

ارزیابی پایداری سیستمهای قدرت به روش تخمین زاویه و سرعت روتور ژنراتور سنکرون و با استفاده از شبکه های عصبی

امیر صباغ الوانی	اصغر جعفرزاده	بهزاد کیوانی
دانشگاه تربیت معلم آذربایجان - تبریز	دانشگاه صنعتی مالک اشتر-تهران	دانشگاه صنعتی مالک اشتر-تهران
دانشکده فنی - گروه مهندسی برق	مجتمع دانشگاهی برق و الکترونیک	مجتمع دانشگاهی برق و الکترونیک
amir_7960@yahoo.com	as_jafarzadeh@yahoo.com	behzad_keivani@yahoo.com

چکیده: بهره برداری بهینه از سیستمهای قدرت مستلزم آن است که عملکرد سیستم همواره در نزدیکی محدوده پایداری دینامیک آن ثابت بماند. سرعت و زاویه ژنراتور سنکرون مهمترین فاکتورهای مرجع در ارزیابی و کنترل دینامیک یک سیستم قدرت می باشند. در این مقاله روش بدست آوردن سرعت و زاویه روتور ژنراتور سنکرون با استفاده از اندازه گیری فازور مورد بررسی قرار گرفته و کاربرد شبکه های عصبی مصنوعی در محاسبه سریعتر و دقیق تر پارامترهای فوق تشریح می شود و در پایان کارآیی روش پیشنهاد شده با استفاده از نتایج حاصل از شبیه سازی ارزیابی می گردد.

کلمات کلیدی: سیستمهای قدرت، پایداری دینامیکی، اندازه گیری فازور، شبکه های عصبی مصنوعی

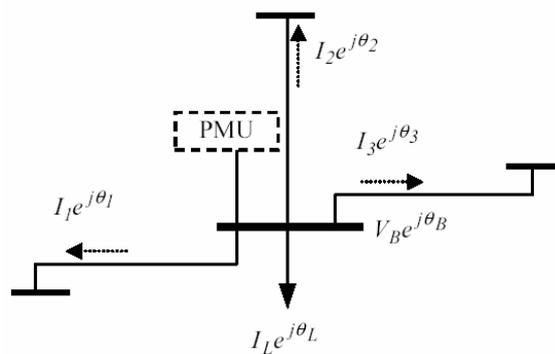
۱-مقدمه: ارزیابی قابلیت اطمینان سیستمهای قدرت شامل برآورد توانایی سیستم در مقابله با اختلالات مختلف و پیشنهاد راهکارهای مناسب برای مقابله با ضعفهای عمده سیستم در مواقع بروز عیب می باشد. متداولترین روش برای بررسی پایداری و اتخاذ روش مناسب برای کنترل سیستم در حالتی گذرا محاسبه زاویه و سرعت روتور ژنراتور سنکرون با استفاده از اندازه گیری فازور است. از جمله مزایای عمده این روش می توان به موارد زیر اشاره کرد:

- بدست آوردن حالت سیستم پس از وقوع عیبهای گذرا و انتخاب روشهای مناسب برای کنترل سیستم
- پیش بینی میزان گسترش حالتی گذرا
- عملکرد سریعتر و مناسبتر سیستم حفاظتی

در قسمتهای بعد ضمن آشنایی با طرز کار تجهیزات اندازه گیری فازور، کاربرد شبکه های عصبی مصنوعی در محاسبه زاویه و سرعت روتور ژنراتور سنکرون مورد بررسی قرار گرفته و با مطالعه نتایج حاصل از شبیه سازی کارآیی روش پیشنهادی ارزیابی می شود.

۲- تخمین سرعت و زاویه روتور با استفاده از اندازه گیری فازور

PMU ها (Phasor Measurement Units) تجهیزاتی هستند که برای اندازه گیری بلادرنگ (Real-Time) فازورهای ولتاژ شین و جریان خطوط (به منظور کاربردهای مختلف نظیر مونیوتورینگ، کنترل، حفاظت و تخمین حالت سیستم) به کار می روند. در شکل ۱ دیاگرام شماتیک یک سیستم قدرت شامل PMU مشخص شده است. PMU های موجود در سیستم برای اندازه گیری دامنه و زاویه فاز ولتاژ شین (V_B, θ_B) و جریانهای تزریقی خطوط ($I_1, I_2, I_3, I_L, \theta_1, \theta_2, \theta_3, \theta_L$) به کار می روند.



شکل (۱)

ساده ترین روش برای محاسبه زاویه روتور از طریق اندازه گیری فازور استفاده از مدل کلاسیک ژنراتور و ارتباط بین فازورها و راکتانسهای ژنراتور و ترانسفورماتورهای Step-up می باشد [۱].

$$E' \angle \delta = V_t \angle \theta_{tV} - jX'I_t \angle \theta_{tI} \quad (1)$$

در رابطه فوق E' ولتاژ ثابت، V_t ولتاژ ترمینال ژنراتور، X' راکتانس گذرا و I_t جریان ترمینال ژنراتور می باشد. در صورتیکه زاویه روتور در لحظات زمانی مختلف محاسبه شود، سرعت روتور با استفاده از رابطه زیر قابل محاسبه خواهد بود:

$$\omega(t) = \frac{\delta(t+1) - \delta(t)}{\Delta t} \quad (2)$$

استفاده از روابط فوق هنگامیکه فازورهای ولتاژ و جریان ژنراتور در دسترس باشد، امکانپذیر خواهد بود. در برخی موارد امکان اندازه گیری مستقیم ولتاژ و جریان ژنراتور وجود ندارد. در اینگونه موارد برای بدست آوردن رابطه بین ولتاژ اندازه گیری شده توسط PMU و ولتاژها و جریانهای داخلی ژنراتور، لازم است ماتریس ادمیتانس کاهش یافته سیستم محاسبه و معادلات حاکم بر سیستم حل شوند.

$$\begin{bmatrix} I_g \\ 0 \end{bmatrix} = \begin{bmatrix} Y_{11} & Y_{12} \\ Y_{21} & Y_{22} \end{bmatrix} \begin{bmatrix} V_g \\ V_m \end{bmatrix} \quad (3)$$

در این رابطه V_m ولتاژ اندازه گیری شده، V_g و I_g ولتاژ و جریان داخلی ژنراتور می باشد. اگر رابطه فوق را ساده کنیم خواهیم داشت:

$$Y_{21}V_g + Y_{22}V_m = 0 \Rightarrow V_m = -Y_{22}^{-1}Y_{21}V_g + \varepsilon \quad (4)$$

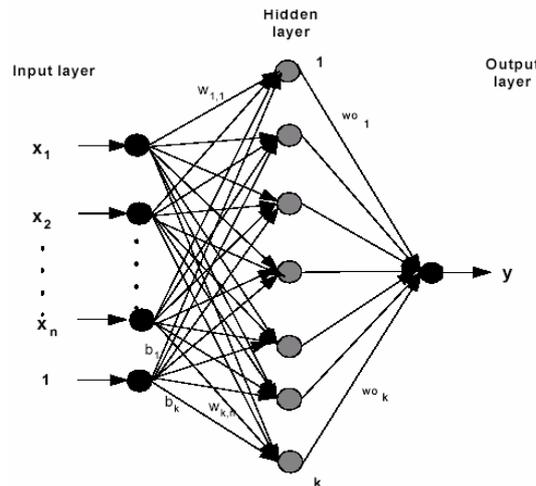
استفاده از روابط فوق مستلزم داشتن اطلاعات کافی از مقادیر قبلی پارامترهای سیستم، وضعیت کلیدهای قدرت و توپولوژی سیستم می باشد (ماتریس تلاقی برای تشکیل ماتریس ادمیتانس لازم است). با توجه به این موضوع که زاویه و سرعت روتور متغیرهای مکانیکی بوده و تغییرات کندتری نسبت به مقادیر اندازه گیری شده توسط PMU ها (که متغیرهای الکتریکی هستند) خواهند داشت، برای جلوگیری از وقوع ناپیوستگی در حالت‌های گذرا بهتر است PMU ها حتی الامکان در شینه های EHV نصب شوند. (در سیستم مورد مطالعه در این مقاله PMU ها در سمت EHV ترانسفورماتور Step-up نصب می شوند). دلیل دیگر برای اینکار این است که اندازه گیری مستقیم حالت‌های انتخاب شده بایستی سریعتر از استخراج حالت‌های مشابه بوسیله تخمین گر های حالت سیستم باشد. زاویه روتور تابعی غیرخطی از متغیرهای ترمینال ژنراتور بوده و برای استفاده در طرح تشخیص الگو، متغیرهای ورودی (پارامترهای اندازه گیری شده توسط PMU) توسط رابطه زیر به زاویه روتور نگاشت می شود:

$$f : \{u_k\} \in R^n \rightarrow \{\delta_k\} \in R^1 \quad (5)$$

در رابطه فوق $\{u_k\} = \{V_k(t), I_k(t), V_k(t-1), I_k(t-1), \theta_{vk}(t), \dots\}$ می باشد و n تعداد متغیرهای ورودی می باشد. برای نگاشت متغیرهای ورودی به زاویه روتور از یک شبکه عصبی چند لایه feed forward استفاده می شود.

۳- شبکه های عصبی مصنوعی [۲]

یک شبکه عصبی با ساختار، الگوریتم آموزش و توابع فعال سازی مربوط به خود مشخص می شود. ساختار شبکه عصبی نحوه اتصال بین نورونها را مشخص می سازد که شامل یک لایه ورودی، یک لایه خروجی و یک یا چند لایه پنهان می باشد. در شکل ۲ ساختار کلی یک شبکه عصبی نشان داده شده است (یک شبکه چند لایه از نوع feed forward با یک لایه پنهان). لایه ها در چنین شبکه ای بوسیله لینکهای ارتباطی که با بردارهای وزن در ارتباطند، بهم متصل می شوند. بردارهای وزن بوسیله الگوریتم آموزش تعیین می شوند.



خروجی گره j در لایه پنهان با رابطه زیر مشخص می شود:

$$h_j = g \left(\sum_{i=1}^n w_{ji} \cdot x_i + b_j \right) \quad (6)$$

و خروجی شبکه عصبی با رابطه زیر بیان می شود:

$$y = \sum_{i=1}^k (w_{oi} \cdot h_i) \quad (7)$$

در این رابطه w_{ji} وزن برداری است که ورودی را به گره j در لایه مخفی متصل می کند. b_j بایاس گره و w_{oi} وزن برداری است که لایه مخفی را به لایه خروجی متصل می سازد. شبکه های عصبی از نظر نوع الگوریتم آموزش به انواع زیر تقسیم می شوند:

شبکه های عصبی با وزن ثابت: این نوع از شبکه های عصبی به هیچ نوع آموزش نیاز ندارند
شبکه های عصبی Unsupervised: این شبکه ها تنها براساس داده های ورودی آموزش داده می شوند و آموزش شبکه با استفاده از مشاهده و تجارب حال از ورودی های قبلی تطبیق داده می شود.

شبکه های عصبی Supervised: این نوع از شبکه ها معمولترین نوع شبکه های عصبی می باشند و برای آموزش آنها از داده های ورودی و خروجی استفاده می شود. وزنها و بایاسها براساس هر مجموعه از داده های ورودی و خروجی تطبیق داده می شوند. شبکه عصبی پرسپترون چند لایه نمونه ای از این نوع شبکه های عصبی می باشد.

شبکه های عصبی Supervised و دارای الگوریتم یادگیری نوع پس انتشار خطا (Back-Propagation) مزایای زیادی نسبت به سایر روشهای محاسباتی متداول دارند که از آن جمله می توان به مقاوم بودن نسبت به نویزهای ورودی و سیستم، آموزش از طریق مثال، قابلیت حافظه و عملکرد بلادرنگ آنها اشاره کرد.

تابع فعال سازی ورودی و خروجی نرون را با توجه به سطح فعالیت آن به هم ارتباط می دهد. برخی از توابع فعال سازی معمول عبارتند از: تابع سطح آستانه (Threshold)، تابع خطی Piece-wise، زیگموئید (Sigmoid)، تانژانت هیپربولیک و تابع گوسی (Gaussian). پروسه آموزش شبکه MLP (پرسپترون چند لایه) شامل استفاده از داده های ورودی - خروجی برای تعیین وزن و بایاس می باشد. یکی از روشهای بدست آوردن این پارامترها الگوریتم پس انتشار خطا (B.P) می باشد. در این روش وزن و بایاس بطور مکرر تعدیل می شوند تا کمترین خطای مجذور متوسط بین خروجی شبکه و مقدار مطلوب بدست آید. شبکه های MLP بیشترین کاربرد را در زمینه تشخیص الگو، کنترل و طبقه بندی دارند. بطور معمول الگوریتم آموزش شامل مراحل زیر می باشد:

مرحله اول: انتخاب ورودی که اولین گام در حل مساله تشخیص الگو بوده و تاثیر مستقیم در کارایی و اندازه شبکه عصبی دارد.

مرحله دوم: جمع آوری داده های آموزشی روشن و قطعی

مرحله سوم: انتخاب شبکه عصبی شامل انتخاب اندازه، تعداد ورودی و نرونهای پنهان ولایه های پنهان

مرحله چهارم: آموزش شبکه عصبی

مرحله پنجم: تست شبکه

برای اجرای این الگوریتم دو روش متفاوت وجود دارد. در روش اول وزن و بایاس پس از هر بار اعمال ورودی به شبکه Update می شود و در روش دوم وزن و بایاس شبکه پس از آموزش نهایی Update می شود. در این مقاله از روش دوم استفاده می شود.

۴- طراحی شبکه عصبی برای تخمین سرعت و زاویه روتور ژنراتور سنکرون

برای تخمین زاویه و سرعت روتور از دو شبکه عصبی جداگانه استفاده می شود، یکی برای تخمین زاویه روتور (ANN1) و دیگری برای تخمین سرعت روتور (ANN2). (شکل ۳)

۴-۱ انتخاب ورودی [۳]

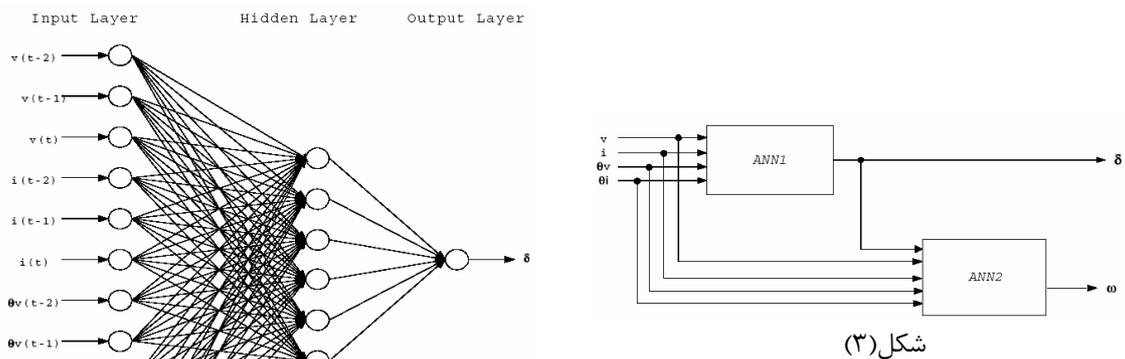
ورودی شبکه اول ولتاژ و جریان و زوایای مربوط به آنها در شینه EHV می باشد که در لحظات زمانی t ، $t-1$ و $t-2$ اندازه گرفته شده اند می باشد (مجموعاً ۱۲ ورودی). خروجی این شبکه زاویه روتور به ازای یک وضعیت عملکرد خاص خواهد بود.

$$\delta(t) = f \left\{ \begin{matrix} v(t), v(t-1), v(t-2), i(t), i(t-1), i(t-2), \theta_v(t), \\ \theta_v(t-1), \theta_v(t-2), \theta_i(t), \theta_i(t-1), \theta_i(t-2) \end{matrix} \right\} \quad (8)$$

برای ورودی شبکه دوم علاوه بر ورودی های شبکه اول، خروجی بدست آمده از شبکه اول در لحظات t ، $t-1$ و $t-2$ نیز در نظر گرفته می شود (مجموعاً ۱۵ ورودی). خروجی این شبکه شامل یک نرون است که سرعت روتور را نشان می دهد.

۴-۲ انتخاب شبکه عصبی [۴]

شبکه عصبی مورد نظر از نوع چند لایه feed forward می باشد که شامل یک لایه پنهان می باشد. این شبکه در شکل ۴ نشان داده شده است. تعداد لایه های پنهان بطور تجربی و با مطالعه رفتار شبکه در حین پروسه آموزش و با در نظر گرفتن چند فاکتور مهم مانند سرعت همگرایی، ضریب خطا و دقت مورد نیاز انتخاب می شود. تعداد واحدهای لایه پنهان برای شبکه اول ۴۰ و برای شبکه دوم ۳۵ انتخاب می شود. برای این واحدها از تابع فعال سازی تانژانت هیپربولیک و برای نورونهای خروجی از تابع خطی استفاده می شود. شبکه بصورت offline آموزش داده می شود.

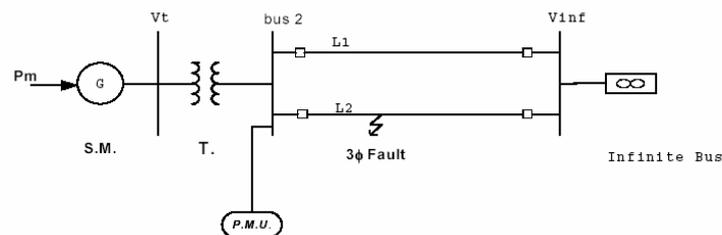


شکل (۳)

شکل (۴)

۵- نتایج حاصل از شبیه سازی

در شکل ۵ آرایش یک سیستم قدرت ساده متشکل از یک ماشین که به شین بی نهایت متصل است مشخص شده است. ژنراتور سنکرون از طریق دو خط انتقال موازی به شین بی نهایت متصل می باشد. این سیستم ساده برای تحلیل پایداری حالت گذرا مناسب است.



شکل (۵)

۱-۵ شبیه سازی مراحل آموزش و تست شبکه عصبی

برای شبیه سازی شبکه عصبی پیشنهاد شده از جعبه ابزار شبکه های عصبی در نرم افزار SIMULINK استفاده شده است. الگوریتم آموزش بکاررفته، الگوریتم Leven berg-Marguard می باشد که دارای همگرایی سریعی است. بایاس و وزن اولیه بطور تصادفی در بازه $[-1, 1]$ انتخاب شده و ورودی و مقادیر مطلوب طوری نرمالیزه می شوند که مقادیری بین 1,1- داشته باشند. در مرحله آموزش پاسخ سیستم به عیب اتصال کوتاه سه فاز در ابتدا و انتهای خط و در دو حالت self-clearing و رفع عیب با قطع خط معیوب به عنوان مجموعه یادگیری در نظر گرفته شده است. این دو حالت به ازای زمان عیبی برابر ۰/۱ ثانیه و به ازای توانهای تولیدی مختلف بررسی شده اند و در مجموع ۱۸۰ الگو برای آموزش در نظر گرفته شده است که هر کدام از این الگوها بطور متوسط شامل ۸۰ جفت ورودی-خروجی می باشند (مجموعاً ۱۴۴۰۰ جفت ورودی-خروجی). برای تست شبکه عصبی نیز ۶۰ الگو مورد استفاده قرار گرفته است. تولید داده های آموزش بطور خلاصه در جدول ۱ آورده شده است. برای هر نوع اتصال کوتاه و توان تولیدی ۹ الگو با مدت دوام عیبی که از بازه های $[0.05, CCT-1]$ ، $[CCT-1, CCT+0.01]$ و $[CCT+0.01, 0.35]$ انتخاب می شود، نیز به عنوان الگوهای آموزش انتخاب می شود. (CCT زمان رفع عیب بحرانی یا Critical Clearing Time می باشد) همچنین در مرحله تست نیز ۳ الگو با زمان دوام عیبی که از بازه های فوق انتخاب می شود (به شرط اینکه در مرحله آموزش انتخاب نشده باشد)، به عنوان الگوهای تست به کار گرفته شده اند. تاثیرات نویز در پاسخ سیستم نیز بوسیله ایجاد اختلالات تصادفی در ورودی ها در شبکه عصبی در نظر گرفته شده است.

توان تولیدی (MW)	آموزش				تست			
	Self-clearing		قطع خط معیوب		Self-clearing		قطع خط معیوب	
	ابتدای خط L2	انتهای خط L2	ابتدای خط L2	انتهای خط L2	ابتدای خط L2	انتهای خط L2	ابتدای خط L2	انتهای خط L2
1100	9	9	9	9	3	3	3	3
850	9	9	9	9	3	3	3	3
600	9	9	9	9	3	3	3	3
500	9	9	9	9	3	3	3	3
300	9	9	9	9	3	3	3	3

جدول (۱)

۲-۵ نتایج

برای ارزیابی کارایی سیستم پیشنهاد شده، سیستم قدرت مفروض با استفاده از مدل جزئی مرتبه هفتم و مدل کلاسیک ژنراتور و توسط جعبه ابزار POWER SYSTEM نرم افزار سیمولینک شبیه سازی می شود. بازه زمانی نمونه برداری در این شبیه سازی برابر با ۲۰ میلی ثانیه در نظر گرفته شده است.

به عنوان معیاری برای سنجش کارایی، خطای ریشه مجذور متوسط به صورت زیر تعریف می شود: [۵]

$$RMSE = \sqrt{\frac{1}{p} \sum_p (t_p - o_p)^2} \quad (9)$$

این معیار برای هر شبکه عصبی پس از ۱۰۰۰ بار تکرار قانون یادگیری محاسبه می شود. در این رابطه p تعداد جفت های ورودی-خروجی در مرحله آموزش، t_p مقدار مطلوب خروجی برای p امین یادگیری و o_p خروجی شبکه عصبی می باشد. در جدول ۲ مقدار $RMSE$ برای مراحل یادگیری و تست مشخص شده است (در معادله ۹ مقدار مطلوب خروجی با

مقادیر واقعی زاویه و سرعت و خروجی شبکه عصبی نیز با مقادیر بدست آمده از مدل کلاسیک ژنراتور جایگزین می شود. سپس این مقادیر در جدول ۳ با مقادیر خطا در شبیه سازی با استفاده از مدل کلاسیک ژنراتور مقایسه شده اند.

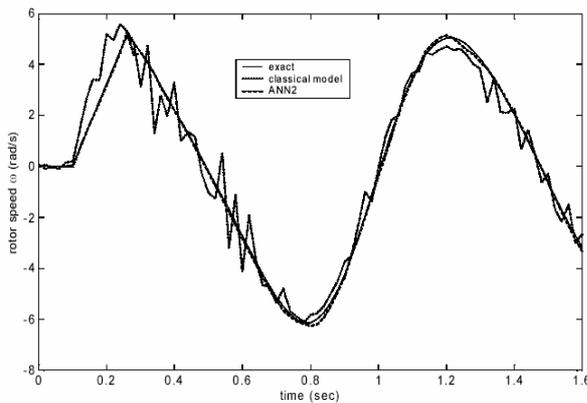
پس از ۱۰۰۰ بار تکرار		
	خطای آموزش	خطای تست
ANN1	0.0020(rad)	0.0092(rad)
ANN2	0.0004(rad/s)	0.0024(rad/s)

جدول (۲)

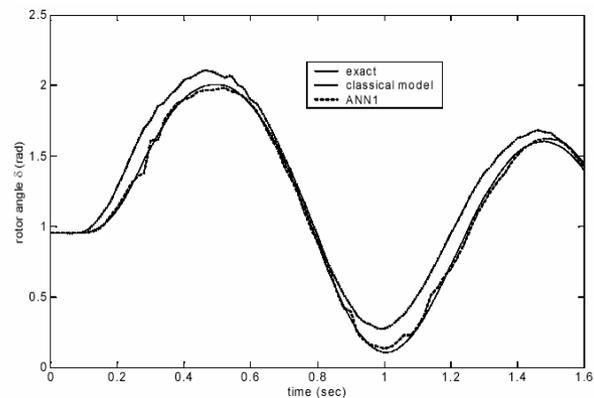
مدل کلاسیک ژنراتور			
	حالت پایدار	ناپایدار	پایدار بحرانی
خطای زاویه(رادیان)	0.1307	0.1607	0.1803
خطای سرعت(رادیان بر ثانیه)	0.6004	0.9567	0.698

جدول (۳)

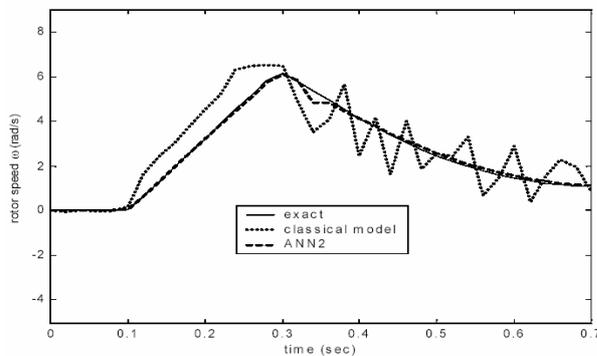
نتایج حاصل از شبیه سازی به ترتیب برای حالت‌های پایدار، ناپایدار و پایدار بحرانی در شکل‌های ۶ تا ۱۲ مشخص شده است. این نتایج برای وقوع عیب در ابتدای خط ۲ و در حالتی که عیب با باز کردن خط معیوب بر طرف می شود، بررسی شده اند برای این حالت مقدار CCT برابر ۰/۲۹۲ ثانیه خواهد بود(تاثیر نویز فقط در متغیرهای ورودی در نظر گرفته شده است).



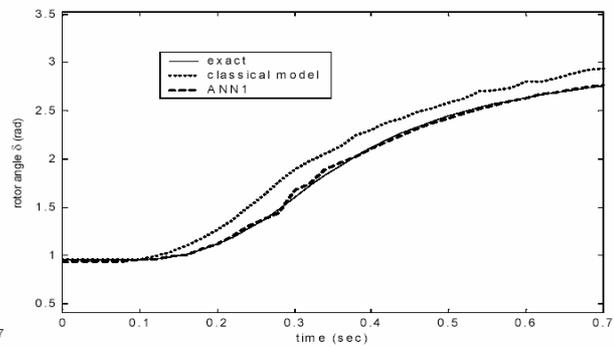
شکل (۷): سرعت روتور(حالت پایدار)



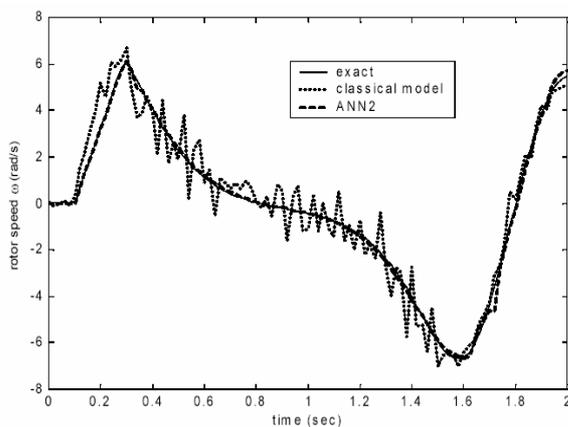
شکل (۸): زاویه روتور(حالت پایدار)



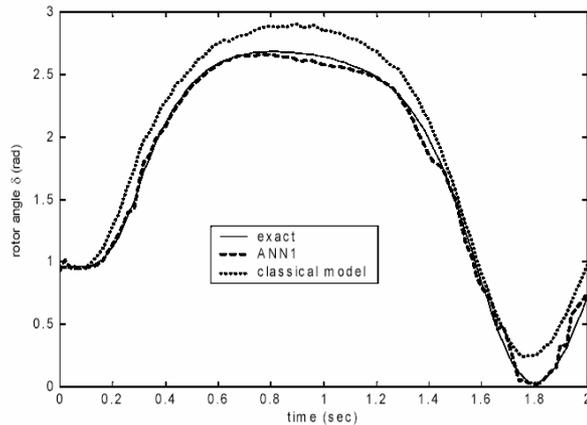
شکل (۹): سرعت روتور(حالت ناپایدار)



شکل (۱۰): زاویه روتور(حالت ناپایدار)



شکل (۱۰): سرعت روتور (حالت پایدار بحرانی)



شکل (۹): زاویه روتور (حالت پایدار بحرانی)

۶- نتیجه گیری:

با توجه به شکلها و جداول در قسمت ۵ می توان دریافت که تخمین زاویه روتور با روش پیشنهادی تطبیق بهتری با مقادیر واقعی، نسبت به محاسبه زاویه با استفاده از مدل کلاسیک ژنراتور دارد. وجود نویز در متغیرهای ورودی باعث اعوجاج اندکی در منحنی زاویه روتور شده است (در مورد مقدار محاسبه شده با رابطه ۱). این اعوجاج کم و بیش در مورد سرعت روتور نیز قابل مشاهده است. اما در مورد زاویه و سرعت محاسبه شده با استفاده از شبکه های عصبی این اعوجاج بسیار کمتر است. در مورد میزان خطا نیز جداول ۲ و ۳ نشان دهنده کارایی و دقت بیشتر شبکه های عصبی است. اگر سطح دقت در ارزیابی و کنترل پایداری گذرا بالا باشد استفاده از مدل کلاسیک و معادلات ۱ و ۲ باعث بروز خطا و پیش بینی های نادرست و بکارگیری استراتژی های نامناسب در کنترل سیستم قدرت خواهد شد. اگرچه سیستم تحلیل شده در این مقاله در مقایسه با سیستمهای واقعی از پیچیدگی کمتری برخوردار است ولی با توجه به نتایج حاصله می توان در مورد سیستمهای واقعی نیز با اطمینان کافی، روش پیشنهاد شده را بکار برد.

۷- مراجع:

- [1] L. Wehenkel, Automatic Learning Techniques in power Systems, Kluwer Academic Publishers, 1998
- [2] S. Haykin, Neural Networks a Comprehensive Foundation, IEEE Press, New York, 1994
- [3] A. G. Phadke, "Synchronized Phasor Measurement in Power Systems", IEEE computer Application in power, Vol.6, No.2, pp.10-15, 1993
- [4] C.H.Liu, M.Ch.Su, "Application of a Novel Fuzzy Neural network to Real-Time transient Stability Swings Prediction Based on synchronized Phasor Measurement", IEEE Transaction on Power Systems, Vol.14, No.2, pp.685-692, 1999
- [5] E.De Tuglio, M. Dicorato, "A Corrective Control for Angle and Voltage Stability Enhancement on the Transient Time-Scale", IEEE Transaction on Power Systems, Vol.15, No.4, pp.1345-1353, 2000