

کنترل هماهنگ توان و بار در نیروگاه‌های سیکل ترکیبی با استفاده از یادگیری تقویتی

*محمد دهقان کفشگری،^۱ اسید محمود مدرسی

۱- دانشجوی دکتری تخصصی مهندسی برق کنترل دانشگاه آزاد واحد تهران جنوب

m_dehghan_s@yahoo.com

۲- استادیار دانشگاه آزاد واحد تهران جنوب modaresi@iaau.ac.ir

خلاصه

نیروگاه‌های سیکل ترکیبی یکی از منابع اصلی تولید برق در بسیاری از کشورها هستند که شامل واحدهای گازی و بخاری می‌باشند. این نیروگاه‌ها به دلیل ویژگی‌های دینامیکی متفاوت این دو نوع واحد، مشکلاتی در هماهنگی و کنترل توان و بار در شرایط متغیر بار شبکه دارند. این پروژه به منظور حل مشکل کنترل توان و بار به صورت هماهنگ بین واحدهای گازی و بخاری در نیروگاه‌های سیکل ترکیبی، از یادگیری تقویتی (Reinforcement Learning) بهره می‌برد. هدف این تحقیق طراحی یک مدل یادگیری تقویتی است که بتواند به طور خودکار و پویا توان را بین این واحدها توزیع کرده و از نوسانات ولتاژ جلوگیری کند. در این پژوهش، یک محیط شبیه‌سازی شده برای نیروگاه‌های سیکل ترکیبی ایجاد شده و الگوریتم‌های یادگیری تقویتی، مانند Deep Q-Learning و Q-Network (DQN)، برای بهینه‌سازی کنترل بار و توان به کار گرفته می‌شوند. نتایج نشان می‌دهد که الگوریتم‌های یادگیری تقویتی قادر به بهبود هماهنگی تولید برق، کاهش نوسانات ولتاژ و افزایش پایداری شبکه هستند. در شبیه‌سازی که در محیط متلب انجام شد، نوسانات ولتاژ کاهش یافته و فرکانس را در برابر تغییرات ناگهانی بطور سریع به حالت پایدار برگرداند. این نشان می‌دهد که الگوریتم یادگیری تقویتی، به‌ویژه در شرایط دینامیکی و پیچیده، قادر است از نوسانات ناخواسته جلوگیری کند و عملکرد بهتری در حفظ پایداری شبکه ارائه دهد.

کلمات کلیدی: تولید برق، واحد گازی، تولید برق، هوش مصنوعی، الگوریتم یادگیری عمیق، واحد بخار

۱. مقدمه

نیروگاه‌های

سیکل ترکیبی یکی از پیشرفته‌ترین انواع نیروگاه‌ها هستند که در آن‌ها از ترکیب دو نوع واحد گازی و بخاری برای تولید برق استفاده می‌شود. این ترکیب نه تنها باعث بهبود بهره‌وری و کاهش مصرف سوخت نسبت به نیروگاه‌های سنتی می‌شود، بلکه امکان استفاده بهینه از منابع انرژی را در شرایط مختلف بار فراهم می‌آورد. در این نیروگاه‌ها، واحد گازی سریع‌تر به

تغییرات بار پاسخ می‌دهد و واحد بخاری به‌عنوان یک واحد پیوسته با پاسخ‌دهی دیرتر، در بارهای بالاتر و زمان‌های طولانی‌تر عمل می‌کند. به دلیل این تفاوت‌های دینامیکی، هماهنگ‌سازی توان تولیدی بین این دو واحد و مدیریت بار شبکه به یک چالش پیچیده تبدیل می‌شود.

۲. ارسال مقالات کامل (B Nazanin 12)

چالش‌های هماهنگ‌سازی واحدهای گازی و بخاری

در نیروگاه‌های سیکل ترکیبی، واحدهای گازی و بخاری باید به‌صورت هماهنگ با یکدیگر عمل کنند تا نه‌تنها توان تولیدی نیروگاه به‌درستی تنظیم شود، بلکه پایداری شبکه برق نیز حفظ گردد. این هماهنگی با چالش‌های متعددی مواجه است:

۱. تفاوت در زمان پاسخ‌دهی: واحد گازی به دلیل ساختار توربین‌های خود قادر است در پاسخ به تغییرات بار شبکه سریع عمل کند، در حالی که واحد بخاری به‌دلیل زمان راه‌اندازی طولانی‌تر و تأخیر در رسیدن به ظرفیت کامل، نمی‌تواند به‌سرعت بار را تنظیم کند.

۲. تأثیر تغییرات بار ناگهانی: در مواقعی که تغییرات بار ناگهانی رخ می‌دهد، تأمین توان و تثبیت ولتاژ شبکه در مواجهه با این تغییرات برای سیستم چالش‌برانگیز است. واحد گازی ممکن است قادر به پاسخگویی سریع باشد، اما به‌طور موقت قادر به پوشش کامل نیاز بار نیست. از طرفی، واحد بخاری به‌دلیل ویژگی‌های کندتر، می‌تواند مشکل ایجاد کند.

۳. موازنه بین کارایی و انعطاف‌پذیری: نیروگاه‌های سیکل ترکیبی معمولاً در حالت‌های مختلف بار و شرایط کاری عمل می‌کنند و در نتیجه باید به‌طور مداوم به شرایط متغیر بار پاسخ دهند. واحد گازی به دلیل سرعت بالای پاسخ‌دهی و کارایی بالا، گزینه مناسبی برای شرایط متغیر است، اما به‌طور کل، باید توان تولیدی از هر دو واحد به‌طور بهینه تنظیم شود.

اهمیت کنترل هماهنگ توان و بار

کنترل هماهنگ توان و بار بین این دو واحد گازی و بخاری می‌تواند تأثیر زیادی بر پایداری و بهره‌وری سیستم داشته باشد. اگر توان تولیدی واحدها به‌درستی تنظیم نشود، می‌تواند منجر به نوسانات ولتاژ، افت کارایی، و حتی خرابی تجهیزات و اختلالات در شبکه برق شود. به‌ویژه در شرایط تغییرات ناگهانی بار، نیاز به یک سیستم کنترل پیشرفته و هوشمند برای تنظیم توان واحدها به‌شکل سریع و بهینه به شدت احساس می‌شود.

راهکارهای سنتی در مدیریت توان

روش‌های سنتی برای مدیریت و هماهنگ‌سازی توان در نیروگاه‌های سیکل ترکیبی، اغلب مبتنی بر مدل‌های کنترل کلاسیک هستند. این مدل‌ها به‌طور معمول از کنترل‌کننده‌های PID (Proportional-Integral-Derivative) و دیگر الگوریتم‌های کنترلی خطی برای مدیریت توان استفاده می‌کنند. با این حال، این روش‌ها در مقابله با سیستم‌های پیچیده و غیرخطی به‌ویژه در مواجهه با بارهای غیرقابل پیش‌بینی و تغییرات سریع در شبکه برق، محدودیت‌هایی دارند. بنابراین،

به‌منظور افزایش کارایی و پایداری در این سیستم‌ها، نیاز به راهکارهایی است که قادر به یادگیری و تطبیق با شرایط محیطی و بار متغیر باشند.

یادگیری ماشین و یادگیری تقویتی در سیستم‌های انرژی

یکی از جدیدترین رویکردها در بهینه‌سازی مدیریت توان و بار، استفاده از روش‌های یادگیری ماشین (Machine Learning) و به‌ویژه یادگیری تقویتی (Reinforcement Learning) است. یادگیری تقویتی به‌طور خاص می‌تواند در تنظیمات پیچیده، جایی که بازخورد محیطی و تصمیم‌گیری در زمان واقعی ضروری است، عملکرد بهتری نسبت به روش‌های کلاسیک ارائه دهد.

یادگیری تقویتی به ماشین‌ها این امکان را می‌دهد که با تعامل با محیط، سیاست‌هایی بیاموزند که منجر به بیشترین پاداش یا کمترین هزینه در یک سری اعمال شود. در زمینه نیروگاه‌های سیکل ترکیبی، این به معنای توانایی یادگیری سیاست‌های بهینه برای تنظیم توان تولیدی از واحدهای گازی و بخاری است، به‌طوری‌که نه‌تنها پایداری شبکه حفظ شود بلکه زمان پاسخ‌دهی به تغییرات بار نیز کاهش یابد.

اهمیت یادگیری تقویتی در بهینه‌سازی کنترل توان

یادگیری تقویتی از آنجا که به ماشین این امکان را می‌دهد که با تجربیات خود و درک تعاملات محیطی بهترین سیاست‌ها را پیدا کند، می‌تواند در حل مشکلات پیچیده‌ای مانند هماهنگ‌سازی توان و بار در نیروگاه‌های سیکل ترکیبی، که نیاز به تصمیم‌گیری‌های غیرخطی و دنباله‌ای دارند، بسیار مؤثر باشد. با استفاده از الگوریتم‌های یادگیری تقویتی مانند Q-Learning و Deep Q-Networks (DQN)، این امکان فراهم می‌شود که سیستم به‌طور خودکار توان خروجی واحدهای گازی و بخاری را با توجه به شرایط مختلف بار و وضعیت شبکه برق بهینه‌سازی کند.

هدف تحقیق

هدف اصلی این تحقیق، توسعه و به‌کارگیری یک سیستم یادگیری تقویتی به‌منظور بهینه‌سازی هماهنگی بین واحدهای گازی و بخاری در نیروگاه‌های سیکل ترکیبی است. با استفاده از الگوریتم‌های Q-Learning و Deep Q-Network (DQN)، هدف ما کاهش نوسانات ولتاژ، افزایش سرعت پاسخ‌دهی به تغییرات بار، و بهبود پایداری شبکه برق است.

در این مقاله، ابتدا مدل شبیه‌سازی‌شده‌ای از نیروگاه سیکل ترکیبی ایجاد می‌شود که در آن دینامیک هر دو واحد گازی و بخاری شبیه‌سازی شده است. سپس الگوریتم‌های یادگیری تقویتی برای هماهنگ‌سازی توان تولیدی در شرایط مختلف بار به‌کار گرفته می‌شوند. نتایج به‌دست‌آمده از شبیه‌سازی‌ها به مقایسه عملکرد این الگوریتم‌ها با روش‌های سنتی پرداخته و تأثیر آن‌ها بر پایداری و کارایی سیستم بررسی می‌شود.

این پژوهش به ارزیابی این مدل می‌پردازد که استفاده از یادگیری تقویتی می‌تواند کنترل توان و بار را در نیروگاه‌های سیکل ترکیبی بهبود دهد و به‌طور مؤثری پایداری شبکه برق را حفظ کند. نتایج این تحقیق می‌تواند راه را برای پیاده‌سازی سیستم‌های کنترل هوشمند در نیروگاه‌های سیکل ترکیبی هموار سازد، به‌ویژه در شرایطی که نیاز به پاسخ‌دهی سریع به تغییرات بار و حفظ کیفیت انرژی در شبکه ضروری است.

روش تحقیق: این تحقیق به بررسی نحوه استفاده از یادگیری تقویتی (Reinforcement Learning) برای هماهنگ‌سازی توان و بار در نیروگاه‌های سیکل ترکیبی می‌پردازد. در ابتدا، یک مدل شبیه‌سازی از نیروگاه سیکل ترکیبی

طراحی می‌شود که شامل واحدهای گازی و بخاری است. سپس، الگوریتم‌های یادگیری تقویتی، مانند Q-Learning و Deep Q-Network (DQN)، برای بهینه‌سازی توان و بار بین این دو واحد پیاده‌سازی می‌شود.

۱. مدل شبیه‌سازی نیروگاه سیکل ترکیبی

برای شبیه‌سازی یک نیروگاه سیکل ترکیبی، به‌ویژه هماهنگ‌سازی توان و بار بین واحدهای گازی و بخاری، یک مدل ساده از دو واحد گازی و بخاری طراحی می‌شود. این مدل‌ها باید شامل دینامیک‌های سیستم و روابط عملکردی بین آن‌ها باشد.

1.1 مدل دینامیک واحد گازی

توان خروجی واحد گازی P_g به صورت تابعی از توان بار شبکه و توان قبلی واحد گازی است. این مدل به صورت خطی نوشته می‌شود:

$$(1 - P_g(t) \cdot g\beta + P_{load}(t) \cdot g\alpha = P_g(t))$$

که در آن:

- $P_g(t)$ توان خروجی واحد گازی در زمان t
- $P_{load}(t)$ توان بار شبکه در زمان t
- $g\alpha$ ضریب مربوط به واحد گازی که نشان‌دهنده تأثیر تغییرات بار شبکه بر توان واحد گازی است
- $g\beta$ ضریب که نشان‌دهنده تأثیر توان قبلی واحد گازی بر توان کنونی آن است

این مدل نشان می‌دهد که توان خروجی واحد گازی، علاوه بر بار شبکه، تحت تأثیر توان قبلی واحد گازی قرار می‌گیرد و به‌طور خطی به تغییرات بار واکنش نشان می‌دهد.

1.2 مدل دینامیک واحد بخاری

واحد بخاری توان خروجی P_b خود را با تأخیر نسبت به تغییرات بار شبکه تنظیم می‌کند. این مدل غیرخطی بوده و به صورت زیر نمایش داده می‌شود:

$$(1 - P_b(t) \cdot b\gamma + (P_{load}(t) - P_g(t)) \cdot b\alpha = P_b(t))$$

که در آن:

- $P_b(t)$ توان خروجی واحد بخاری در زمان t
- $b\alpha$ ضریب تأثیر بار شبکه بر توان واحد بخاری



γ ضریب تأثیر توان قبلی واحد بخاری بر توان کنونی آن

این مدل نشان می‌دهد که توان خروجی واحد بخاری وابسته به بار شبکه است و علاوه بر این، تأثیر توان قبلی خود را نیز دارد. واحد بخاری به دلیل ویژگی‌های کندتر، قادر به پاسخ‌دهی سریع به تغییرات بار نیست.

۲. الگوریتم‌های یادگیری تقویتی

برای کنترل توان و بار به‌طور هماهنگ، از الگوریتم‌های یادگیری تقویتی استفاده می‌شود. این الگوریتم‌ها به سیستم اجازه می‌دهند تا از طریق تعامل با محیط، بهترین سیاست‌ها را برای تنظیم توان بین واحدهای گازی و بخاری یاد بگیرد.

Q-Learning 2.1

الگوریتم Q-Learning یک الگوریتم یادگیری تقویتی است که از یک جدول Q برای یادگیری سیاست‌های بهینه استفاده می‌کند. این الگوریتم به‌طور خاص برای محیط‌هایی مناسب است که اندازه فضای حالت و عمل آن‌ها محدود باشد.

در این الگوریتم، سیاست به‌وسیله یک تابع ارزش Q که در آن مقدار ارزشی برای انجام عمل a در حالت s^t است، تعیین می‌شود. این تابع بر اساس فرمول بروزرسانی زیر به‌روز می‌شود:

$$\alpha \left(r_t + \gamma \cdot \max_a Q(s_{t+1}, a) - Q(s_t, a_t) \right) + Q(s_t, a_t) = Q(s_t, a_t)$$

که در آن:

- s^t حالت فعلی سیستم
- a^t عمل انتخاب‌شده
- r^t پاداش دریافتی برای عمل a^t
- γ فاکتور تخفیف
- α نرخ یادگیری

فرایند یادگیری از طریق تعامل با محیط و بروزرسانی جدول Q ادامه می‌یابد تا نهایتاً سیاست بهینه برای تخصیص توان بین واحدهای گازی و بخاری به دست آید.

2.2. Deep Q-Network (DQN)

الگوریتم Deep Q-Network یک نسخه پیشرفته‌تر از Q-Learning است که برای محیط‌های پیچیده‌تر با فضای حالت و عمل بزرگ‌تر استفاده می‌شود. در این الگوریتم، به‌جای استفاده از یک جدول Q ، از یک شبکه عصبی عمیق برای تخمین تابع Q استفاده می‌شود.

شبکه عصبی که در اینجا استفاده می‌شود، یک شبکه پیش‌خور (feedforward) است که ورودی آن شامل ویژگی‌های محیط (حالت‌ها) و خروجی آن مقادیر Q برای هر عمل است. فرایند آموزش شبکه عصبی مشابه Q-Learning است، با این تفاوت که به جای استفاده از جدول، مقادیر Q از طریق شبکه عصبی به‌روزرسانی می‌شود.

فرمول به‌روزرسانی برای DQN به شکل زیر است:

$$\alpha \left(r_t + \gamma \cdot \max_a Q_{\theta'}(s_{t+1}, a) - Q_{\theta}(s_t, a_t) \right) + Q_{\theta}(s_t, a_t) = Q_{\theta}(s_t, a_t)$$

در اینجا:

- θ پارامترهای شبکه عصبی

- θ' پارامترهای شبکه عصبی هدف

این الگوریتم به‌ویژه برای شرایط پیچیده‌تر و با فضای حالت بزرگ‌تر مناسب است، جایی که استفاده از جدول Q غیرممکن یا غیرعملی است.

۳. مدل پاداش و عملکرد سیستم

در هر دو الگوریتم Q-Learning و DQN، یک مدل پاداش برای سیستم تعریف می‌شود که میزان کیفیت عملکرد سیستم را ارزیابی می‌کند. پاداش سیستم باید به‌گونه‌ای طراحی شود که منجر به بهبود توزیع توان و کاهش نوسانات ولتاژ و فرکانس در شبکه شود. این پاداش می‌تواند بر اساس معیارهای زیر باشد:

- پایداری ولتاژ: میزان نوسانات ولتاژ در شبکه، که باید کمینه شود.
- پاسخ‌دهی به تغییرات بار: زمان پاسخ‌دهی سیستم به تغییرات بار شبکه.
- مصرف سوخت: میزان سوخت مصرفی توسط هر واحد که باید بهینه شود.

پاداش r^t می‌تواند به صورت ترکیبی از این معیارها محاسبه شود:

$$\text{FuelConsumption}(t) \cdot 3w - \text{ResponseTime}(t) \cdot 2w - \text{Stability}(t) \cdot 1w = r^t$$

که در آن $1w, 2w, 3w$ ضرایب وزن‌دهی به معیارهای مختلف هستند.

۴. شبیه‌سازی و ارزیابی مدل

برای ارزیابی عملکرد مدل‌های یادگیری تقویتی، شبیه‌سازی‌های مختلفی در شرایط بار متغیر و تغییرات سریع انجام می‌شود. این شبیه‌سازی‌ها به‌ویژه به ارزیابی توانایی الگوریتم‌ها در هماهنگ‌سازی توان و بار در شرایط بار ناگهانی و نوسانات ولتاژ و فرکانس می‌پردازند.

در این شبیه‌سازی‌ها، دو حالت برای شبکه بررسی می‌شود:

۱. حالت بار ثابت: جایی که بار شبکه ثابت است و سیستم باید توان تولیدی خود را برای حفظ پایداری تنظیم کند.

۲. حالت بار متغیر: جایی که بار شبکه به‌طور ناگهانی تغییر می‌کند و سیستم باید به سرعت واکنش نشان دهد.

یافته‌ها: در این بخش، به تحلیل نتایج به‌دست‌آمده از شبیه‌سازی سیستم کنترل توان و بار در نیروگاه‌های سیکل ترکیبی Deep Q-Learning و Q-Learning (مانند Reinforcement Learning) با استفاده از الگوریتم‌های یادگیری تقویتی پرداخته می‌شود. هدف از این بخش، ارزیابی کارایی مدل‌های پیشنهادی و مقایسه آن‌ها با روش‌های (DQN) Network سنتی کنترل توان است. یافته‌ها شامل تأثیر یادگیری تقویتی بر بهینه‌سازی توان تولیدی واحدهای گازی و بخاری در شرایط بار متغیر، پایداری ولتاژ و فرکانس شبکه و کارایی مصرف سوخت است.

۱- بهینه‌سازی توان تولیدی و کاهش نوسانات بار

یکی از نتایج کلیدی در این پروژه، بهبود هماهنگی و بهینه‌سازی توان تولیدی بین واحدهای گازی و بخاری در نیروگاه‌های سیکل ترکیبی است. در روش‌های سنتی، هماهنگ‌سازی توان در شرایط تغییرات بار ناگهانی معمولاً به چالش می‌خورد. اما استفاده از یادگیری تقویتی در این تحقیق به‌ویژه با استفاده از Q-Learning و DQN باعث بهبود قابل توجهی در توزیع توان میان دو واحد گازی و بخاری شد.

در شبیه‌سازی‌های انجام‌شده، در حالت بار متغیر (جایی که بار شبکه به‌طور ناگهانی تغییر می‌کند)، الگوریتم‌های یادگیری تقویتی توانستند به سرعت واکنش نشان دهند و توان تولیدی واحدهای گازی و بخاری را به‌طور بهینه تنظیم کنند. در این شبیه‌سازی‌ها، مشاهده شد که:

- واحد گازی سریع‌تر به تغییرات بار پاسخ داد و توان خود را برای جبران تغییرات سریع بار تنظیم کرد.
- واحد بخاری به‌طور پیوسته و با تأخیر به تغییرات بار واکنش نشان داد، اما با استفاده از یادگیری تقویتی، توانست تا حد زیادی زمان پاسخ‌دهی خود را کاهش دهد.

این نتایج نشان‌دهنده عملکرد بهتر سیستم در مقایسه با روش‌های سنتی مانند کنترل PID است که معمولاً به دلیل محدودیت‌های غیرخطی و تأخیر در پاسخ‌دهی در مواقع بار متغیر کارایی کمتری دارند. در حالت کنترل PID، مشاهده می‌شود که نوسانات توان واحد گازی و بخاری بیشتر است و زمان تنظیم توان بیشتر طول می‌کشد. در حالت یادگیری تقویتی، توان‌ها به سرعت تنظیم می‌شوند و نوسانات کمتری مشاهده می‌شود.

۲- پایداری ولتاژ و فرکانس شبکه

پایداری ولتاژ و فرکانس در شبکه‌های برق به‌ویژه در شرایط بار ناگهانی، یکی از چالش‌های اصلی در نیروگاه‌های سیکل ترکیبی است. در این تحقیق، مدل‌های یادگیری تقویتی (Q-Learning) و (DQN) به‌طور مؤثری بر پایداری ولتاژ و فرکانس شبکه تأثیر گذاشتند.

در شبیه‌سازی‌هایی که در آن بار به‌طور ناگهانی افزایش یافت، دو معیار پایداری ولتاژ و فرکانس شبکه مورد بررسی قرار گرفتند:

در روش‌های سنتی، نوسانات ولتاژ و فرکانس به‌ویژه در ابتدا از کنترل خارج می‌شدند و برای بازگشت به وضعیت پایدار، زمان زیادی نیاز بود.

در مقایسه با این روش‌ها، یادگیری تقویتی باعث شد که ولتاژ و فرکانس شبکه در کوتاه‌ترین زمان ممکن به حالت پایدار بازگردند.

فرمول‌های مربوط به پایداری ولتاژ و فرکانس برای ارزیابی پایداری ولتاژ و فرکانس، از معیارهایی مانند نوسانات ولتاژ

(V_{rms}) و نوسانات فرکانس (f_{rms}) استفاده می‌شود:

$$\sqrt{\int_0^T dt^2 (\text{nom} V(t) - V)^2} \int \frac{1}{T} = \text{rms} V$$

که در آن:

- $V(t)$ ولتاژ در زمان t
- $\text{nom} V$ ولتاژ نامی شبکه
- T زمان نمونه‌برداری

برای فرکانس نیز از فرمول مشابهی استفاده می‌شود:

$$\sqrt{\int_0^T dt^2 (\text{nom} f(t) - f)^2} \int \frac{1}{T} = \text{rms} f$$

که در آن:

- $f(t)$ فرکانس در زمان t
- $\text{nom} f$ فرکانس نامی شبکه

در شبیه‌سازی‌های انجام‌شده، الگوریتم‌های یادگیری تقویتی توانستند نوسانات ولتاژ و فرکانس را به‌طور قابل توجهی کاهش دهند.

۳. مقایسه نتایج با روش‌های سنتی

در نهایت، مقایسه نتایج حاصل از الگوریتم‌های یادگیری تقویتی (DQN و Q-Learning) با روش‌های سنتی، مانند کنترل PID، نشان‌دهنده مزایای واضح این روش‌ها در بهبود کارایی سیستم بود. نتایج شبیه‌سازی نشان داد که:

- یادگیری تقویتی توانست هماهنگی توان و بار را بهبود دهد و نوسانات ولتاژ و فرکانس را کاهش دهد.
- در شرایط بار متغیر، الگوریتم‌های یادگیری تقویتی عملکرد بهتری در مقایسه با روش PID داشتند، که خود نشان‌دهنده پتانسیل بالای این روش‌ها در بهینه‌سازی سیستم‌های پیچیده مانند نیروگاه‌های سیکل ترکیبی است.

بحث و نتیجه‌گیری

در این پژوهش، به بررسی استفاده از یادگیری تقویتی (Reinforcement Learning) برای کنترل هماهنگ توان و بار در نیروگاه‌های سیکل ترکیبی پرداخته شد. با استفاده از الگوریتم‌های یادگیری تقویتی مانند Deep Q-Learning و Q- Network (DQN)، بهینه‌سازی در پاسخ‌دهی سیستم به تغییرات بار شبکه، هماهنگ‌سازی توان تولیدی واحدهای گازی و بخاری، پایداری ولتاژ و فرکانس، و کاهش مصرف سوخت مورد بررسی قرار گرفت. نتایج به‌دست‌آمده از شبیه‌سازی‌ها نشان داد که استفاده از این الگوریتم‌ها در مقایسه با روش‌های سنتی مانند کنترل PID، مزایای قابل توجهی دارد.

۱. مقایسه با کارهای گذشته

در کارهای گذشته، به‌ویژه در زمینه کنترل نیروگاه‌های سیکل ترکیبی، از روش‌های کلاسیک و کنترل خطی مانند کنترل PID و مدل پیش‌بینی استفاده شده است. این روش‌ها، علی‌رغم سادگی و سرعت در پیاده‌سازی، در شرایط دینامیکی پیچیده، نوسانات بار و تغییرات ناگهانی در شبکه، قادر به تأمین عملکرد مطلوب نبوده‌اند. از طرفی، این روش‌ها به دلیل نیاز به مدل‌های دقیق ریاضی و فرضیات اولیه، به‌ویژه در مواقعی که سیستم تحت تأثیر اغتشاشات قرار دارد، کارایی کمتری دارند.

از جمله تحقیقات اخیر که به این موضوع پرداخته‌اند، می‌توان به استفاده از الگوریتم‌های بهینه‌سازی مانند الگوریتم‌های تکاملی و شبکه‌های عصبی اشاره کرد. این الگوریتم‌ها در برخی موارد توانسته‌اند کارایی را افزایش دهند، اما همچنان محدودیت‌هایی از جمله زمان محاسباتی طولانی و پیچیدگی در پیاده‌سازی وجود دارد. از جمله مطالعات مهم در این زمینه، تحقیقات مربوط به استفاده از الگوریتم‌های ژنتیک و شبکه‌های عصبی عمیق بوده است که به‌طور معمول در زمینه بهینه‌سازی سیستم‌های غیرخطی مورد استفاده قرار می‌گیرند.

یادگیری تقویتی (Reinforcement Learning) برخلاف روش‌های یادگیری نظارت‌شده، به‌ویژه در نیروگاه‌های سیکل ترکیبی که ویژگی‌های دینامیکی و غیرخطی دارند، مزایای قابل توجهی دارد. الگوریتم‌های یادگیری تقویتی به‌ویژه Q-Learning و DQN می‌توانند از طریق تعامل با محیط و یادگیری تجربی، خود را به شرایط مختلف وفق دهند و بدون نیاز به مدل‌سازی دقیق سیستم، بهینه‌ترین سیاست‌ها را بیاموزند.

مقایسه با کارهای گذشته نشان می‌دهد که:

- یادگیری تقویتی می‌تواند در شرایط بار متغیر و تغییرات سریع در شبکه، نسبت به روش‌های کلاسیک مانند PID یا کنترل پیش‌بینی مدل عملکرد بهتری داشته باشد.
- برخلاف روش‌های تکاملی یا شبکه‌های عصبی که نیاز به مجموعه داده‌های بزرگی دارند، یادگیری تقویتی قادر است به‌طور مستقیم از تعامل با محیط یاد بگیرد و سیاست‌های بهینه را برای مدیریت توان و بار توسعه دهد.

- در مواردی که سیستم در معرض اغتشاشات و نوسانات بار است، یادگیری تقویتی می‌تواند پاسخ‌گویی سیستم را سریع‌تر و دقیق‌تر کند.

۲. مزایای تحقیق و نوآوری‌ها

تحقیق حاضر مزایای قابل توجهی دارد که در مقایسه با کارهای گذشته برجسته می‌شود:

2.1 یادگیری خودکار و انعطاف‌پذیری سیستم

یکی از بزرگترین مزایای استفاده از یادگیری تقویتی این است که نیاز به مدل‌سازی دقیق سیستم ندارد و می‌تواند به‌طور خودکار سیاست‌های بهینه را از طریق تعامل با محیط یاد بگیرد. این ویژگی به‌ویژه در نیروگاه‌های سیکل ترکیبی که دینامیک‌های پیچیده و غیرخطی دارند، بسیار مؤثر است. برخلاف روش‌های سنتی که ممکن است برای هر تغییر در شرایط بار نیاز به بازتعریف مدل‌ها و تنظیم پارامترها داشته باشند، یادگیری تقویتی به‌طور مستمر و بدون نیاز به مدل‌سازی دقیق، توانست سیاست‌های بهینه را یاد بگیرد.

2.2 بهینه‌سازی همزمان توان و بار

در نیروگاه‌های سیکل ترکیبی، هماهنگ‌سازی توان و بار بین واحدهای گازی و بخاری یکی از چالش‌های مهم است. استفاده از الگوریتم‌های یادگیری تقویتی، به‌ویژه Q-Learning و DQN، توانسته است این مشکل را به‌طور همزمان حل کند. در شرایط بار متغیر، واحدهای گازی و بخاری به‌طور هماهنگ تنظیم شده‌اند تا همواره بهترین استفاده از منابع سوختی را داشته باشند و در عین حال پایداری شبکه را حفظ کنند.

۲.۳ پایداری ولتاژ و فرکانس

پایداری ولتاژ و فرکانس شبکه از جمله مواردی است که در این تحقیق به آن پرداخته شد. یادگیری تقویتی توانست نوسانات ولتاژ و فرکانس را در برابر تغییرات ناگهانی بار کاهش دهد و به‌طور مؤثری در بازگشت سیستم به حالت پایدار پس از اغتشاشات کمک کند. این ویژگی به‌ویژه در شبکه‌های برق با بار متغیر و در معرض نوسانات، اهمیت زیادی دارد.

۴.۲ قابلیت استفاده در شرایط پیچیده و غیرخطی

الگوریتم‌های یادگیری تقویتی به‌ویژه در شرایط پیچیده و غیرخطی که در سیستم‌های قدرت مانند نیروگاه‌های سیکل ترکیبی وجود دارند، عملکرد بسیار بهتری از خود نشان دادند. این سیستم‌ها قادر به یادگیری سیاست‌های بهینه بدون نیاز به مدل‌سازی دقیق و پیش‌بینی‌های پیچیده هستند.

۳. نتایج مهم تحقیق

نتایج این تحقیق به‌طور کلی نشان‌دهنده تأثیر مثبت استفاده از یادگیری تقویتی در بهینه‌سازی سیستم‌های کنترل توان و بار در نیروگاه‌های سیکل ترکیبی است. از مهم‌ترین نتایج به‌دست‌آمده می‌توان به موارد زیر اشاره کرد:

- بهینه‌سازی هماهنگ توان تولیدی بین واحدهای گازی و بخاری به‌طور مؤثرتر از روش‌های سنتی مانند PID انجام شد.
- کاهش نوسانات ولتاژ و فرکانس در شبکه در پاسخ به تغییرات ناگهانی بار و افزایش پایداری سیستم.
- واکنش سریع‌تر به تغییرات بار، به‌ویژه در شرایطی که بار به‌طور ناگهانی تغییر می‌کند.

- کارایی بالاتر نسبت به روش‌های سنتی در حل مسائل پیچیده و غیرخطی.

۴. روابط

$$(1 - P_g(t) \cdot \beta + P_{load}(t) \cdot \alpha = P_g(t)$$

$$(1 - P_b(t) \cdot \gamma + (P_{load}(t) - P_g(t)) \cdot \alpha = P_b(t)$$

$$\alpha \left(r_t + \gamma \cdot \max_a Q(s_{t+1}, a) - Q(s_t, a_t) \right) + Q(s_t, a_t) = Q(s_t, a_t)$$

$$\alpha \left(r_t + \gamma \cdot \max_a Q_{\theta}(s_{t+1}, a) - Q_{\theta}(s_t, a_t) \right) + Q_{\theta}(s_t, a_t) = Q_{\theta}(s_t, a_t)$$

$$\text{FuelConsumption}(t) \cdot w_3 - \text{ResponseTime}(t) \cdot w_2 - \text{Stability}(t) \cdot w_1 = r$$

$$\sqrt{dt^2(\text{nom}V(t) - V)^2 \int_0^T \frac{1}{T} dt} =_{rms} V$$

$$\sqrt{dt^2(\text{nom}f(t) - f)^2 \int_0^T \frac{1}{T} dt} =_{rms} f$$

۱۲. نتیجه‌گیری

یادگیری تقویتی، به‌ویژه Q-Learning و DQN، توانسته است به‌طور قابل توجهی عملکرد نیروگاه‌های سیکل ترکیبی را در کنترل هماهنگ توان و بار بهبود بخشد. استفاده از این الگوریتم‌ها موجب کاهش نوسانات ولتاژ و فرکانس و افزایش

پایداری سیستم شده است. این تحقیق نشان داد که روش‌های یادگیری تقویتی می‌توانند در شرایط پیچیده و دینامیکی به‌طور مؤثری بهینه‌سازی سیستم‌های قدرت را انجام دهند و جایگزین مناسبی برای روش‌های سنتی باشند.

نتایج تحقیق نشان می‌دهد که به‌کارگیری این تکنیک‌ها در نیروگاه‌های سیکل ترکیبی می‌تواند به بهبود بهره‌وری، کاهش هزینه‌ها و ارتقاء پایداری شبکه‌های برق کمک کند.

۱۲. مراجع

1. Sutton, R. S., & Barto, A. G. (2018). Reinforcement Learning: An Introduction. MIT Press.
2. Mnih, V., et al. (2015). Human-level control through deep reinforcement learning. *Nature*, 518(7540), 529-533.
3. Zhang, Y., & Liu, H. (2020). Reinforcement learning for energy management in smart grid systems. *Energy*, 207, 118232.
4. CIGRÉ Study Committee, 2019. Guidelines for Power System Stability Analysis. CIGRÉ Technical Paper.
5. Shafie-khah, M., & Olama, M. M. (2020). AI-based optimization methods for power system operations. *IEEE Transactions on Power Systems*, 35(6), 4567-4578.
6. Wang, L., et al. (2016). An intelligent approach to the optimal operation of combined-cycle power plants. *Energy Conversion and Management*, 113, 10–20.
7. Liu, Y., et al. (2020). Application of reinforcement learning in optimal energy management of combined-cycle power plants. *International Journal of Electrical Power & Energy Systems*, 118, 105722.
8. Yang, Y., et al. (2020). Optimal power flow control using deep reinforcement learning in smart grids. *IEEE Transactions on Power Systems*, 35(2), 1223–1232.
9. Gao, Y., et al. (2021). Reinforcement learning-based optimal operation of integrated gas and electricity systems. *Applied Energy*, 281, 116035.
10. Xie, L., et al. (2019). Reinforcement learning-based control strategy for smart grid voltage regulation. *IEEE Transactions on Smart Grid*, 10(6), 6488-6497.
11. Gama, J., & Tsoumakas, G. (2020). Reinforcement learning for energy management in smart grids. *Springer Handbook of Computational Intelligence*, 1033-1051.
12. Tao, H., et al. (2021). Reinforcement learning for control of combined-cycle power plant: Application and challenges. *Applied Energy*, 298, 117227.

13. Wang, Q., et al. (2019). Deep reinforcement learning-based power dispatch strategy for integrated multi-energy systems. *Energy*, 173, 35-47.
14. Raffard, R., et al. (2017). Optimal control of power systems using deep Q-learning and model predictive control. *IEEE Transactions on Power Systems*, 32(6), 4667-4677.
15. Khan, F., et al. (2019). Energy management in smart grids using deep reinforcement learning. *IEEE Transactions on Industrial Electronics*, 66(7), 5072-5081.
16. Lu, Y., et al. (2017). Reinforcement learning-based economic dispatch for power systems with renewable energy integration. *IEEE Transactions on Power Systems*, 32(4), 2920-2930.