

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

محمد رضا یوسفی نجف آبادی^(۱) - محمد تشنه لب^(۲)

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

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

خلاصه: یکی از روشهای تشخیص خطای ژنراتور در حین کار، آنالیز هارمونیک‌های جریان استاتور می‌باشد. در این مقاله از شبکه‌های عصبی انعطاف پذیر 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 بدست 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 انعطاف پذیر آموزش داده شده با خطای کمتر از ده درصد می‌تواند هارمونیک‌های جریان را برای نقاط بار دلخواه روی منحنی بهره برداری، نسبت به نتایج حاصل از الگوریتم CFE-SS به دست آورد. پارامترهای نامی ژنراتور آسک عبارتند از: ۴۳۹۵۰ کیلو ولت آمپر، ۱۱ کیلو ولت، ۳۰۰۰ رادیان بر دقیقه، ۵۰ هرتز و ضریب توان ۰/۸.

کلمات کلیدی: روش المان محدود، شبکه عصبی انعطاف پذیر، منحنی بهره برداری و ژنراتور سنکرون

۱- مقدمه

ماشین در حالت خطادار مقایسه کرد، تا بتوان تشخیص داد که آیا خطایی صورت گرفته 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 خطا استفاده می‌شود. در این مقاله هدف، به دست آوردن هارمونیک‌های شکل موج جریان استاتور در شرایط بدون خطا برای نقاط مختلف کار است تا در صورت وقوع خطا، از طریق مشاهده تغییر هارمونیک‌های جریان نسبت به شرایط بدون خطا، بتوان در مورد روی دادن خطا نظر داد. از آنجا که ترکیب دو مدل المان محدود و فضای حالت (CFE-SS) در به دست آوردن هارمونیک‌های جریان برای همه نقطه کارهای مختلف ژنراتور، بسیار مشکل و زمانبر است، از شبکه عصبی برای تعیین این پارامترها استفاده شده است. سلیمانی، رنجیر و میر عابدینی در مرجع [۱] اینکار

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 قبل از آنکه در اثر بروز خطا از مدار خارج شود، بلافاصله بعد از رخ دادن خطا، برای تعمیرات خارج سازند. یافتن محل خطا نیز از اهمیت بالایی برخوردار است. در این مقاله هدف آن است که بتوان به هنگام به وجود آمدن خطا، تغییرات پارامترهای ماشین را دنبال نمود و از روی آنها به محل خطا پی برد. بنابراین لازم است مشخصه‌هایی را که می‌توان به صورت به هنگام در ماشین اندازه‌گیری نمود، تحت شرایط مختلف کاری ماشین، در شرایط بدون خطا از طریق تئوری محاسبه نمود و سپس با مقدار اندازه‌گیری شده از

پریونیت برای ولتاژ پایانه استفاده شده است. جدول‌های (۱) و (۲) و (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 برحسب نمونه برای هر چهار هارمونیک نشان داده شده است.

۳ - 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 نرونهای لایه ورودی و لایه خروجی، تعیین تعداد لایه‌های پنهان و سپس تعیین تعداد نرونهای هر یک از لایه‌های پنهان به سادگی دیده می‌شود که هر نقطه کار از روی سه پارامتر ولتاژ، جریان و ضریب توان از بقیه نقاط مجزا می‌گردد که این امر نشان دهنده تعداد نرونهای لایه ورودی می‌باشد. لذا لایه ورودی دارای سه نرون و سه بردار ورودی ولتاژ، جریان و ضریب توان خواهد بود. تعداد نرونهای 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.

را با استفاده از شبکه عصبی معمولی سه لایه و روش پس انتشار خطا انجام داده‌اند. در این مقاله ابتدا با یک شبکه عصبی با ساختار ۳ لایه پیشنهادی این کار 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 داده شود. برای تعیین 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 ضریب توان بزرگتر از ۰/۸ و در شرایط پیش فاز نیز دارای ضریب توان بزرگتر از ۰/۹۵ می‌باشد. همچنین در این ژنراتور در توان ۰/۷، ۰/۸ 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 ۰/۹۵، ۱ و ۱/۰۵



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

جدول (۱): نقاط کار در سطح ولتاژ یک پریونیت


نقاط کار	جریان فاز a (pu) $*10^{-5}$	توان p $*10^{-1}$	ضریب توان $\cos\Phi * 10^{-2}$	هارمونیک اول $*10^{-1}$	هارمونیک سوم $*10^{-2}$	هارمونیک پنجم $*10^{-2}$	هارمونیک هفتم $*10^{-2}$
۱	۷۰۰۰۰	۷	۸۰	۲۳۹۷۷	۲۰۹۹۰	۱۱۷۶۰	۱۵۷۷۰
۲	۸۰۰۰۰	۸	۸۰	۲۶۸۸۵	۲۵۸۶۰	۱۳۶۹۰	۱۸۳۷۰
۳	۹۰۰۰۰	۹	۸۰	۲۹۷۸۵	۳۰۰۱۰	۱۴۴۷۰	۱۹۹۸۰
۴	۶۶۰۰۰	۷	۸۵	۲۲۹۸۸	۲۴۱۵۰	۱۱۷۷۰	۱۶۰۲۰
۵	۷۵۳۰۰	۸	۸۵	۲۵۸۴۹	۲۳۵۴۰	۱۳۵۴۰	۱۸۵۲۰
۶	۸۴۷۰۰	۹	۸۵	۲۸۸۶۱	۲۹۳۱۴	۱۴۶۶۰	۲۰۴۱۰
۷	۶۲۲۰۰	۷	۹۰	۲۱۹۸۰	۱۹۷۵۰	۱۰۸۳۰	۱۴۹۶۰
۸	۷۱۲۰۰	۸	۹۰	۲۴۷۷۶	۲۲۷۸۰	۱۳۲۱۴	۱۷۴۳۰
۹	۸۰۰۰۰	۹	۹۰	۲۷۶۴۶	۲۸۵۶۰	۱۴۲۱۸	۲۰۳۴۰
۱۰	۵۸۹۰۰	۷	۹۵	۲۱۰۹۵	۲۰۰۵۰	۱۰۳۴۶	۱۴۷۶۰
۱۱	۶۷۴۰۰	۸	۹۵	۲۳۸۰۰	۲۵۴۲۰	۱۳۲۹۰	۱۶۱۱۸
۱۲	۷۵۸۰۰	۹	۹۵	۲۶۳۴۰	۲۵۱۴۰	۱۳۷۹۰	۱۹۸۹۰
۱۳	۵۸۹۰۰	۷	-۹۵	۱۹۷۴۷	۱۹۰۲۰	۱۰۸۱۰	۱۳۸۷۰
۱۴	۶۷۴۰۰	۸	-۹۵	۲۳۲۰۴	۲۰۶۱۰	۱۱۱۳۰	۱۴۸۹۰
۱۵	۷۵۸۰۰	۹	-۹۵	۲۴۵۹۰	۲۱۵۳۰	۱۲۷۶۰	۱۴۵۳۰
۱۶	۵۷۱۴۳	۷	-۹۸	۱۹۰۳۰	۱۷۹۹۰	۱۰۰۶۰	۱۲۹۶۰
۱۷	۶۵۳۰۶	۸	-۹۸	۲۱۴۹۵	۲۲۳۹۰	۱۰۹۰۰	۱۵۲۶۰
۱۸	۷۳۴۶۹	۹	-۹۸	۲۴۰۷۵	۲۵۲۰۰	۱۳۳۱۰	۱۵۹۹۰

جدول (۲): نقاط کار در سطح ولتاژ ۰/۹۵ پریونیت

نقاط کار	جریان فاز a (pu) $*10^{-5}$	توان p $*10^{-1}$	ضریب توان $\cos\Phi * 10^{-2}$	هارمونیک اول $*10^{-1}$	هارمونیک سوم $*10^{-2}$	هارمونیک پنجم $*10^{-2}$	هارمونیک هفتم $*10^{-2}$
۱	۷۳۷۰۰	۷	۸۰	۲۵۰۷۱	۲۳۷۱۰	۱۴۱۲۰	۱۷۱۳۰
۲	۸۴۲۰۰	۸	۸۰	۲۲۱۸۳	۱۹۷۵۰	۱۱۰۰۰	۱۶۲۷۰
۳	۹۴۷۰۰	۹	۸۰	۱۹۹۳۹	۱۸۱۷۰	۱۰۴۲۰	۱۳۸۹۰
۴	۶۹۵۰۰	۷	۸۵	۲۵۵۸۵	۲۲۶۹۰	۱۳۷۲۰	۱۸۴۳۰
۵	۷۹۳۰۰	۸	۸۵	۲۲۸۹۴	۲۱۲۵۰	۱۱۸۵۰	۱۶۸۷۰
۶	۸۹۲۰۰	۹	۸۵	۲۰۳۴۸	۱۷۸۲۰	۱۰۶۲۰	۱۳۹۱۰
۷	۶۵۵۰۰	۷	۹۰	۲۷۰۱۳	۲۵۷۸۰	۱۵۰۸۰	۱۹۲۷۰
۸	۷۴۸۰۰	۸	۹۰	۲۴۲۰۸	۲۱۹۴۰	۱۲۱۴۰	۱۸۱۶۰
۹	۸۴۲۰۰	۹	۹۰	۲۲۴۹۰	۲۱۲۶۰	۱۲۰۷۰	۱۵۵۴۰
۱۰	۶۲۰۰۰	۷	۹۵	۲۸۴۴۳	۲۶۴۰۰	۱۴۲۸۰	۲۰۵۸۰
۱۱	۷۰۹۰۰	۸	۹۵	۲۵۵۷۸	۲۵۰۸۰	۱۳۵۹۰	۱۷۳۳۰
۱۲	۷۹۸۰۰	۹	۹۵	۲۲۵۹۶	۲۱۲۷۰	۱۳۳۹۰	۱۶۲۵۰
۱۳	-۶۲۰۰۰	۷	۹۵	۲۹۶۵۷	۲۱۸۰۰	۱۴۷۱۰	۲۲۰۵۰
۱۴	-۷۰۹۰۰	۸	۹۵	۲۴۵۷۴	۲۵۲۹۰	۱۴۲۱۰	۱۹۷۱۰
۱۵	-۷۹۸۰۰	۹	۹۵	۲۷۷۸۰	۲۸۰۶۰	۱۲۲۵۰	۱۷۳۹۰
۱۶	-۶۰۱۵۰	۷	۹۸	۲۹۶۷۰	۲۱۹۰۰	۱۵۴۸۰	۲۰۴۷۰
۱۷	-۶۸۷۴۳	۸	۹۸	۲۳۸۱۷	۲۵۷۶۰	۱۴۶۹۰	۱۹۶۵۰
۱۸	-۷۷۳۳۰	۹	۹۸	۲۶۷۴۲	۲۸۳۰۰	۱۲۰۴۰	۱۶۶۳۰

جدول (۳): نقاط کار در سطح ولتاژ ۱/۰۵ پریونیت

نقاط کار	جریان فاز a *10 ⁻⁵ (pu)	توان p *10 ⁻¹	ضریب توان cosΦ *10 ⁻²	هارمونیک اول *10 ⁻¹	هارمونیک سوم *10 ⁻²	هارمونیک پنجم *10 ⁻²	هارمونیک هفتم *10 ⁻²
۱	۶۶۶۰۰	۷	۸۰	۲۳۴۴۰	۲۱۱۴۰	۱۱۷۷۰	۱۵۷۵۰
۲	۷۶۲۰۰	۸	۸۰	۲۶۲۳۳	۲۴۰۰۰	۱۳۴۲۰	۱۸۲۸۰
۳	۸۹۱۰۰	۹	۸۰	۳۰۱۳۷	۲۷۹۷۰	۱۵۳۵۰	۲۰۶۹۰
۴	۶۲۸۰۰	۷	۸۵	۲۲۶۳۲	۲۲۳۹۰	۱۲۰۸۰	۱۶۴۵۰
۵	۷۱۷۰۰	۸	۸۵	۲۵۳۱۸	۲۳۹۴۰	۱۳۳۳۰	۱۷۵۷۰
۶	۸۰۷۶۰	۹	۸۵	۲۷۹۱۱	۲۶۷۶۰	۱۵۳۱۰	۱۸۹۳۰
۷	۵۹۲۰۰	۷	۹۰	۲۱۵۱۱	۲۱۱۰۰	۱۱۵۴۰	۱۶۱۵۰
۸	۶۷۷۰۰	۸	۹۰	۲۴۳۲۷	۲۴۷۱۰	۱۳۱۹۰	۱۷۷۲۰
۹	۷۶۲۰۰	۹	۹۰	۲۶۸۵۶	۲۶۱۰۰	۱۴۳۳۰	۱۹۷۱۰
۱۰	۵۶۱۰۰	۷	۹۵	۲۰۵۵۰	۱۷۹۹۰	۱۱۱۷۰	۱۵۵۵۰
۱۱	۶۴۲۰۰	۸	۹۵	۲۳۵۸۳	۲۱۸۱۰	۱۲۳۳۰	۱۶۵۴۰
۱۲	۷۲۲۰۰	۹	۹۵	۲۵۶۶۰	۲۴۲۶۰	۱۲۸۳۰	۱۷۳۶۰
۱۳	۵۶۱۰۰	۷	-۹۵	۱۹۳۹۹	۱۹۸۹۰	۱۰۲۶۰	۱۲۹۹۰
۱۴	۶۴۲۰۰	۸	-۹۵	۲۱۶۵۷	۲۰۲۹۰	۱۰۸۸۰	۱۵۱۹۰
۱۵	۷۲۲۰۰	۹	-۹۵	۲۳۸۳۱	۲۱۴۹۰	۱۳۳۱۰	۱۷۳۲۰
۱۶	۵۴۴۲۲	۹	-۹۸	۱۸۶۲۰	۱۷۹۳۰	۰۹۵۸۰	۱۳۱۷۰
۱۷	۶۲۱۹۶	۸	-۹۸	۲۱۲۱۰	۲۰۸۵۰	۱۰۴۱۰	۱۴۴۱۰
۱۸	۶۹۹۷۱	۷	-۹۸	۲۳۳۵۰	۱۹۷۸۰	۱۲۴۶۰	۱۶۸۹۰



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

دلیل این انتخاب منفی شدن ورودیهای شبکه است، بدین معنا که محدوده تغییرات ورودی هم در ناحیه مثبت و هم در ناحیه منفی می-باشد. برای یادگیری شبکه، تک تک داده‌ها به شبکه داده شد تا وزنه‌های شبکه را آموزش دهند و اینکار برای هر ۱۸ مورد داده در هر یک از ولتاژها انجام می‌شود یعنی شبکه با ۵۴ داده آموزش یافته است. همچنین تابع هدف برای اصلاح وزنها و بایاسهای شبکه، مینیمم کردن مجموع مربعات خطای ما بین خروجی مطلوب و خروجی شبکه عصبی می‌باشد. در این طراحی از نرخ آموزشی برابر ۰/۰۳ استفاده شده است. استفاده از این نرخ آموزش برای دسترسی به خطای کمتر و به صورت سعی و خطا بوده است. نتایج نهائی این تست در شکل‌های (۵)، (۶) و (۷) آورده شده است. در شکل (۵) خروجی شبکه، در شکل (۶) خطای خام شبکه $(e = y - 0)$ و در شکل (۷) درصد خطای خام پس از ۴۰ مرتبه آموزش نمایش داده شده است.

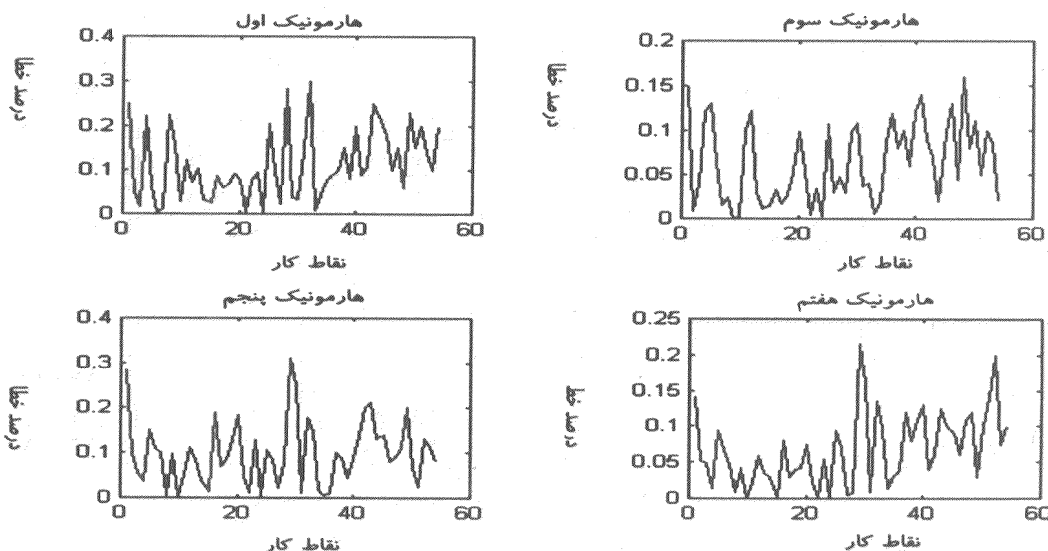
این چهار مورد برای هر چهار هارمونیک بررسی شده‌اند. همانطور که ملاحظه می‌گردد در بدترین حالت میزان خطای شبکه طراحی شده برای هارمونیک اول به میزان ۰/۴۵٪ برای هارمونیک سوم به میزان ۰/۵۳٪ برای هارمونیک پنجم به میزان ۰/۶۳٪ و برای هارمونیک هفتم به میزان ۰/۴۰٪ بوده است. در طراحی سوم برای آموزش نیز شبکه و حل 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 لایه-های 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 انعطاف پذیر می‌باشند که به صورت رابطه (۲) تعریف 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 بدست آمده از شبکه عصبی رسید. برای تشخیص مناسب بودن تعداد نرون‌های لایه میانی به بررسی صحت الگوهای ورودی و پیش بینی 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 آموزش دهنده 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 اینصورت 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 می-گردد در بدترین حالت میزان خطای نرمالیزه شده شبکه (خطا تقسیم بر خروجی مطلوب) طراحی شده به میزان ۳۵ 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 خطا می‌باشد. تابع محرک شبکه، تابع سیگموئید دو قطبی می‌باشد که به صورت رابطه (۱) تعریف می‌شود:

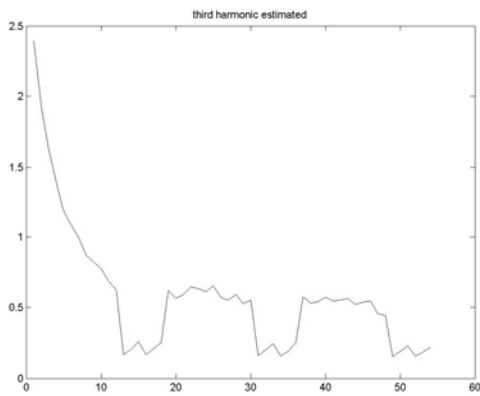
$$f(x) = \tanh(x) = \frac{1 - e^{-x}}{1 + e^{-x}} = \frac{2}{1 + \exp(-2x)} - 1 \quad (1)$$



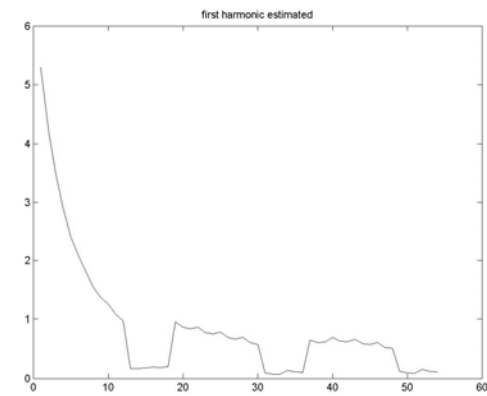
شکل (۳): منحنی درصد خطای بین الگوریتم CFE-SS و شبکه عصبی معمولی برای هارمونیک‌های ۱ و ۳ و ۵ و ۷ جریان



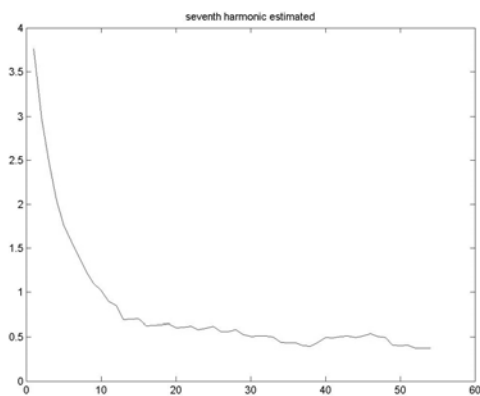
شکل (۴): ساختار شبکه عصبی آموزش داده شده




(ب) هارمونیک سوم



(الف) هارمونیک اول




(د) هارمونیک هفتم

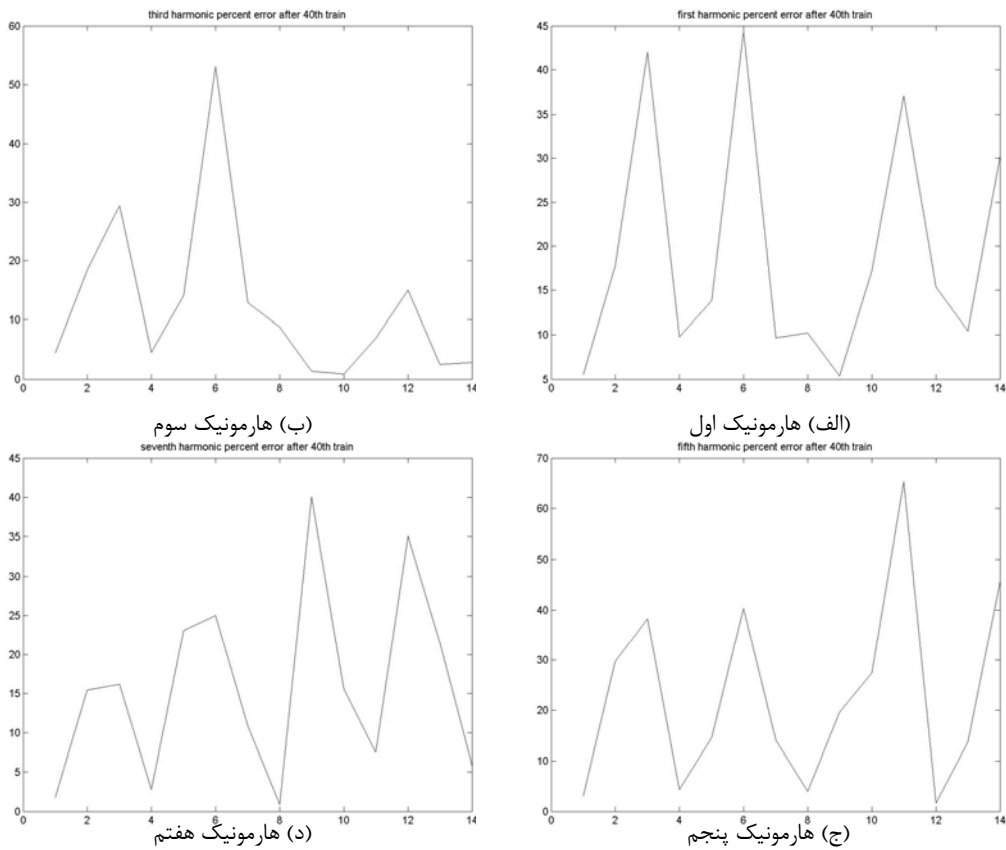


(ج) هارمونیک پنجم

شکل (۵): خروجی شبکه عصبی معمولی



شکل (۶): تغییرات خطای خام شبکه معمولی



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

می‌توان با گذاشتن Flag یا پرچم‌ها انجام داد. در مقابل این امر، وزنه‌های 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 وزنه‌های به روز آوری شده به آن اعمال می‌شوند و شبکه ناپایدار نخواهد شد. به دلیل آموزش گین‌ها در این شبکه دیگر از آموزش بایاسها در لایه خروجی استفاده نشده و از چرخه آموزش حذف می‌شوند. برای آموزش گین‌ها همچون آموزش وزنه‌ها از قانون یادگیری پس از انشار خطا استفاده می‌شود که به صورت رابطه (۳) تعریف می‌شود:

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

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

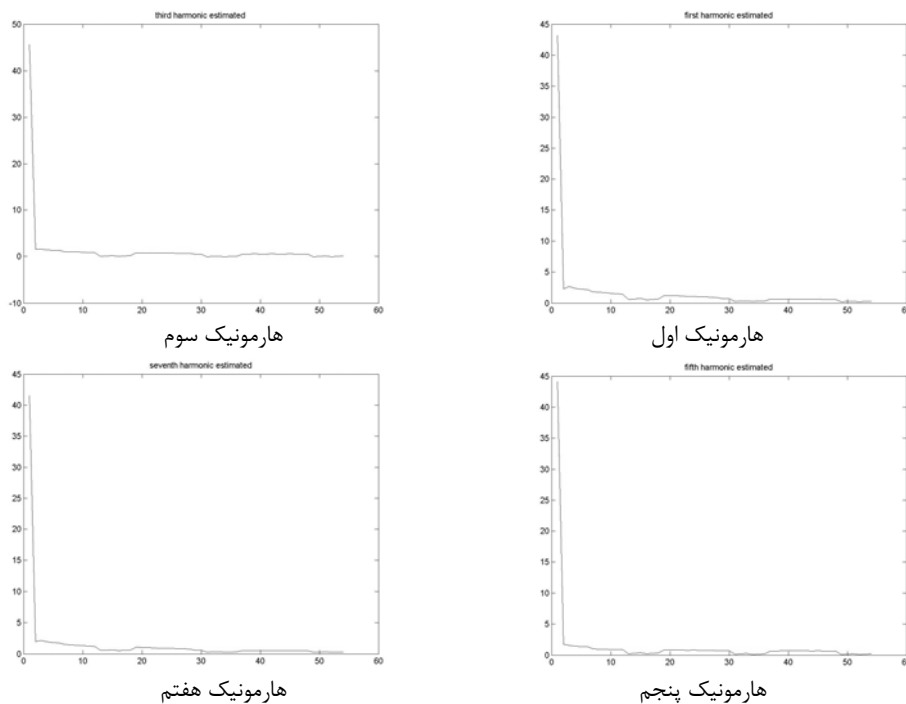
$$f'(x, a^l) = 1 - (a^l)^2 f^2(x, a^l) \quad (4)$$

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

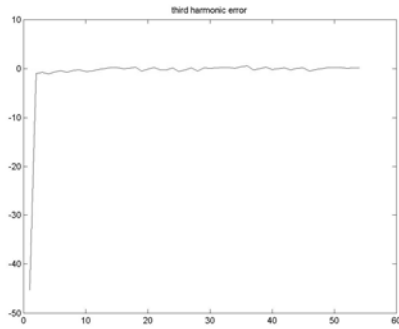
در تست نهائی انجام شده از ضریب آموزش 0.12 برای آموزش وزنه‌ها و بایاسها و 0.002 برای آموزش پارامترهای تابع محرکه استفاده شده است. نتایج نهائی این تست در شکل‌های (۸)، (۹) و (۱۰) آورده شده است. در شکل (۸) خروجی شبکه، در شکل (۹) خطای خام شبکه $(e = y - 0)$ و در شکل (۱۰) درصد خطای خام را پس از 40 مرتبه آموزش نمایش داده شده است. این چهار مورد برای هر چهار هارمونیک بررسی شده‌اند.

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


استفاده از تابع دو قطبی به این دلیل است که وقتی در جریان آموزش شبکه a^l به سمت صفر میل می‌کند این تابع به صورت یک تابع خطی در می‌آید و باعث ناپایداری شبکه نمی‌شود [۳]. در این شبکه همچون قبل وزنه‌ها آموزش پیدا می‌کنند. برای آموزش از به روز آوردن پارامترها استفاده شده است. علاوه بر این گین a^l نیز در فرآیند آموزش شرکت داشته و دائماً در حال تغییر است. از مزیت‌های دیگر این تابع این است که وارد ناحیه اشباع نمی‌شوند و به نرون‌های فیزیولوژیکی طبیعی نزدیک‌تر هستند. همچنین وجود پارامتر a^l سبب می‌شود که یک شبه حافظه نیز داشته باشیم [۳]. مقادیر اولیه وزنه‌ها به صورت تصادفی انتخاب می‌شوند و فرآیند آموزش آنها همچون قبل می‌باشد. مقادیر اولیه گین‌ها (a^l) یک انتخاب می‌شود. تعداد نرون‌های 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 $1/0.4$ است کمتر شد آن نرون حذف و اگر در مراحل بعدی آموزش مقدار گین از آن حد آستانه بیشتر شود نرون دوباره وارد ساختار شبکه عصبی می‌شود. به همین دلیل تعداد نرون‌ها به صورت بهینه انتخاب می‌شوند و دیگر مشکل انتخاب نرون‌ها را نخواهیم داشت. در تست نمونه انجام شده تعداد نرون‌ها از 100 عدد اولیه به 7 رسیده است و این خیلی نزدیک به آن چیزی است که ما بصورت سعی و خطا بدست آورده بودیم. با حذف هر نرون از فرآیند آموزش وزنه‌های مرتبط با آن در لایه‌های بعدی دیگر آموزش پیدا نمی‌کنند و مقدار آنها ثابت شده و از فرآیند پیش رو و پس رو شبکه خارج می‌شوند این کار را



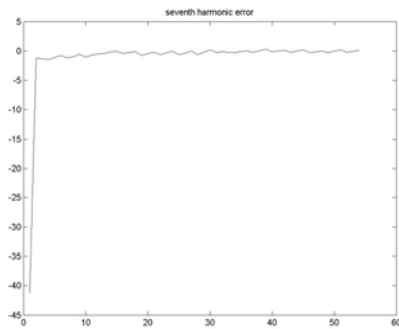
شکل (۸): خروجی شبکه انعطاف پذیر.




هارمونیک سوم



هارمونیک اول



هارمونیک هفتم



هارمونیک پنجم

شکل (۹): تغییرات خطای خام شبکه انعطاف پذیر

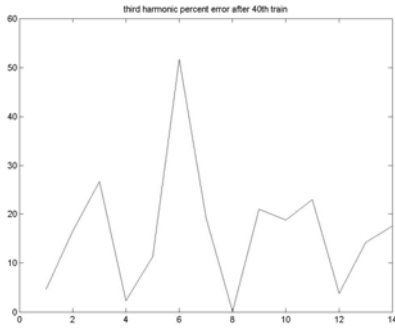
مختلف کاری به دست آورد و نیاز به اجرای الگوریتم CFE-SS برای به دست آوردن هارمونیکهای جریان در نقاط مختلف کاری نمی‌باشد. همچنین باید گفت که علت اصلی روی آوردن به شبکه عصبی برای به دست آوردن پارامترهای ژنراتور و یا هر ماشین دیگر نیز زمانبر بودن الگوریتمهایی مثل CFE-SS و ... بوده است. از آنجا که در کاربرد موردنظر ما که تشخیص خطا 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 انعطاف پذیر ساختار متغیر بوده است. برای مقایسه دقیقتر این دو روش و اثبات نظراتمان در مورد شبکه‌های عصبی انعطاف پذیر حداکثر خطای این شبکه‌ها را برای هارمونیکهای مختلف در جدول (۴) فهرست کرده‌ایم. مشاهده می‌شود که همانطور که انتظار داشتیم شبکه عصبی انعطاف پذیر ساختار متغیر خیلی بهتر عمل نموده و خطا 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 اغتشاشات است که خود گامی مهم جهت استفاده از شبکه‌های عصبی با ساختار بهینه می‌باشد.

همانطور که ملاحظه می‌گردد در بدترین حالت میزان خطای شبکه طراحی شده برای هارمونیک اول به میزان $0.8/44\%$ برای هارمونیک سوم به میزان $0.73/51\%$ برای هارمونیک پنجم به میزان $0.48/41\%$ و برای هارمونیک هفتم به میزان $0.82/25\%$ بوده است. ساختار شبکه باز مطابق شکل (۴) می‌باشد که در آن در طول فرآیند آموزش n^1 دائماً در حال تغییر است. شبکه مورد نظر از نوع پرسپترون انعطاف پذیر و با قانون یادگیری پس انشار خطا برای آموزش پارامترها و وزنهای می‌باشد. همچنین تابع هدف برای اصلاح وزنهای شبکه نیز همچون قبل حداقل کردن مجموع مربعات خطای مابین خروجی مطلوب و خروجی شبکه عصبی می‌باشد.

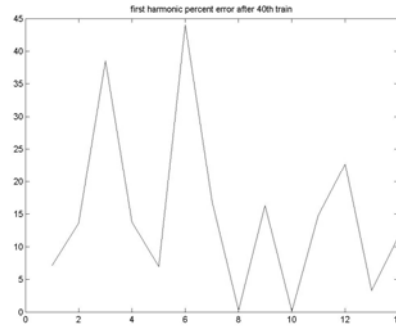
در شکل (۱۱) تغییرات تعداد نرونها را در مراحل مختلف آموزش مشاهده خواهید کرد. همانطور که مشاهده می‌گردد تعداد نرونها از ۱۰۰ عدد به ۷ عدد کاهش یافته است.

۴ - نتیجه گیری


همانطور که ملاحظه گردید، بعد از اینکه شبکه با استفاده از نتایج نقاط کار و در نظر گرفته شده از منحنی بهره برداری ژنراتور با یک لایه میانی و با قانون یادگیری پس انتشار خطا 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 از هارمونیکهای جریان در حالت بدون خطا برای نقاط




هارمونیک سوم



هارمونیک اول

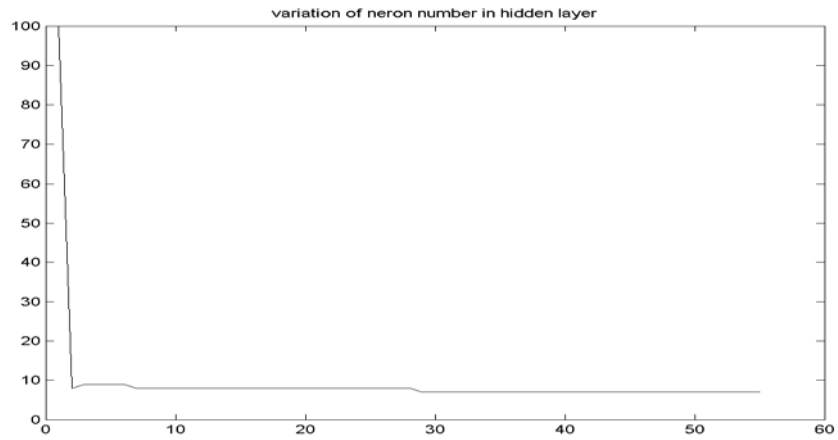


هارمونیک هفتم



هارمونیک پنجم

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



شکل (۱۱): تغییرات تعداد نرونها در طول آموزش.

جدول (۴): حداکثر خطای هر دو شبکه در هر هارمونیک.

هارمونیک هفتم	هارمونیک پنجم	هارمونیک سوم	هارمونیک اول	هارمونیکها
%۴۰/۰۸	%۶۳/۳۳	%۵۳/۰۵	%۴۵	شبکه عصبی معمولی
%۲۵/۸۲	%۵۱/۷۳	%۴۴/۰۸	%۴۱/۴۸	شبکه عصبی انعطاف پذیر

مراجع

- [۱] سودابه سلیمانی ، علیمحمد رنجبر ، حسام میر عابدینی ، "استفاده از شبکه‌های عصبی انعطاف پذیر در تخمین هارمونیک‌های جریان استاتور ژنراتور آسک نیروگاه ری بر اساس الگوریتم CFS/SS" ، نشریه علمی برق ، شماره ۳۱ ، صفحه ۲۸-۳۵ ، بهار ۱۳۸۰ .
- [2] S.R.Chaudhry, N.A.Demerdash,"An artificial-neural-network method for the identification of saturated turbo generator parameters based on coupled finite-element/state-space computational algorithm",IEEE transactions on Energy Conversation, Vol. 10,No. 4,December 1995.
- [3] M.Teshnehlab, 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. Syposium 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 Jurnal, 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 Intelligent & Robotics Systems, 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 transactions on energy conversation, Vol.10, No.1, March 1995.
- [۹] الهام خسرو شاهی ، علیمحمد رنجبر ، حسام میر عابدینی ، " تشخیص خطای ژنراتور سنکرون در حین کار با استفاده از تحلیل هارمونیک‌های جریان استاتور" ، نشریه علمی برق ، شماره ۳۱ ، صفحه ۴۱-۳۶ ، بهار ۱۳۸۰ .
- [۱۰] علیمحمد رنجبر ، ثنوری جامع ماشین سنکرون ، دانشگاه صنعتی شریف ، ۱۳۷۳ .
- [۱۱] محمد باقر منهج ، مبانی شبکه های عصبی ، دانشگاه صنعتی امیر کبیر ، واحد تفرش ، مرکز نشر پروفسور حسابی .
- [۱۲] مرتضی سقائیان نژاد ، حسن نیک خواجویی ، تحلیل ماشینهای الکتریکی ، دانشگاه صنعتی اصفهان ، ۱۳۷۶ .

رزومه



محمد رضا یوسفی نجف آبادی در سال ۱۳۵۹ در شهر نجف آباد متولد شد. ایشان فارغ التحصیل کارشناسی مهندسی برق قدرت از دانشگاه آزاد اسلامی واحد نجف آباد و مقطع کارشناسی ارشد بیوالکتریک از دانشگاه صنعتی خواجه نصیرالدین طوسی می‌باشد. از ایشان تا کنون 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 تشنه 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.