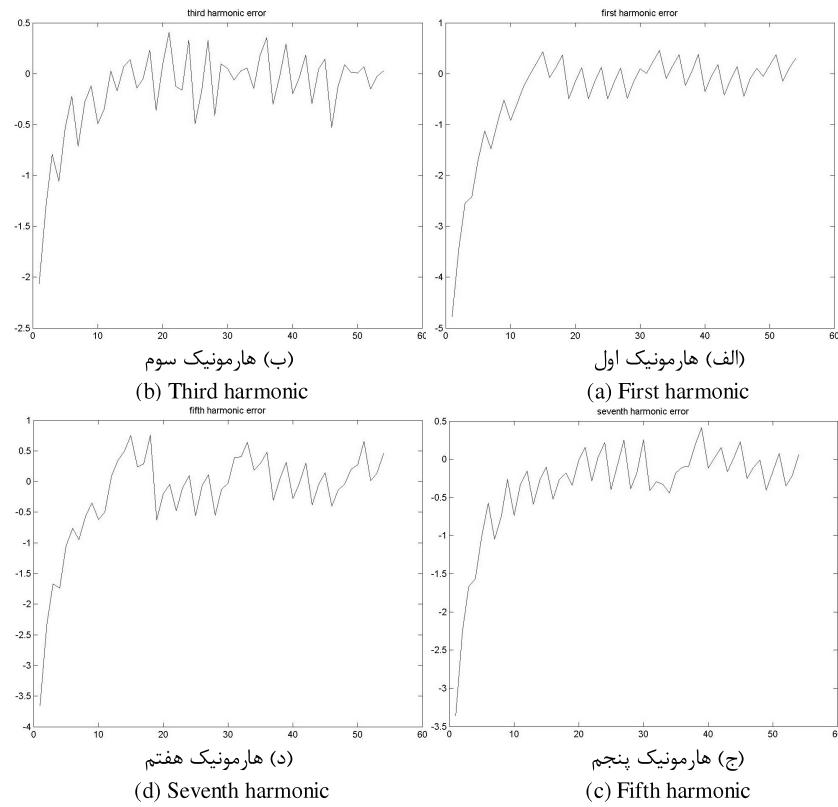
Fig. (3): The graph of percentage of error between CFE-SS algorithm and the neural network for the current harmonics of 1,3,5 and 7



شکل (۴): ساختار شبکه عصبی آموزش داده شده  
Fig. (4): The structure of a trained neural network

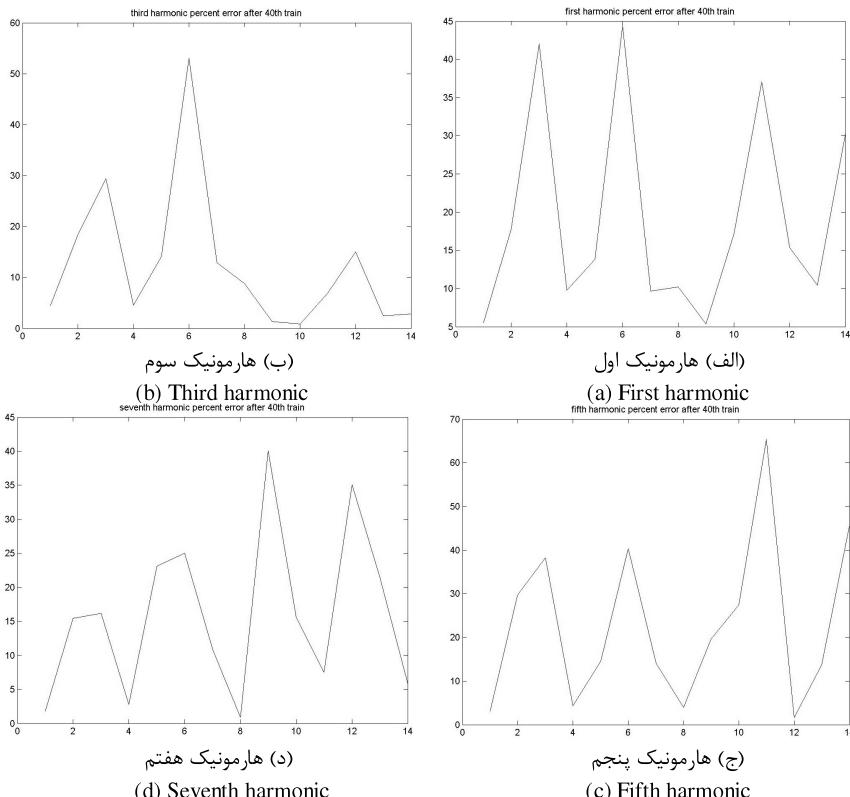


شکل (۵): خروجی شبکه عصبی معمولی  
Fig. (5): The output of a usual neural network



شکل (۶): تغییرات خطای خام شبکه معمولی

Fig. (6): The raw error variations of an usual neural network



شکل (۷): درصد خطای خام شبکه معمولی پس از ۴۰ مرتبه آموزش

Fig. (7): The percentage of an usual raw neural network after 40 times training

شده و از فرآیند پیش رو و پس رو شبکه خارج می‌شوند این کار را می‌توان با گذاشتن Flag یا پرچم‌ها انجام داد. در مقابل این امر، وزنهای لایه‌های قبل همچنان با حذف شدن نرونها آموزش پیدا می‌کنند و فرآیند آموزش در آنها ادامه دارد. به این ترتیب با وارد شدن دوباره یک نرون، ورودیها با وزنهای به روز آوری شده به آن اعمال می‌شوند و شبکه ناپایدار نخواهد شد. به دلیل آموزش گین‌ها در این شبکه دیگر از آموزش باسیها در لایه خروجی استفاده نشده و از چرخه آموزش حذف می‌شوند. برای آموزش گین‌ها همچون آموزش وزنهای از قانون یادگیری پس از انتشار خطا استفاده می‌شود که به صورت رابطه (۳) تعریف می‌شود:

$$\Delta a^1(t) = -\mu \frac{\partial E}{\partial a^1(t)} \quad (3)$$

برای آموزش از مشق تابع حرکه‌ها نسبت به پارامتر  $x$  و نسبت به پارامتر  $a$  به صورت روابط (۴) و (۵) تعریف شده استفاده شده است.

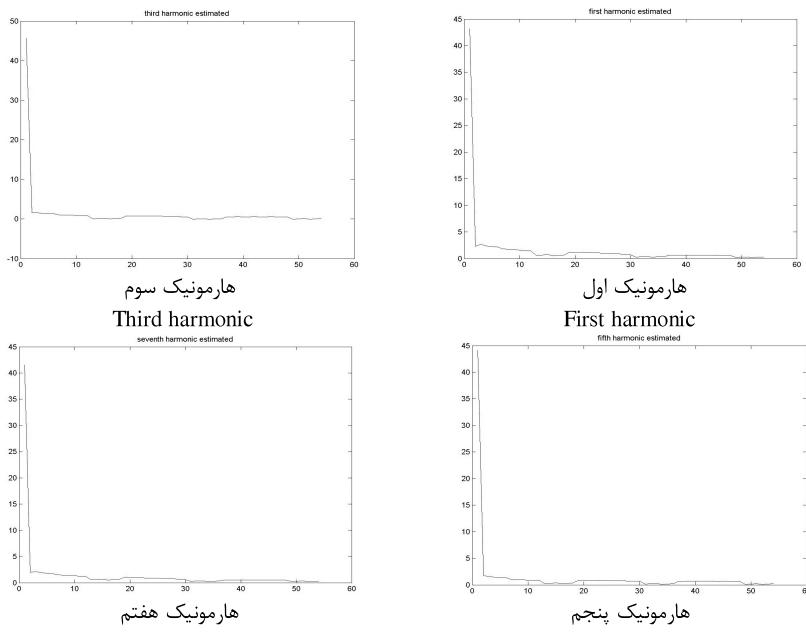
$$f'(x, a^1) = 1 - (a^1)^2 f^2(x, a^1) \quad (4)$$

$$f^*(x, a^1) = \frac{1}{a^1} [f'(x, a^1)x - f(x, a^1)] \quad (5)$$

در تست نهائی انجام شده از ضریب آموزش 0.012 برای آموزش وزنهای و بایاسها و 0.0002 برای آموزش پارامترهای های تابع حرکه استفاده شده است. نتایج نهائی این تست در شکل‌های (۸)، (۹) و (۱۰) آورده شده است. در شکل (۸) خروجی شبکه، در شکل (۹) خطای خام شبکه ( $y=0$ ) و در شکل (۱۰) درصد خطای خام را پس از 40 مرتبه آموزش نمایش داده شده است. این چهار مورد برای هر چهار هارمونیک بررسی شده‌اند.

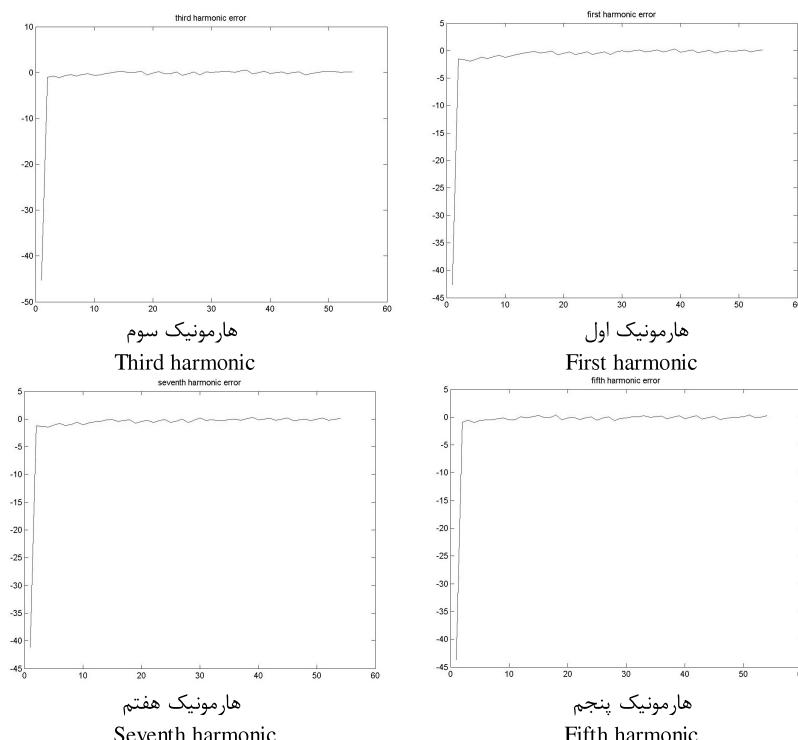
$$f(x, a^1) = \tanh(x, a^1) = \frac{1}{a^1} * \frac{1 - e^{-2xa^1}}{1 + e^{-2xa^1}} \quad (2)$$

استفاده از تابع دو قطبی به این دلیل است که وقتی در جریان آموزش شبکه  $a^1$  به سمت صفر می‌کند این تابع به صورت یک تابع خطی در می‌آید و باعث ناپایداری شبکه نمی‌شود [۳]. در این شبکه همچون قبل وزنهای آموزش پیدا می‌کنند. برای آموزش از به روز آوردن پارامترها استفاده شده است. علاوه بر این گین  $a^1$  نیز در فرآیند آموزش شرکت داشته و دائمًا در حال تغییر است. از مزیتهای دیگر این تابع این است که وارد ناحیه اشباع نمی‌شوند و به نزنهای فیزیولوژیکی طبیعی تر زدیکتر هستند. همچنین وجود پارامتر  $a^1$  سبب می‌شود که یک شبکه حافظه نیز داشته باشیم [۳]. مقدار اولیه وزنهای به صورت تصادفی انتخاب می‌شوند و فرآیند آموزش آنها همچون قبل از این مقدار اولیه گین‌ها ( $a^1$ ) یک انتخاب می‌شود. تعداد نزنهای اولیه نیز 100 می‌باشد که در فرآیند آموزش تغییر پیدا می‌کنند. طریقه تغییر آنها به این صورت است که اگر گین از یک مقدار آستانه که در این مقاله 1.004 است کمتر شد آن نزون حذف و اگر در مراحل بعدی آموزش مقدار گین از آن حد آستانه بیشتر شود نزون دوباره وارد ساختار شبکه عصبی می‌شود. به همین دلیل تعداد نزنهای به صورت بهمنه انتخاب می‌شوند و دیگر مشکل انتخاب نزنهای را نخواهیم داشت. در تست نمونه انجام شده تعداد نزنهای از 100 عدد اولیه به 7 رسیده است و این خیلی نزدیک به آن چیزی است که ما به صورت سعی و خطاب دست آورده بودیم، با حذف هر نزون از فرآیند آموزش وزنهای مرتبط با آن در لایه‌های بعدی دیگر آموزش پیدا نمی‌کنند و مقدار آنها ثابت



شکل (۸): خروجی شبکه انعطاف‌پذیر

Fig. (8): The output of a flexible neural network



شکل (۹): تغییرات خطای خام شبکه انعطاف پذیر  
Fig. (9): The variations of raw error of a flexible neural network

از هارمونیکهای جریان در حالت بدون خطای خام برای نقاط مختلف کاری به دست آورده و نیاز به اجرای الگوریتم CFE-SS برای به دست آوردن هارمونیکهای جریان در نقاط مختلف کاری نمی‌باشد. همچنین باید گفت که علت اصلی روی آوردن به شبکه عصبی برای به دست آوردن پارامترهای ژنراتور و یا هر ماشین دیگر نیز زمانبر بودن الگوریتمهای مثل CFE-SS و ... بوده است. از آنجا که در کاربرد موردنظر ما که تشخیص خطای در ژنراتور می‌باشد، دقت به دست آوردن این پارامترها در همین حدود نیز مناسب است پس شبکه عصبی برای این منظور با موفقیت عمل نموده است. اما هدف اصلی بحث فوق مقایسه شبکه‌های عصبی معمولی و انعطاف‌پذیر ساختار متغیر بوده است. برای مقایسه دقیق‌تر این دو روش و اثبات نظراتمان در مورد شبکه‌های عصبی انعطاف‌پذیر حداکثر خطای این شبکه‌ها را برای هارمونیکهای مختلف در جدول (۴) فهرست کرده‌ایم.

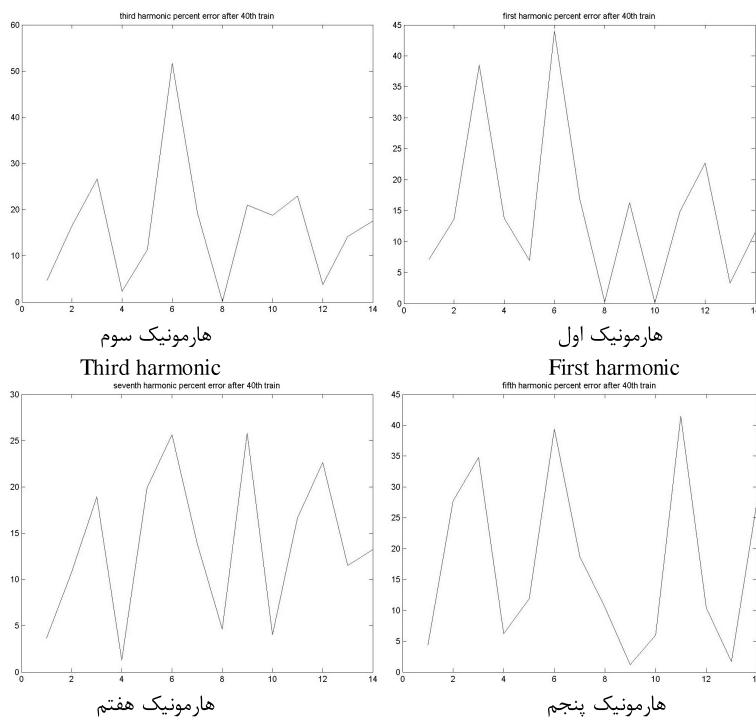
مشاهده می‌شود که همان طور که انتظار داشتیم شبکه عصبی انعطاف‌پذیر ساختار متغیر خیلی بهتر عمل نموده و خطای را به میزان چشمگیری کاهش داده است و این در عین حذف آزمایش و خطاهای وقت‌گیر برای تعیین تعداد نرونها و همچنین بازسازی ساختار شبکه عصبی مطابق با تغییرات سیستم و ورود اختشاشات است که خود گامی مهم جهت استفاده از شبکه‌های عصبی با ساختار بهینه می‌باشد.

همان طور که ملاحظه می‌گردد در بدترین حالت میزان خطای شبکه طراحی شده برای هارمونیک اول به میزان ۴۴.۰۸٪ برای هارمونیک سوم به میزان ۵۱.۷۳٪ برای هارمونیک پنجم به میزان ۴۱.۴۸٪ و برای هارمونیک هفتم به میزان ۲۵.۸۲٪ بوده است. ساختار شبکه باز مطابق شکل (۴) می‌باشد که در آن که در آن در طول فرآیند آموزش  $n^1$  دائمًا در حال تغییر است. شبکه مورد نظر از نوع پرسپترون انعطاف‌پذیر و با قانون یادگیری پس انتشار خطای برای آموزش پارامترها و وزنها می‌باشد. همچنینتابع هدف برای اصلاح وزنهای شبکه نیز همچون قبل حداقل کردن مجموع مربعات خطای مابین خروجی مطلوب و خروجی شبکه عصبی می‌باشد.

در شکل (۱۱) تغییرات تعداد نرونها را در مراحل مختلف آموزش مشاهده خواهید کرد. همانطور که مشاهده می‌گردد تعداد نرونها از ۱۰۰ عدد به ۷ عدد کاهش یافته است.

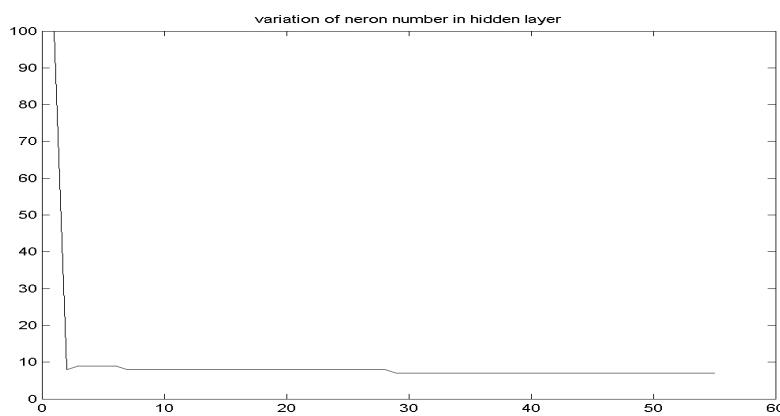
#### ۴- نتیجه گیری

همانطور که ملاحظه گردید، بعد از اینکه شبکه با استفاده از نتایج نقاط کار و در نظر گرفته شده از منحنی بهره‌برداری ژنراتور با یک لایه میانی و با قانون یادگیری پس انتشار خطای آموزش داده شد خطای نرمالیزه شده زیر ۳۵ درصد را برای بدترین نقطه کار نتیجه داد. لذا می‌توان نتیجه گرفت که با استفاده از شبکه عصبی می‌توان تقریب بسیار خوبی



شکل (۱۰): درصد خطای خام شبکه انعطاف پذیر پس از ۴۰ مرتبه آموزش

Fig. (10): The percentage of the error of a flexible neural network after 40 times training



شکل (۱۱): تغییرات تعداد نرونها در طول آموزش

Fig. (11): The variations of the number of neurons during training

Table (4): The maximum errors of both networks in each harmonic

جدول (۴): حداکثر خطاهای هر دو شبکه در هر هارمونیک

هارمونیک هفتم	هارمونیک پنجم	هارمونیک سوم	هارمونیک اول	هارمونیکها
%40.08	%63.33	%53.05	%45	شبکه عصبی معمولی
%25.82	%51.73	%44.08	%41.48	شبکه عصبی انعطاف پذیر

### References

- [1] S. Soleimani, A. Ranjbar, H. Mirabedini, "The use of versatile neuro networks in estimating the harmonics of ASK generator of ray power station based on CFS/SS algorithm", Power Jou. NO.31, pp.25-28, Spring 2000.
- [2] S.R. Chaudhry, N.A. Demerdash,"An artificial-neural-network method for the identification of saturated turbo generator p-arameters based on coupled finite-element/state-space computational algoritm",IEEE Trans. on Ene. Conv., Vol.10,No.4, Dec. 1995.
- [3] M. Teshnghlab, K. Watanabe, "Intelligent control based on flexible neural networks", Kluwer Academic publishers,

Dordrecht, Boston, London, 1999.

- [4] S. Haykin, "Neural networks a comprehensive foundation", Second Edition, Prentice Hall International Inc., USA, Mexico, or Canada, 1999.
- [5] M. Teshnehlab, K. Watanabe, "The high flexibility and learning capability of neural networks with learning bipolar and unipolar sigmoid function", Proceeding of Japan-U.S.A. Symposium on flexible automation, Vol.3, pp.1453-1460, Kobe, 1994.
- [6] M. Teshnehlab, K. Watanabe, "Flexible structural learning control of a robotic manipulator using artificial neural networks", JSME International Journal, Vol.13, pp.1-21, 1995.
- [7] M. Teshnehlab, K. Watanabe, "Neural networks controller with flexible structure based on feed-back-error-learning", Jour. of Int. & Rob. Sys., Vol.15, No.4, pp.367-387, 1996.
- [8] S.R. Chaudhry, S. Ahmed-Zaid, N.A. Demerdash, "Coupled finite-element/state-space modeling of turbo generators in the ABC frame of reference—the no-load case", IEEE Trans. on Ene. Conv., Vol.10, No.1, March 1995.
- [9] E. Khosrow-shahi, A. Ranjbar, H. Mirabedini, "Identification of synchronous Generator error during analyzing the stator harmonics", Power Jou. No.31, pp.41-46, Spring 2000.
- [10] A. Ranjbar, "Theory of synchronous machines", The Sharif University, 1994.
- [11] M.B. Menhaj, "The basis of neuro networks systems", The Amir Kabir University of Technology, Tafresh Branch, Prof. Hessabi Publishing Center.
- [12] M. Saghaian Nejad, H.N. Khajooie, "The analysis of Electric machines", Isfahan University of Technology, 1997.

#### رزومه



محمد رضا یوسفی نجف‌آبادی در سال ۱۳۵۹ در شهر نجف‌آباد متولد شد. ایشان فارغ التحصیل کارشناسی مهندسی برق قدرت از دانشگاه آزاد اسلامی واحد نجف‌آباد و مقطع کارشناسی ارشد بیوکلریک از دانشگاه صنعتی خواجه نصیرالدین طوسی می‌باشد. ایشان تاکنون نزدیک به ۳۰ مقاله علمی در کنفرانسها و مجلات داخلی و خارجی به چاپ رسیده است. زمینه تخصصی مورد علاقه ایشان ماشینهای الکتریکی، اتوماسیون صنعتی، کنترل فازی و شبکه‌های عصبی می‌باشد. ایشان ایده شبکه‌های عصبی ساختار متغیر را در سال ۱۳۸۳ مطرح نمودند.



محمد تنه لب استاد گروه کنترل دانشگاه صنعتی خواجه نصیرالدین طوسی دارای درجه Ph.D از EE Saga ژاپن می‌باشد. از ایشان تا کنون ۲ کتاب در زمینه کنترل فازی و بیش از ۲۲ مقاله ISI و ۶۰ مقاله علمی در کنفرانس‌های معتبر خارجی به چاپ رسیده است. ایشان در زمینه کنترل خطی، شبکه‌های عصبی، کنترل فازی و سیستمهای تکاملی و زیستی فعالیتهای زیادی داشته‌اند.

