



Improving distribution network operation using load forecasting and optimal placement of DGs by heuristic algorithms

Shahriar Abbasi ¹

¹ Department of Electrical and Computer Engineering, National University of Skills (NUS), Tehran, Iran.

ARTICLE INFO

Article Type:

Original Research

Received: 15.08.2024

Revised: 19.09.2024

Accepted: 19.11.2024

Keyword:

Distribution network, particle swarm optimization (PSO), artificial neural network (ANN), voltage stability index (VSI), cuckoo search algorithm.

*Corresponding Author:

Shahriar Abbasi

Email: shabbasi@tvu.ac.ir

ABSTRACT

Distribution network expansion plays a vital role in the reliable transmission of electricity to the final consumers. But, this expansion requires investment and the lack of this investment causes increased losses, more voltage drop and load imbalance. On the other hand, with the optimal placement of DG devices, the performance of the distribution network can be improved and investment in its expansion can be postponed. Improper installation of DGs increases network losses, reduces network efficiency, and reduces reliability. This paper is focused on improving the efficiency of the distribution network with more reliability by optimal placement of multiple DGs and optimal load forecasting based on evolutionary optimization algorithms. In the proposed method, several DGs are assigned to minimize voltage deviation, reduce power losses, and minimize energy losses and costs. In order to identify candidate buses for DG installation, a voltage stability index (VSI) is used to determine buses subject to voltage drop. Buses with low VSI value are identified as weak ones and selected as candidates for DG installation. Then, using the Improved Cuckoo Search (ICS) algorithm, the optimal DG location is found. Finally, load forecasting will be done using the k-means clustering method and an artificial neural network (ANN) based on particle swarm optimization (PSO) on weekdays. The simulations performed on the IEEE 30 buses test system confirm the efficient and effective performance of the proposed method compared to previous conventional methods.



EXTENDED ABSTRACT

Introduction

Distribution network expansion plays a vital role in the reliable transmission of electricity to the final consumers. However, this expansion requires investment and the lack of this investment causes increased losses, more voltage drop and load imbalance. On the other hand, with the optimal placement of DG devices, the performance of the distribution network can be improved and investment in its expansion can be postponed. Improper installation of DGs increases network losses, reduces network efficiency, and reduces reliability. This study was focused on improving the efficiency of the distribution network with more reliability by optimal placement of multiple DGs and optimal load forecasting based on evolutionary optimization algorithms. In the proposed method, several DGs were assigned to minimize voltage deviation, reduce power losses, and minimize energy losses and costs. To identify candidate buses for DG installation, a voltage stability index (VSI) was used to determine buses subject to voltage drop. Buses with low VSI values were identified as weak ones and selected as candidates for DG installation. Then, using the improved Cuckoo Search (ICS) algorithm, the optimal DG location was found. Finally, load forecasting was carried out using the k-means clustering method and an artificial neural network (ANN) based on particle swarm optimization (PSO) on weekdays. The simulations performed on the IEEE 30 buses test system confirmed the efficient and effective performance of the proposed method compared to previous conventional methods.

Methodology

In the proposed method, several DGs were assigned to minimize voltage deviation, reduce power losses, and minimize energy losses and costs. To identify candidate buses for DG installation, a voltage stability index (VSI) was used to identify buses subject to voltage drop. Buses with lower VSI were identified as poor buses and thus candidates for DG installation. Then, using the improved Cuckoo Search (ICS) algorithm, the exact installation location of the DGs was determined. Finally, weekly load forecasting was conducted using the k-means clustering method and an artificial neural network (ANN) based on particle swarm optimization (PSO). The simulations performed on the IEEE 30-bus test system confirmed the efficient and effective performance of this proposed method compared to previous conventional methods. The proposed method was implemented on the 30-bus IEEE standard system in the MATLAB software environment with a computer system with the following specifications:

- Processor: Intel core i5 @ 3GHz
- RAM: 8GB
- Operating system: Windows 8
- MATLAB version: 2013b

Results and discussion

Simulation of DG placement: For EP, GA, PSO and proposed methods, the result of

optimal DG placements is listed in Table 1. The voltage and power loss characteristics of the IEEE 30-bus system with and without DG installation are presented in Figures 2 and 3. The results showed that the proposed approach is better than previous approaches. According to Figures 1 and 2, before installing the DG, the total power loss was 0.09 kW and the voltage profile was 220 kV. After installing DG, the total power loss was 0.0778 kW by EP, 0.05 kW by GA, 0.04 kW by PSO, and 0.0301 kW by the proposed ICS-based method. In addition, the total voltage profile was 245 kV by EP, 290 kV by GA, 300 kV by PSO, and 307 kV by the proposed ICS-based method.

Table 1: Optimum placements of DG along with voltage and loss profile.

Method	Candidate bus		Total Power Loss (KW)	Total Voltage Profile (kV)	Population	Iteration	Run time (S)
EP	9		0.0778	245	40	80	396
GA	18		0.05	290	40	80	376
PSO	4		0.04	300	40	80	340
The proposed method	26		0.0301	307	40	80	312

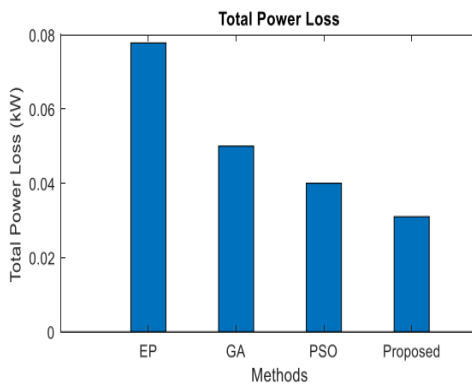


Figure 1: Total power losses.

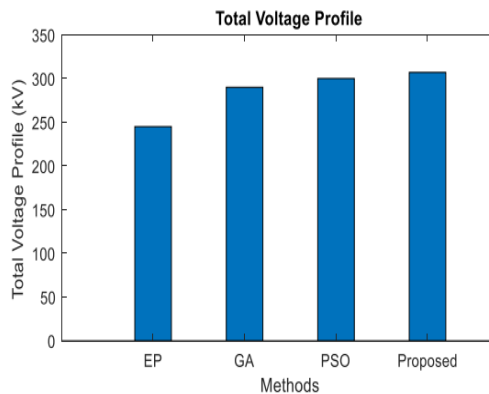


Figure 2: Total voltage profile.

Simulation of load demand forecasting: The quality of load forecasting was evaluated

based on sample data of days of the week. In the proposed method, k-means and ANN were used, so that the primary data were clustered and then classified. Considering Sundays as holidays and Wednesdays as the middle of the week, the electrical load required on Wednesday was often higher compared to Sunday. The load forecast for Wednesday and Sunday is shown in Tables 2 and 3 and Figures 3 and 4. Therefore, the load predicted by the ICS method was closer to the actual load, but the estimated load by other methods such as EP, GA, and also PSO differed significantly from the actual load.

Table 2: Comparison of load forecasting methods on Wednesday.

Method	Load (MW)	Forecasting error (%)
ABC	2.57	- 41
EP	3	- 31
ECO-ABC	3.1	- 29
GA	3.5	- 20
PSO	3.4	- 22
Proposed method	4.4	1
Actual load	4.36	-

Table 3: Comparison of load forecasting methods on Sunday.

Method	Load (MW)	Forecasting error (%)
ABC	0.7	- 70
EP	1	- 58
ECO-ABC	1.23	- 48
GA	1.5	- 37
PSO	1.7	- 56
Proposed method	2.4	1
Actual load	2.37	-




Figure 3: Comparison of load forecasting methods on Wednesday.

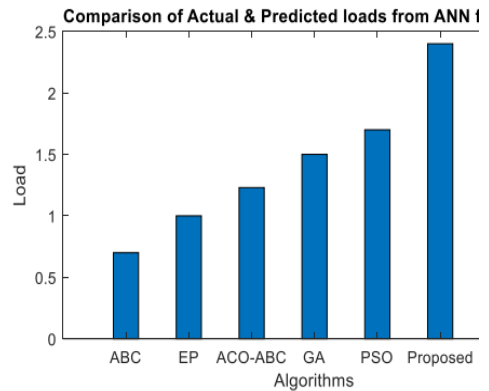


Figure 4: Comparison of load forecasting methods on Sunday.

Conclusion

In this paper, improving the performance of the distribution network by placing DG productions and load forecasting using heuristic algorithms was investigated. The IEEE standard 30-bus test system was used to test the proposed ICS-based method for optimal placement of DG resources. Initially, k-means clustering combined with ANN based on particle swarm optimization was used for load forecasting. Then, DG resources were placed in the experimental system with the help of the ICS optimization algorithm. After analyzing the simulation results and comparing them with conventional methods such as EP, GA and PSO, it was concluded that the performance of the method proposed in the paper is more effective in predicting the load and optimal placement of DG resources. Therefore, the test results showed that the proposed method is a more suitable solution for improving the efficiency of energy distribution systems.



بهبود عملکرد شبکه توزیع برق با پیش‌بینی بار و جانمایی بهینه تولیدات پراکنده با الگوریتم‌های ابتکاری

شهریار عباسی^۱

۱- استادیار مهندسی برق، گروه مهندسی برق و کامپیوتر، دانشگاه ملی مهارت، تهران، ایران.

چکیده

اطلاعات مقاله

توسعه شبکه توزیع انرژی الکتریکی، نقش حیاتی در ارسال مطمئن این انرژی به مصرف‌کنندگان نهایی دارد. این توسعه مستلزم سرمایه‌گذاری است و در غیر این صورت، افزایش تلفات توزیع، افت زیاد ولتاژ و عدم تعادل بار را به دنبال دارد. از طرفی، با جانمایی بهینه تولیدات پراکنده DG می‌توان عملکرد شبکه توزیع را بهبود و سرمایه‌گذاری توسعه آن را به تعویق انداخت. نصب نادرست DGها باعث افزایش تلفات شبکه توزیع، کاهش کارایی و قابلیت اطمینان آن می‌شود. هدف این مقاله، بهبود کارایی شبکه توزیع با قابلیت اطمینان بیشتر با جانمایی بهینه DGها و پیش‌بینی بهینه بار با الگوریتم‌های بهینه‌سازی تکاملی است. چندین DG برای حداقل کردن انحراف ولتاژ، تلفات توان و هزینه‌ها لحاظ شده است. برای شناسایی شین‌های کاندیدای نصب DG، از یک شاخص پایداری ولتاژ (VSI) برای شناسایی شین‌های در معرض سقوط ولتاژ استفاده شده است. شین‌های با VSI کمتر به‌عنوان شین‌های ضعیف شناسایی و کاندیدا می‌شوند. با استفاده از الگوریتم بهبودیافته جستجوی فاخته (ICS)، مکان دقیق نصب DGها تعیین می‌شود. نهایتاً، پیش‌بینی بار هفتگی به کمک روش خوشه‌بندی k-means و یک شبکه عصبی مصنوعی (ANN) مبتنی بر بهینه‌سازی ازدحام ذرات (PSO) انجام می‌گیرد. شبیه‌سازی‌های انجام‌شده روی سیستم آزمایشی ۳۰ شینه IEEE موید کارایی روش پیشنهادی در مقایسه با روش‌های مرسوم قبلی است به‌گونه‌ای که نسبت به سایر روش‌ها، روش پیشنهادی با دقت بیشتری بار مصرفی شبکه توزیع را پیش‌بینی می‌کند. به علاوه، به کمک روش پیشنهادی جانمایی منابع DG منجر به حداقل کردن تلفات توان و بهبود پروفیل ولتاژ می‌شود.

نوع مقاله: مقاله پژوهشی

دریافت مقاله: ۱۴۰۳/۰۵/۲۵

بازنگری مقاله: ۱۴۰۳/۰۶/۲۹

پذیرش مقاله: ۱۴۰۳/۰۸/۲۹

کلید واژگان:

شبکه توزیع، بهینه‌سازی انبوه ذرات (PSO)، شبکه عصبی مصنوعی (ANN)، شاخص پایداری ولتاژ (VSI)، الگوریتم جستجوی فاخته (CS)

*نویسنده مسئول: شهریار عباسی

پست الکترونیکی:

shabbasi@tvu.ac.ir



مقدمه

مقررات‌زدایی^۱ و تغییرساختار^۲ صنعت برق باعث افزایش گرایش به تولید پراکنده^۳ (DG) شده است که این موضوع نقش مهمی در برنامه‌ریزی توسعه ساختار سیستم قدرت و عملکرد شرکت‌ها دارد [۱-۳]. تولیدکننده متصل به یک شین توزیع به‌عنوان DG شناخته می‌شود [۴، ۵]. در عمل، برای ممانعت از بازطراحی، بهبود پروفیل ولتاژ، کاهش تلفات، تقویت و بهبود کیفیت و اثربخشی شبکه توزیع، DGها به‌طور هدفمند در شبکه، جانمایی و نصب می‌شوند. DGها اغلب در سمت تقاضای سیستم‌های قدرت یعنی سطح توزیع نصب می‌شوند و نفوذ بالای DGها تأثیر بسزایی در عملکرد در شبکه‌های توزیع دارند تا آنجایی که می‌توان مقدار و جهت شارش توان را در شبکه توزیع از طریق نفوذ تولید DG تغییر داد [۶-۸]. بنابراین باید نصب DG با توجه به اندازه و مکان بهینه آنها و با هدف دستیابی به بیشترین مزیت DG در شبکه باشد [۹، ۱۰]. فاکتورهای مهم در نصب DGها، شناسایی بهترین مکان، اندازه، ظرفیت، نوع، به علاوه دوره نصب آنها است [۱۱]. روش‌های متعددی برای جانمایی بهینه واحدهای DG در سیستم‌های توزیع وجود دارد [۱۲، ۱۳]. مؤلفان مراجع [۱۴-۱۶] جانمایی بهینه DGها در شبکه‌های توزیع را به‌صورت یک مسئله بهینه‌سازی واحد، فرمول‌بندی و حل کرده‌اند. در این مراجع، هزینه‌های سرمایه‌گذاری، بهره‌برداری، راه‌اندازی، هزینه توان‌های اکتیو و راکتیو، پیش‌نیازهای حرارت و توان و پروفیل ولتاژ متغیر اصلی مسئله بهینه‌سازی بودند. در حل این مسئله بهینه‌سازی، از روش‌های سنتی و ابتکاری استفاده شده است. در همین راستا، مراجع [۱۷-۱۹] به جانمایی بهینه یک واحد DG منفرد و مراجع [۲۰] به جانمایی بهینه واحدهای چندگانه DG پرداخته‌اند.

از دیرباز، پیش‌بینی بار، ابزاری قابل اعتماد در بهره‌برداری و برنامه‌ریزی سیستم‌های قدرت بوده است. پس از پیش‌بینی بار، توزیع بهینه تولید، ارزیابی قابلیت اطمینان، تخصیص DGها و تعمیر و نگهداری ژنراتورها [۲۱] مؤثرتر انجام می‌گردد. از جمله مطالعات انجام‌شده در راستای پیش‌بینی بار، مدل پیش‌بینی بار کوتاه‌مدت ماشین بردار پشتیبان^۴ [۲۲] و مدل مبتنی بر الگوریتم ژنتیک [۲۳] است.

گیتی‌زاده و همکاران در مرجع [۲۴] مسئله برنامه‌ریزی توسعه شبکه توزیع چندمرحله‌ای (MDEP) در حضور DGها را به‌صورت یک مسئله بهینه‌سازی چندهدفه با اهداف حداقل‌رساندن هزینه‌های سرمایه‌گذاری و بهره‌برداری و حداکثر کردن شاخص قابلیت اطمینان ارائه کرده‌اند. این مسئله بهینه‌سازی برای یافتن پیکربندی ایدئال فیدر که شامل اندازه بهینه هادی‌ها، جایگزینی هادی برای فیدرهای آماده به کار و توان تولیدی DG حل شده است. برای ارزیابی قابلیت اطمینان در مسئله MDEP پیشنهادی، از یک رویکرد تحلیلی مبتنی بر نظریه گراف استفاده می‌شود و شاخص انرژی تأمین‌نشده^۵ (ENS) به‌عنوان یک تابع هدف اضافی ارزیابی می‌گردد. همچنین از یک الگوریتم ترکیبی بهینه‌سازی ازدحام ذرات^۶ (PSO) و جهش قورباغه مختلط^۷ (SFL) برای شناسایی پاسخ‌های بهینه پارتو^۸ مسئله چندهدفه MDEP استفاده شده است. در مرجع [۲۵]، با نصب DGها در شبکه‌های توزیع مقیاس‌بزرگ، تلفات به‌طور چشم‌گیری کاهش یافته است. همچنین در این مرجع، یک روش تحلیلی ارتقایافته^۹ (IA) مبتنی بر بیان IA برای محاسبه اندازه ایدئال

1. Deregulation

2. Restructuring

3. Distributed Generation

4. Prerequisites

5. Support vector machine

6. Multistage Distribution Network Expansion Planning

7. Energy-Not-Supplied

8. Hybrid Particle Swarm Optimization

9. Shuffled Frog Leaping

1. Pareto optimal solutions 0

1. Upgraded analytical 1

چهار نوع مختلف DG و از یک استراتژی خاص برای جانمایی DGها استفاده شده است. مرجع [۲۶]، از یک رویکرد جدید مبتنی بر الگوریتم جستجوی هارمونی (HS) موسوم به HS چندهدفه بهبودیافته (IMOHS) برای جانمایی DGها در شبکه‌های توزیع شعاعی استفاده کرده است که در آن، معیارهای تلفات توان و پروفیل ولتاژ به عنوان توابع هدف برای جانمایی واحدهای DG استفاده شده است. در مرجع [۲۷]، روش تحلیل حساسیت تلفات توان برای جانمایی DGها با هدف کاهش تلفات شبکه، کاهش هزینه‌های بهره‌برداری و افزایش پایداری ولتاژ پیشنهاد شده است. برای تعیین اندازه مناسب DG، از الگوریتم بهینه‌سازی کاوش باکتریایی استفاده شده است. شنگ دلیبو و همکاران در مرجع [۲۸] یک الگوریتم INSGA-II بهبودیافته برای برنامه‌ریزی کارآمد انواع واحدهای DG را پیشنهاد کرده‌اند. توابع چندهدفه ایجادشده شامل حداقل تلفات خط، حداقل تغییرات ولتاژ و حداکثر حاشیه پایداری ولتاژ هستند.

هدف این مقاله، بهبود کارایی شبکه توزیع انرژی الکتریکی با قابلیت اطمینان بیشتر با جانمایی بهینه DGهای چندگانه و پیش‌بینی بهینه بار بر اساس الگوریتم‌های بهینه‌سازی تکاملی متمرکز شده است. این مقاله، روی بهبود کارایی شبکه توزیع با قابلیت اطمینان بیشتر با جانمایی بهینه DGهای چندگانه و پیش‌بینی بهینه بار بر اساس الگوریتم‌های بهینه‌سازی تکاملی متمرکز شده است. در روش پیشنهادی، چندین DG برای به حداقل رساندن انحراف ولتاژ، کاهش تلفات توان و به حداقل رساندن تلفات انرژی و هزینه‌ها اختصاص داده شده است. به منظور شناسایی شین‌های کاندیدای نصب DG، از یک شاخص پایداری ولتاژ (VSI) برای شناسایی شین‌های در معرض سقوط ولتاژ استفاده شده است. شین‌های با VSI کمتر به عنوان شین‌های ضعیف شناسایی و برای نصب DG کاندیدا می‌شوند. سپس، با استفاده از الگوریتم بهبودیافته جستجوی فاخته (ICS)^۳، مکان دقیق نصب DGها تعیین می‌شود. در نهایت، پیش‌بینی بار هفتگی به کمک روش خوشه‌بندی k-means و یک شبکه عصبی مصنوعی (ANN)^۴ مبتنی بر بهینه‌سازی ازدحام ذرات (PSO) انجام می‌گیرد. شبیه‌سازی‌های انجام‌شده روی سیستم آزمایشی ۳۰ شینه IEEE موید عملکرد کارا و مؤثر این روش پیشنهادی (روش مبتنی بر ICS) در مقایسه با روش‌های مرسوم قبلی است به گونه‌ای که نسبت به سایر روش‌ها، روش پیشنهادی با دقت بیشتری بار مصرفی شبکه توزیع را پیش‌بینی می‌کند. به علاوه، به کمک روش پیشنهادی جانمایی منابع DG منجر به کاهش بیشتر تلفات توان و بهبود بیشتر پروفیل ولتاژ می‌شود. خلاصه نوآوری‌های این مقاله به صورت زیر است:

- بهبود کارایی شبکه توزیع انرژی الکتریکی با قابلیت اطمینان بیشتر با جانمایی بهینه DGهای چندگانه
 - پیش‌بینی دقیق‌تر بار شبکه توزیع به کمک روش پیشنهادی
 - شناسایی و انتخاب شین‌های در معرض سقوط ولتاژ و کاندیدا به کمک یک شاخص پایداری ولتاژ (VSI) برای نصب DGهای چندگانه
 - کاهش بیشتر تلفات توان شبکه توزیع به کمک روش پیشنهادی نسبت به سایر روش‌ها
 - بهبود بیشتر پروفیل ولتاژ به کمک روش پیشنهادی نسبت به سایر روش‌ها.
- ادامه این مقاله به این صورت سازماندهی شده است: در بخش ۲، مبانی نظری و فرمول‌بندی روش پیشنهادی ارائه شده است. در بخش ۳، روش انجام آزمایش و در بخش ۴، نتایج شبیه‌سازی و بحث ارائه شده است. بخش ۵ مربوط به نتیجه‌گیری است.

1. Improved Multi objective HS

2. Bacterial Foraging Optimization Algorithm

3. Improved Cuckoo Search

4. Artificial neural network

مبانی نظری و فرمول‌بندی روش پیشنهادی

شبکه‌های توزیع عموماً از فیدرهایی با اتصال شعاعی تشکیل شده‌اند. بار و تقاضا رو به رشد مستلزم توسعه شبکه‌های توزیع می‌باشد. در غیر این صورت، ازدست‌دادن پایداری ولتاژ شین، عدم تعادل بار، افت بیشتر ولتاژ و افزایش تلفات شبکه دور از انتظار نیست. استفاده از منابع DG به‌منظور پیشگیری پیامدهای نامطلوب فوق، اقدامی مؤثر در بهبود عملکرد شبکه‌های توزیع است. نصب چنین منابعی در شبکه‌های توزیع می‌تواند سرمایه‌گذاری توسعه شبکه را کاهش دهد و باعث صرفه‌جویی در هزینه‌ها گردد. در تحقیقات قبلی، واحد DG منفرد در سیستم‌های توزیع جانمایی شده است اما امروزه نصب DGهای چندگانه در شبکه‌های توزیع به‌سرعت رو به افزایش است. تا کنون پژوهشگران بسیاری با استفاده از روش‌های بهینه‌سازی تکاملی مانند الگوریتم ژنتیک (GA) [۲۹]، بهینه‌سازی ازدحام ذرات (PSO) [۳۰]، الگوریتم جستجوی فاخته (CS) [۳۱] و غیره، تکنیک‌هایی را برای یافتن مکان و اندازه بهینه DGها ارائه کرده‌اند. از میان این الگوریتم‌ها، الگوریتم CS توسعه‌یافته (ICS) عملکرد بهتری از خود نشان داده و قادر است پاسخ بهینه را براساس جستجوی تصادفی کشف کند. البته این الگوریتم تضمینی برای همگرایی سریع ارائه نمی‌کند و برای حل مسائل مختلف باید نرخ همگرایی آن را افزایش داد. در این مقاله، از این الگوریتم برای جانمایی DGهای چندگانه در شبکه‌های توزیع استفاده می‌شود. در ادامه، مبانی نظری و فرمول‌بندی روش پیشنهادی تشریح می‌گردد.

نصب DGهای چندگانه

مسئله برنامه‌ریزی توسعه شبکه توزیع همراه با جانمایی DG و پیش‌بینی بار مطرح‌شده در بالا براساس استراتژی چند مرحله‌ای زیر انجام می‌شود:

الف - جانمایی DGها براساس شاخص پایداری ولتاژ (VSI)^۴

ب - یافتن اندازه DGها به کمک الگوریتم ICS

ج - پیش‌بینی بهینه بار به کمک روش خوشه‌بندی k-means همراه با الگوریتم ترکیبی PSO با ANN. این روش‌ها در بخش چهار تشریح می‌گردند.

جانمایی DGها و پیش‌بینی بار به کمک الگوریتم ترکیبی PSO با ANN

DGها منابع نسبتاً کوچک تولید توان هستند و برای تقویت شبکه‌های توزیع (معمولاً بین ۳ تا ۱۰۰۰۰ کیلووات) نصب می‌شوند. سلول‌های سوختی، توربین‌های گازی کوچک، میکروتوربین‌ها، انرژی باد و خورشید، زیست توده، انرژی آبی کوچک نمونه‌هایی از سیستم‌های DG هستند. گنجاندن ماژول‌های DG در سیستم‌های قدرت چندین مزیت را به دنبال دارد: بهبود پروفیل‌های ولتاژ، تقویت شبکه، به تعویق انداختن هزینه سرمایه‌گذاری توسعه زیرساخت‌ها، کاهش تلفات و هزینه‌های نگهداری، افزایش یکپارچگی، قابلیت اطمینان و کارایی سیستم. برای استفاده بهینه باید واحدهای DG با اندازه بهینه در مکان مناسب نصب گردند. نصب این واحدها در مکان‌های نامناسب ممکن است قابلیت اطمینان را کاهش دهد و ناکارآمدی شبکه و همچنین افزایش هزینه‌ها را به دنبال داشته باشد.

در روش پیشنهادی در این مقاله، چندین DG برای به حداقل رساندن انحراف ولتاژ، کاهش تلفات توان و کاهش هزینه انرژی تخصیص داده می‌شود. شین‌های کاندیدا نصب DG به کمک شاخص VSI شناسایی می‌شوند. شین‌های با شاخص VSI کوچک همان شین‌های ضعیف و منتخب برای نصب DG هستند. سپس، با استفاده از الگوریتم ICS اندازه بهینه DG تعیین می‌گردد. نهایتاً، پیش‌بینی بار به کمک روش خوشه‌بندی k-means و یک ANN مبتنی بر الگوریتم PSO در روزهای هفته انجام خواهد شد.

1. Genetic algorithm


2. Particle swarm optimization

3. Cuckoo search

4. Voltage Stability Index

شاخص پایداری ولتاژ (VSI)

پایداری ولتاژ به معنای قابلیت سیستم در حفظ دامنه ولتاژ همه شین‌ها در سطوح قابل قبول پس از رخداد اغتشاش یا افزایش بار است [۳۲]. از جمله شایع‌ترین علل ناپایداری ولتاژ می‌توان به افزایش ظرفیت، عملکرد نادرست شبکه قدرت (مانند خطوط انتقال، ترانسفورماتورهای قدرت و ژنراتورها)، تجاوز از محدودیت‌های تولید توان راکتیو ژنراتورها و همچنین خرابی ترانسفورماتورهای سوئیچینگ تحت بار اشاره کرد. بهترین روش جلوگیری از ناپایداری ولتاژ، بهبود استحکام شبکه قدرت است. در این مقاله، به‌منظور یافتن شین‌های ضعیف و انتخاب مکان و اندازه بهینه DGها در شبکه توزیع از یک شاخص VSI مبتنی بر الگوریتم ICS استفاده می‌شود. این شاخص بر اساس قیود مشخصی و مدار معادل تونن شکل ۱ می‌باشد [۳۳].



شکل ۱. مدار معادل تونن از دید یک شین بار متصل به سیستم قدرت.

در بارگذاری حداکثر، مقدار افت ولتاژ غیرخطی در امپدانس تونن Z با دامنه ولتاژ شین بار V_r برابر می‌گردد. اگر افزایش بار به‌صورت پیوسته باشد، نقطه حداکثر قابلیت بارگذاری منطبق بر نوک منحنی PV می‌گردد [۳۴]. با توجه به مدار معادل شکل ۱، شاخص VSI برای شین i به‌صورت رابطه (۱) محاسبه می‌شود:

$$VSI_i = \frac{V_i}{\Delta V_i} \quad (1)$$

V_i : دامنه ولتاژ در شین بار i

ΔV_i : افت ولتاژ در امپدانس تونن که بیانگر نزدیکی این شین بار به نزدیک‌ترین ژنراتورها.

مقدار VSI در بارگذاری حداکثر برابر ۱ و در بارگذاری‌های کمتر مقدار این شاخص بیشتر از ۱ می‌گردد. کوتاه‌ترین مسیرهای j بین شین بار i و هر شین ژنراتور سیستم قدرت باید مطابق رابطه (۲) شناسایی شود که

مجموع مقادیر مطلق افت ولتاژ هر مسیر است.

$$\Delta V_i^{(j)}(t) = \min_j \Delta V_i^{(j)}(t) = \min_j \sum_{b=1}^{n_j-1} |V_b(t) - V_{b+1}(t)| \quad (2)$$

1. Maximum loadability

2. Power-Voltage

که n_j بیانگر تعداد شین‌های ژنراتوری است. رابطه (۲) بیان می‌کند که پس از هر تغییر در سیستم لازم است نزدیک‌ترین شین ژنراتوری به شین بار i شناسایی گردد. بدین منظور، مؤلفان مرجع [۲۱] یک رویکرد تطبیقی مبتنی بر ساخت یک ماتریس که شامل تمامی مسیرهای اتصال شین بار i به شین‌های ژنراتوری است، ارائه کرده‌اند. یکی از معایب کلیدی این رویکرد، حجم محاسباتی قابل توجه آن است. همچنین، ماتریس موردنظر باید با هر تغییر در ساختار شبکه انرژی اصلاح گردد که این کار به‌ویژه در شبکه‌های مقیاس بزرگ آسان نیست. در نتیجه، مکانیسم ارزیابی مسیر باید بهبود یابد. برای رفع این مشکل، در این مقاله از الگوریتم ICS استفاده شده است.

الگوریتم بهبودیافته جستجوی فاخته (ICS)

اصول عملکرد این الگوریتم در مرجع [۳۵] تشریح شده است. متغیرهای P_a ، λ و α به این الگوریتم در یافتن جایگزین‌های تقویت‌شده بین‌المللی و منطقه‌ای کمک می‌کنند. متغیرهای P_a و α در واقع متغیرهای بسیار ضروری در تنظیم پاسخ‌های مسئله هستند و ممکن است برای تغییر سرعت بسته فردی مورد استفاده قرار گیرند. روش استاندارد CS از مقادیر ثابتی برای P_a یا α استفاده می‌کند که این مقادیر ممکن است در طول تکرارهای بعدی اصلاح شوند. نقطه ضعف اصلی این استراتژی، تعداد زیاد تکرارهای موردنیاز برای به‌دست‌آوردن پاسخ بهینه است. اگر مقدار P_a کم و مقدار α زیاد باشد، اثربخشی فرد ناکافی خواهد بود و در نتیجه تعداد تکرارها افزایش می‌یابد. اگر مقدار P_a کم و سطح α نیز پایین باشد، سرعت ادغام بالا می‌شود ولی ممکن است الگوریتم در یافتن گزینه‌های بهینه دچار شکست گردد.

$$P_a(gn) = \frac{(P_{a_{\max}} - P_{a_{\min}})}{NI} \times gn \quad (۳)$$

$$\alpha(gn) = \alpha_{\max} \exp(c \cdot gn) \quad (۴)$$

$$c = \frac{\ln\left(\frac{\alpha_{\min}}{\alpha_{\max}}\right)}{NI} \quad (۵)$$

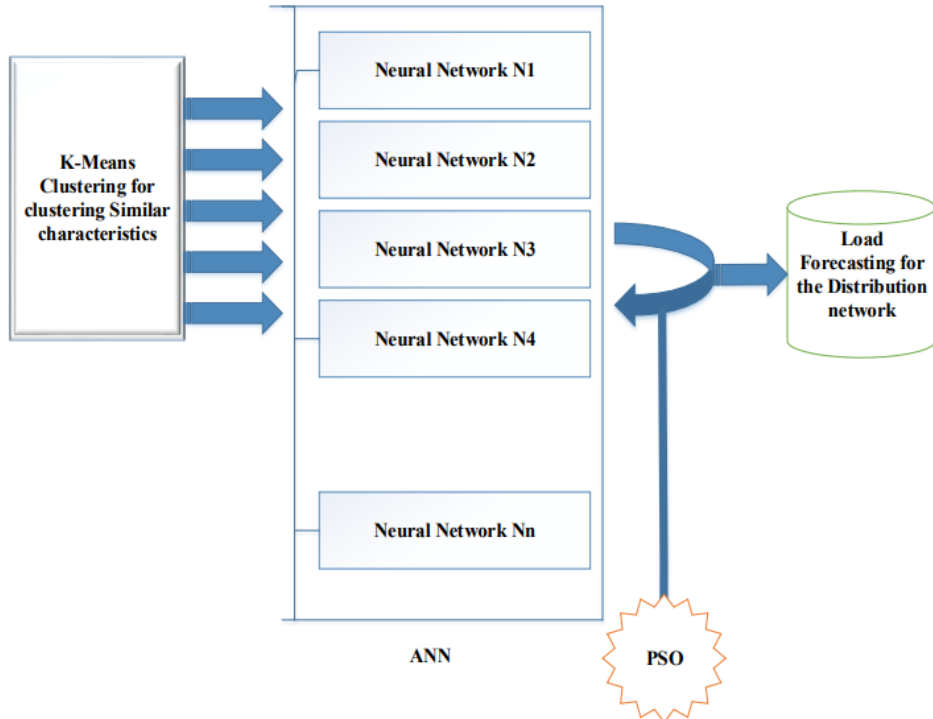
پیش‌بینی بار به کمک روش خوشه‌بندی k-means همراه با الگوریتم ترکیبی ANN و PSO

در اینجا یک استراتژی برای پیش‌بینی تقاضای بار یک‌روزه برای حفظ کارایی شبکه‌های توزیع ارائه شده است. با جمع‌آوری اطلاعات قبلی بارها، هدف ساختن سیستمی برای پیش‌بینی‌های بلادرنگ بار است. تقاضای بار سیستم که مجموع بارهای منفرد است به دو مؤلفه پایه^۱ و اتفاقی^۲ تقسیم می‌شود. عوامل اقتصادی، محیطی، زمان و آب و هوا باعث تغییر این مؤلفه‌ها در منحنی بار می‌شوند.

شکل ۲ روش پیشنهادی برای پیش‌بینی بار را معرفی می‌کند. هدف روش پیشنهادی تشخیص مؤثر عوامل مذکور در پاراگراف قبلی برای استفاده در الگوریتم یادگیری و سپس تخمین بار متناظر است.

1. Base

2. Random



شکل ۲. روش پیش‌بینی بهینه بار به کمک روش خوشه‌بندی k-means همراه با الگوریتم‌های ترکیبی PSO و ANN.

بنابراین، این روش پیش‌بینی بار شامل خوشه‌بندی K-means همراه با طبقه‌بندی‌کننده PSO مبتنی بر ANN است. برای پیش‌بینی دقیق بار، داده‌های قبلی بار توسط k-means خوشه‌بندی شدند و از خوشه‌های آن برای آموزش ANN استفاده می‌شود. سپس، الگوریتم PSO از خروجی‌های ANN برای پیش‌بینی تقاضای بار استفاده می‌کند. ANN متشکل از یک لایه ورودی، یک یا چندین لایه پنهان و همچنین یک لایه خروجی است. هر لایه دارای چندین نورون است زیرا هر نورون در یک لایه دارای یک ارتباط وزنی مشخص با نورون‌های لایه مجاور است. اطلاعات وارد لایه ورودی می‌شوند، در لایه‌های پنهان حرکت می‌کنند و در نهایت به لایه خروجی می‌رسند. به استثنای لایه ورودی، هر نورون ورودی‌هایی را از نورون‌های لایه‌های قبلی دریافت می‌کند که به صورت خطی توسط امتیاز پیوند نورون‌های متصل وزن داده می‌شوند. پس از آن، نورون، الگوی خروجی خود را با ارسال سیگنال انباشته‌شده از طریق یک عملگر سیگموئید تولید می‌کند.

خوشه‌بندی K-means در پیش‌بینی بار [۳۶]

در حالت معمول، تعداد داده‌های قبلی بار به عنوان ورودی‌های ANN زیاد است. برای تحلیل پیش‌بینی بار، تعداد ورودی‌ها و مقدار و مکان آنها باید دقیق شناسایی شوند. بدین منظور در روش پیشنهادی، ابتدا از خوشه‌بندی K-means برای به حداقل رساندن ابعاد داده‌های ورودی استفاده می‌شود.

انتظار می‌رود که تعداد Q منبع اطلاعاتی در دسترس باشد. ورودی‌های $\{W_{ij}\}$ به بالاترین لایه اعمال می‌شوند. این خوشه K-means مجموعه بزرگ مقدار $\{\vec{t}_1, \vec{t}_2, \dots, \vec{t}_Q\}$ را به سه خوشه ممکن مانند $\{\vec{a}_1, \vec{a}_2, \dots, \vec{a}_Q\}$ و $\{\vec{b}_1, \vec{b}_2, \dots, \vec{b}_Q\}$ و $\{\vec{c}_1, \vec{c}_2, \dots, \vec{c}_Q\}$ گروه‌بندی می‌کند. این خوشه‌ها بر اساس معیارهای $\{W_{ij}\}$ تقسیم می‌شوند.

ANN

از خوشه‌های استخراج‌شده از K-means برای آموزش ANN برای پاسخ‌دادن به بردارهای هدف مربوطه استفاده می‌شود. این آموزش در صورت نبود نقص خاصی ادامه دارد. معمولاً هر زمان که میانگین نقص بین پاسخ‌های موردانتظار ANN در مقابل پاسخ‌های واقعی در مجموعه اطلاعات آموزشی Q کمتر از حد از پیش تعیین شده باشد، آموزش پایان می‌یابد. مدت‌زمان یادگیری لازم توسط عوامل مختلفی از قبیل پیچیدگی موضوع، مقدار نقاط داده، پیکربندی شبکه و همچنین ثابت‌های برنامه‌نویسی به‌کار گرفته‌شده، تعیین می‌شود.

در این مقاله، از قانون دلتای تعمیم‌یافته (GDR) برای آموزش یک ANN از نوع پرسپترون چند لایه استفاده شده

است. هنگامی که یک دنباله ورودی به سیستم ارائه می‌شود، یک دنباله نتیجه تولید می‌کند. وزن‌های $\{W_{ij}\}$ برنامه برای کاهش خطای خروجی بر اساس تفاوت بین نتایج تولیدشده با خروجی‌های هدف تغییر می‌کند. این خطا قبل از اینکه به لایه ورودی نزدیک شود از مرحله تسلیم به لایه پنهان به سمت پایین منتشر می‌شود. به دلیل انتقال واپسگرا^۱ خطاها، GDR به عنوان روش پیشخور نادرست شناخته می‌شود.

تخلیه یک نورون i یعنی O_i ، به وسیله وزن اتصال $\{W_{ij}\}$ به ورودی نورون j مرتبط است. به استثنای حالتی که نورون k یکی از نورون‌های ورودی k باشد، شرط آن به صورت زیر است:

$$O_k = f(\sum_i W_{ik}, O_i) \quad (6)$$

که $f(x) = 1/(1 + e^{-x})$ و مجموع آن برای تمام نورون‌های لایه همسایه است. با فرض اینکه، حالت هدف نورون خروجی t باشد، خطا در نورون خروجی را می‌توان به صورت تعریف کرد:

$$E = \frac{1}{2}(t_k - O_k)^2 \quad (7)$$

که k نورون خروجی است.

وزن‌ها توسط الگوریتم کاهش گرادیان بر اساس خطای گرادیان تنظیم می‌شوند، یعنی:

$$\Delta W_{ij} \alpha - \frac{\partial E}{\partial W_{ij}} = - \frac{\partial E}{\partial O_j} \frac{\partial O_j}{\partial W_{ij}} \quad (8)$$

سیگنال خطا به صورت زیر تعریف می‌شود:

$$\delta_j = - \frac{\partial E}{\partial O_j} \quad (9)$$

GDR معادل با استفاده از deception جزئی به‌دست می‌آید:

1. Generalized Delta rule

2. Retrograde

$$\Delta W_{ij} = \varepsilon \delta_j O_j \quad (10)$$

که ε یک بهره سازگاری است. δ_j بر اساس بودن یا نبودن نورون j در لایه خروجی محاسبه می‌شود. اگر یکی از نورون‌های خروجی نورون j باشد:

$$\delta_j = (t - O_j) O_j (1 - O_j) \quad (11)$$

اگر نورون j در لایه خروجی نباشد:

$$\delta_j = O_j (1 - O_j) \sum_k \delta_k W_{jk} \quad (12)$$

برای بهبود همگرایی می‌توان یک عبارت تکانه با بهره حرکت α به رابطه (۱۰) اضافه کرد:

$$\Delta W_{ij}(n+1) = \varepsilon \delta_j O_i + \alpha \Delta W_{ij}(n) \quad (13)$$

که n شاخص تکرار است.

بهینه‌سازی ANN همراه با PSO

الگوریتم بهینه‌سازی PSO از گروهی از ذرات تشکیل شده است که بر اساس بهترین مکان قبلی خود و همچنین بهترین مکان گذشته کل جمعیت یا یک همسایه نزدیک در فضای جستجو حرکت می‌کنند. سرعت هر ذره در هر تکرار به صورت زیر به روز می‌شود:

$$v_i^{(t+1)} = v_i^{(t)} + (c_1 \times \text{rand}()) \times (p_i^{best} - p_i(t)) + (c_2 \times \text{rand}()) \times (p_{gbest} - p_i(t)) \quad (14)$$

که در آن، $v_i^{(t+1)}$ سرعت جدید برای ذره i است، c_1 و c_2 به ترتیب ضرایب وزنی برای بهترین موقعیت ذره و بهترین موقعیت جهانی است. $p_i(t)$ موقعیت ذره i در زمان t ، p_i^{best} بهترین موقعیت شناخته شده ذره i و p_{gbest} بهترین موقعیت شناخته شده برای جمعیت است. تابع $\text{rand}()$ یک متغیر تصادفی یکنواخت در بازه $[0, 1]$ تولید می‌کند. موقعیت هر ذره به صورت زیر به روز می‌شود:

$$p_i^{(t+1)} = p_i^{(t)} + v_i^{(t)} \quad (15)$$

الگوریتم PSO در مرجع [۳۰] به صورت مفصل تشریح شده است.

مسئله بهینه‌سازی مربوطه

در واقع، مسئله بهینه‌سازی مربوطه یک مسئله بهینه‌سازی دو سطحی است. در سطح نخست، مکان بهینه منابع DG توسط یک الگوریتم بهینه‌سازی تعیین می‌گردد. پس از نصب منابع DG در مکان موردنظر در سیستم موردبررسی، به عنوان سطح دوم مسئله، مجموعه معادلات پخش بار بهینه (۱۶) به منظور حداقل کردن هزینه‌های بهره‌برداری سیستم حل می‌گردد (به کمک جعبه ابزار mathpower).

(۱۶-الف)

$$\min \sum_{i=1}^{NG} f_i(P_G) + P_{Loss}$$

که،

$$P(V, \theta) - P_G + P_D = 0 \quad (16-ب)$$

$$Q(V, \theta) - Q_G + Q_D = 0 \quad (16-ج)$$

$$\underline{P}_G \leq P_G \leq \bar{P}_G \quad (16-د)$$

$$\underline{Q}_G \leq Q_G \leq \bar{Q}_G \quad (16-ه)$$

$$\underline{V} \leq V \leq \bar{V} \quad (16-g)$$

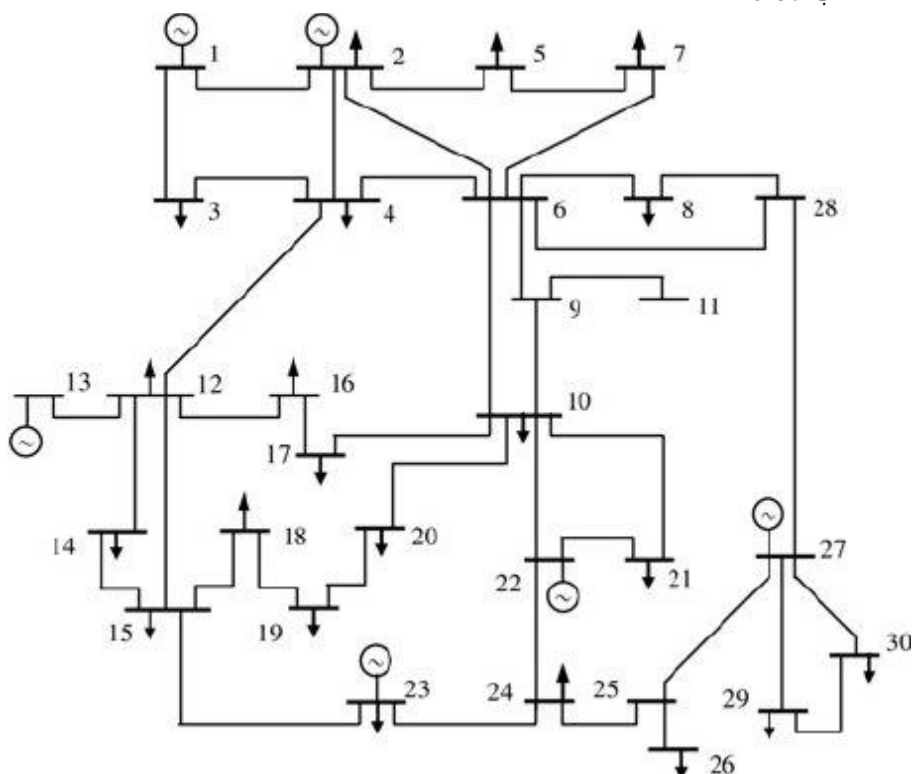
$$\underline{S}_{ij} \leq S_{ij} \leq \bar{S}_{ij} \quad (16-r)$$

که رابطه (۱۶-الف)، مجموع هزینه‌های تولیدی و تلفات توان است. روابط (۱۶-ب) و (۱۶-ج) مجموع معادلات تعادل توان در شین‌های سیستم و روابط (۱۶-د) و (۱۶-ه) حدود تولید توان‌های اکتیو و راکتیو شین‌های تولیدی است. رابطه (۱۶-و) محدودیت دامنه ولتاژ شین‌ها و رابطه (۱۶-ر) محدودیت توان عبوری از خطوط انتقال است.

روش انجام آزمایش

روش پیشنهادی روی سیستم ۳۰ شینه استاندارد IEEE شکل ۳ [۲۷] در محیط نرم‌افزار متلب با سیستمی کامپیوتری با مشخصات زیر اجرا شده است:

- پردازنده: Intel core i5 @ 3GHz
- 8GB :RAM
- سیستم عامل: ویندوز ۸
- نسخه متلب: 2013b



شکل ۳. نمودار تک خطی سیستم ۳۰ شینه استاندارد IEEE.

این سیستم آزمایشی دارای ۶ شین ژنراتوری با شماره‌های ۱، ۲، ۱۳، ۲۲، ۲۳ و ۲۷ و تعداد ۲۴ شین بار است. در ابتداء، کارایی روش پیشنهادی در این مقاله، با روش‌های معمول از قبیل برنامه‌ریزی تکاملی (EP)، الگوریتم ژنتیک (GA) و الگوریتم PSO مقایسه شده است. این روش‌ها اغلب به عنوان اکتشافی تکاملی شناخته می‌شوند و از آنها برای جانمایی بهینه DGها در شبکه‌های توزیع استفاده می‌شود.

نتایج شبیه‌سازی و بحث

نتایج شبیه‌سازی برای جانمایی DG

در تمامی روش‌های EP، GA، PSO و پیشنهادی (روش مبتنی بر ICS)، منبع تولید پراکنده DG با مشخصات جدول ۱ برای جانمایی انتخاب می‌گردد. نتیجه جانمایی‌های بهینه این DG به کمک روش‌های مذکور در جدول ۲ لیست شده است. مشخصات ولتاژ و تلفات توان در سیستم ۳۰ شینه استاندارد IEEE با و بدون نصب DG در شکل‌های ۴ و ۵ آورده شده است. نتایج نشان می‌دهند که رویکرد پیشنهادی از نظر بهره‌وری بهتر از رویکردهای قبلی است. با توجه به شکل‌های ۴ و ۵، قبل از نصب DG، تلفات برق کلی ۰،۰۹ کیلووات و پروفیل ولتاژ ۲۲۰ کیلوولت است. پس از نصب DG، تلفات توان کل به ۰،۰۷۷۸ کیلووات توسط EP، 0.05 کیلووات توسط GA، 0.04 کیلووات توسط PSO، و ۰،۰۳۰۱ کیلووات توسط روش پیشنهادی مبتنی بر ICS می‌گردد. به علاوه، پروفیل ولتاژ کل ۲۴۵ کیلوولت توسط EP، 290 کیلوولت توسط GA، 300 کیلوولت توسط PSO و ۳۰۷ کیلوولت توسط روش پیشنهادی مبتنی بر ICS می‌گردد. بنابراین، روش پیشنهادی به‌طور بالقوه کارایی سیستم توزیع را از طریق بهبود پایداری کلی ولتاژ و همچنین کاهش تلفات توان افزایش می‌دهد زیرا به کمک روش پیشنهادی، تلفات توان کل حداقل و پروفیل ولتاژ کل حداکثر می‌گردد.

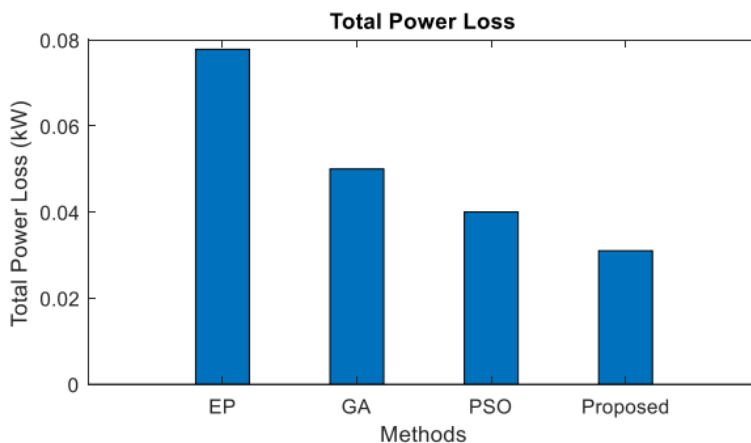
جدول ۱. مشخصات فنی DG مورد استفاده

پارامتر	مقدار
حد توان اکتیو DG (MW)	2
ضریب قدرت DG	0.87
حد ولتاژ (pu)	0.98
حد بارگذاری خط (%)	81
محدودیت ظرفیت قطع اتصال کوتاه (%)	84
حد اتصال کوتاه در PCC (%)	24
ظرفیت قطع اتصال کوتاه (KA)	25

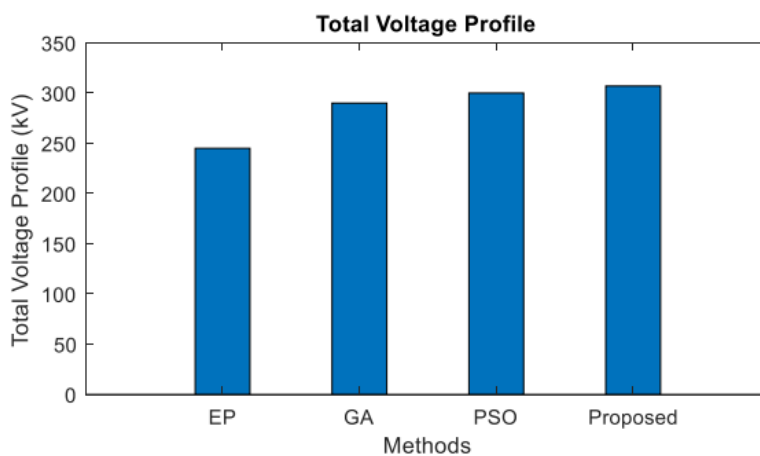
جدول ۲. جانمایی‌های بهینه DG همراه با پروفیل ولتاژ و تلفات

روش	شین کاندیدا	تلفات توان کل (KW)	پروفیل ولتاژ کل (kV)	جمعیت	تکرار	زمان اجرا (S)
EP	9	0.0778	245	۴۰	۸۰	۳۹۶
GA	18	0.05	290	۴۰	۸۰	۳۷۶
PSO	4	0.04	300	۴۰	۸۰	۳۴۰
روش پیشنهادی مبتنی بر ICS	26	0.0301	307	۴۰	۸۰	۳۱۲

1. Evolutionary programming

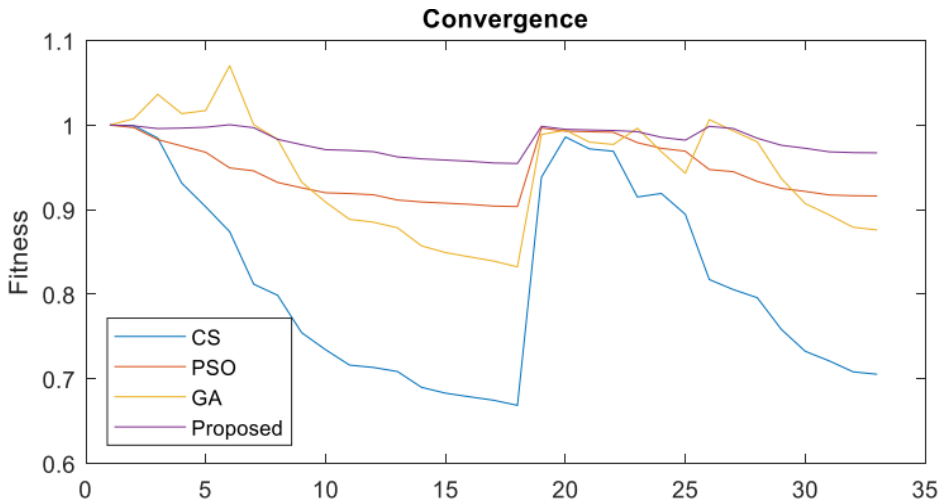


شکل ۴. کل تلفات توان سیستم در روش‌های مختلف



شکل ۵. پروفیل ولتاژ کل سیستم در روش‌های مختلف.

شکل ۶ قابلیت همگرایی الگوریتم پیشنهادی مبتنی بر ICS برای جانمایی بهینه DG در مقایسه با سایر روش‌ها را نشان می‌دهد. این منحنی‌ها به‌وضوح نشان می‌دهند که روش پیشنهادی در مقایسه با سایر روش‌ها مؤثرتر عمل می‌کند.



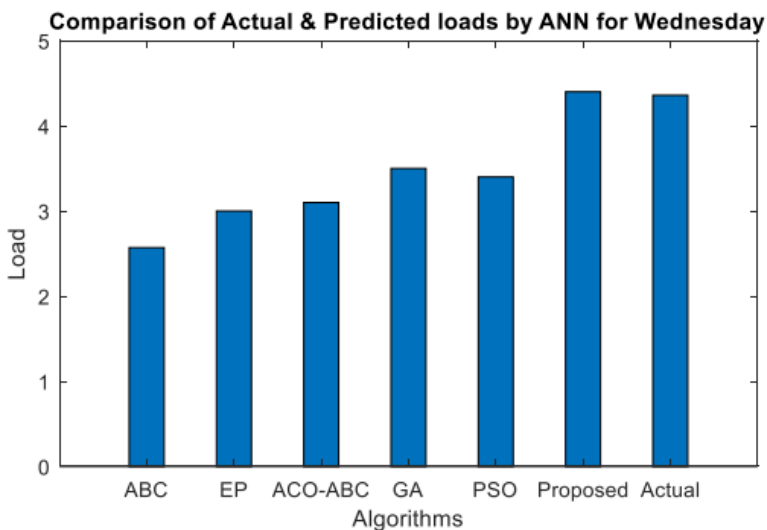
شکل ۶. مقایسه همگرایی روش‌های مختلف

نتایج شبیه‌سازی برای پیش‌بینی تقاضای بار

کیفیت پیش‌بینی بار بر مبنای اطلاعات نمونه‌ای که شامل روزهای هفته، تقاضای در ساعت (یعنی ۲۴ بار در روز)، اطلاعات آب و هوای قبلی و همچنین پیش‌بینی‌شده در طول دو سال ارزیابی می‌شود. در روش پیشنهادی مبتنی بر ICS، از ANN و k-means استفاده شده است، به طوری که داده‌های اولیه خوشه‌بندی و سپس طبقه‌بندی می‌شوند. با در نظر گرفتن یکشنبه‌ها به عنوان روز تعطیل و چهارشنبه‌ها به عنوان روز وسط هفته، بار الکتریکی مورد نیاز در روز چهارشنبه اغلب در مقایسه با یکشنبه بیشتر است. در نتیجه، در تحقیق ما، پیش‌بینی بار برای چهارشنبه و یکشنبه در جداول ۳ و ۴ و شکل‌های ۷ و ۸ نشان داده شده است بنابراین، بار پیش‌بینی‌شده توسط روش ICS به بار واقعی نزدیک‌تر است اما بار برآوردشده توسط سایر روش‌ها مانند EP، GA و همچنین PSO نسبت به بار واقعی اختلاف قابل توجهی دارد. پس، روش پیشنهادی نسبت به سایر روش‌های موجود، برتری قابل توجهی دارد.

جدول ۳. مقایسه روش‌های پیش‌بینی بار در پیش‌بینی بار چهارشنبه‌ها

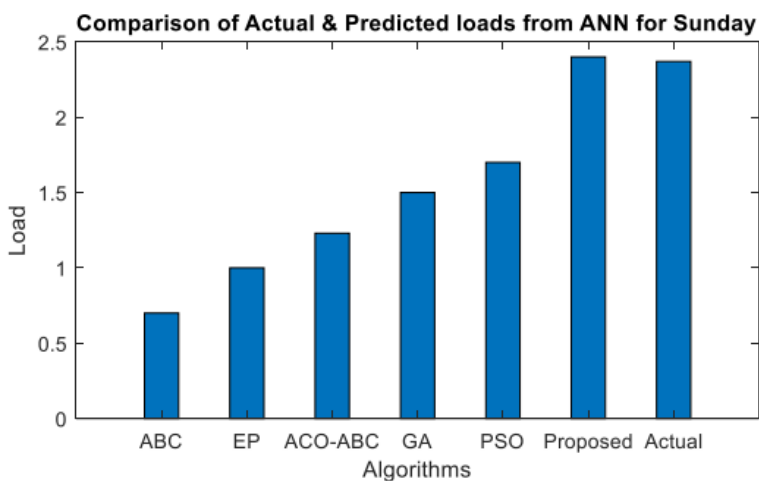
روش پیش‌بینی	بار	خطای پیش‌بینی (%)
ABC	2.57	- 41
EP	3	- 31
ECO-ABC	3.1	- 29
GA	3.5	- 20
PSO	3.4	- 22
روش پیشنهادی مبتنی بر ICS	4.4	1
بار واقعی	4.36	-



شکل ۷. مقایسه روش‌های پیش‌بینی بار در پیش‌بینی بار چهارشنبه‌ها

جدول ۴. مقایسه روش‌های پیش‌بینی بار در پیش‌بینی بار یکشنبه‌ها

خطای پیش‌بینی (%)	بار	روش پیش‌بینی
۷۰-	0.7	ABC
۵۸-	1	EP
۴۸-	1.23	ECO-ABC
۳۷-	1.5	GA
۵۶-	1.7	PSO
1	2.4	روش پیشنهادی مبتنی بر ICS
-	2.37	بار واقعی



شکل ۸. مقایسه روش‌های پیش‌بینی بار در پیش‌بینی بار یکشنبه‌ها.

به‌طور خلاصه، نتایج شبیه‌سازی‌های فوق نشان می‌دهند که:

- روش خوشه‌بندی k-means ترکیبی با ANN بر اساس بهینه‌سازی ازدحام ذرات با دقت خیلی بیشتری بار روزانه سیستم را پیش‌بینی می‌کند و خطای پیش‌بینی بار با این روش پیشنهادی به مراتب کمتر (حدود ۱ درصد) از روش‌های مرسوم مانند EP (۵۸ درصد)، GA (۳۷ درصد) و PSO (۵۶ درصد) است.
- روش پیشنهادی مبتنی بر ICS کارایی بیشتری در جانمایی بهینه منابع DG به‌منظور بهبود کارایی شبکه توزیع انرژی را دارد به‌گونه‌ای که در مقایسه با روش‌های مرسوم مانند EP، GA و PSO، در روش پیشنهادی، تلفات توان کل سیستم کمترین (۰.۳۰۱ MW) و پروفیل ولتاژ کل سیستم بیشترین (۳۰۷ kV) مقدار می‌گردد.
- قابلیت همگرایی روش پیشنهادی مبتنی بر ICS بهتر از روش‌های مرسوم EP، GA و PSO می‌باشد.
- زمان اجرای روش پیشنهادی مبتنی بر ICS حداقل و برابر ۳۱۲ S است. این زمان برای روش‌های EP، GA و PSO به‌ترتیب ۳۹۶ S، ۳۷۶ S و ۳۴۰ S است.

نتیجه‌گیری

در این مقاله، یک روش پیشنهادی مبتنی بر ICS برای بهبود عملکرد شبکه توزیع برق با جانمایی بهینه تولیدات پراکنده ارائه گردید. در ابتدا، از خوشه‌بندی k-means ترکیبی با ANN بر اساس بهینه‌سازی ازدحام ذرات برای پیش‌بینی بار استفاده شد. از سیستم ۳۰ شینه استاندارد IEEE برای آزمایش روش پیشنهادی استفاده گردید. روش پیشنهادی با دقت بسیار بیشتری بار روزانه سیستم را پیش‌بینی می‌کند و خطای پیش‌بینی بار با روش پیشنهادی به مراتب کمتر (حدود ۱ درصد) از روش‌های مرسوم مانند EP (۵۸ درصد)، GA (۳۷ درصد) و PSO (۵۶ درصد) بود. روش پیشنهادی کارایی بیشتری نیز در جانمایی بهینه منابع DG به‌منظور بهبود کارایی شبکه توزیع را دارد به‌گونه‌ای که در مقایسه با روش‌های مرسوم مانند EP، GA و PSO، در روش پیشنهادی، تلفات توان کل سیستم کمترین (۰.۳۰۱ MW) و پروفیل ولتاژ کل سیستم بیشترین (۳۰۷ kV) مقدار می‌گردد. همچنین، قابلیت همگرایی روش پیشنهادی بهتر از سایر روش‌های مذکور می‌باشد و سرعت اجرای روش پیشنهادی بیشتر از سایر روش‌ها است. این نتایج آزمایش نشان می‌دهد که روش پیشنهادی مبتنی بر ICS راه‌حل مناسب‌تری برای بهبود کارایی سیستم‌های توزیع انرژی با جانمایی بهینه تولیدات پراکنده است. این روش قابلیت اجرا در سایر سیستم‌های واقعی را دارد.

References

- [1] S. Abbasi and H. Abdi, "Multiobjective transmission expansion planning problem based on ACOPF considering load and wind power generation uncertainties," *International Transactions on Electrical Energy Systems*, vol. 27, no. 6, p. e2312, 2017, doi: <https://doi.org/10.1002/etep.2312>.
- [2] S. Abbasi, H. Abdi, S. Bruno, and M. La Scala, "Transmission network expansion planning considering load correlation using unscented transformation," *International Journal of Electrical Power & Energy Systems*, vol. 103, pp. 12-20, 2018, doi: <https://doi.org/10.1016/j.ijepes.2018.05.024>.
- [3] A. Khodadadi, T. Abedinzadeh, H. Alipour, and J. Pouladi, "Multi-objective Operation Planning for a Distribution Network to Improve Economic Parameters and Network Resilience Considering Weather Conditions," *Karafan Quarterly Scientific Journal*, vol. 19, no. 3, pp. 305-331, 2022, doi: <https://doi.org/10.48301/kssa.2022.346042.2144>.

- [4] M. A. Nezhadpashaki, F. Karbalaeei, and S. Abbasi, "Optimal placement and sizing of distributed generation with small signal stability constraint," *Sustainable Energy, Grids and Networks*, vol. 23, p. 100380, 2020, doi: <https://doi.org/10.1016/j.segan.2020.100380>.
- [5] D. Singh, R. K. Misra, and D. Singh, "Effect of load models in distributed generation planning," *IEEE Transactions on Power Systems*, vol. 22, no. 4, pp. 2204-2212, 2007, doi: <https://doi.org/10.1109/TPWRS.2007.907582>.
- [6] A. Piccolo and P. Siano, "Evaluating the impact of network investment deferral on distributed generation expansion," *IEEE Transactions on Power Systems*, vol. 24, no. 3, pp. 1559-1567, 2009, doi: <https://doi.org/10.1109/TPWRS.2009.2022973>.
- [7] H. Alimohamadi, R. Zeinali Davarani, and M. Shafiee, "Investigating the Feasibility of Increasing the Participation of Solar Power Plants in Supplying Load during the Peak Hours of the Day," *Karafan Quarterly Scientific Journal*, vol. 20, no. 1, pp. 13-30, 2023, doi: <https://doi.org/10.48301/kssa.2023.365108.2313>.
- [8] F. Askari, "Assessment of the Impact of Distributed Generation and Distribution Network Faults on Generation Reliability Indices," *Karafan Journal*, vol. 18, no. 3, pp. 13-33, 2021, doi: <https://doi.org/10.48301/kssa.2021.277262.1427>.
- [9] R. K. Singh and S. Goswami, "Optimum allocation of distributed generations based on nodal pricing for profit, loss reduction, and voltage improvement including voltage rise issue," *International journal of electrical power & energy systems*, vol. 32, no. 6, pp. 637-644, 2010, doi: <https://doi.org/10.1016/j.ijepes.2009.11.021>.
- [10] D. Q. Hung, N. Mithulananthan, and R. Bansal, "Analytical expressions for DG allocation in primary distribution networks," *IEEE Transactions on energy conversion*, vol. 25, no. 3, pp. 814-820, 2010, doi: <https://doi.org/10.1109/TEC.2010.2044414>.
- [11] P. Järventausta, S. Repo, A. Rautiainen, and J. Partanen, "Smart grid power system control in distributed generation environment," *Annual Reviews in Control*, vol. 34, no. 2, pp. 277-286, 2010, doi: <https://doi.org/10.1016/j.arcontrol.2010.08.005>.
- [12] M. Gandomkar, M. Vakilian, and M. Ehsan, "A combination of genetic algorithm and simulated annealing for optimal DG allocation in distribution networks," in *Canadian Conference on Electrical and Computer Engineering, 2005.*, 2005: Ieee, pp. 645-648, doi: <https://doi.org/10.1109/CCECE.2005.1557013>.
- [13] D. Zhu, R. P. Broadwater, K.-S. Tam, R. Seguin, and H. Asgeirsson, "Impact of DG placement on reliability and efficiency with time-varying loads," *IEEE Transactions on Power Systems*, vol. 21, no. 1, pp. 419-427, 2006, doi: <https://doi.org/10.1109/TPWRS.2005.860943>.
- [14] M. P. Lalitha, V. V. Reddy, and V. Usha, "OPTIMAL DG PLACEMENT FOR MINIMUM REAL POWER LOSS IN RADIAL DISTRIBUTION SYSTEMS USING PSO," *Journal of Theoretical & Applied Information Technology*, vol. 13, 2010, doi: <https://doi.org/10.1109/App.2010.2043411>.
- [15] W. El-Khattam, Y. Hegazy, and M. Salama, "An integrated distributed generation optimization model for distribution system planning," *IEEE Transactions on power systems*, vol. 20, no. 2, pp. 1158-1165, 2005, doi: <https://doi.org/10.1109/TPWRS.2005.846114>.
- [16] G. P. Harrison, A. Piccolo, P. Siano, and A. R. Wallace, "Hybrid GA and OPF evaluation of network capacity for distributed generation connections," *Electric Power Systems Research*, vol. 78, no. 3, pp. 392-398, 2008, doi: <https://doi.org/10.1016/j.eprsr.2007.03.008>.

- [17] D. Singh, D. Singh, and K. Verma, "Multiobjective optimization for DG planning with load models," *IEEE transactions on power systems*, vol. 24, no. 1, pp. 427-436, 2009, doi: <https://doi.org/10.1109/TPWRS.2008.2009483>.
- [18] A. Soroudi and M. Afrasiab, "Binary PSO-based dynamic multi-objective model for distributed generation planning under uncertainty," *IET renewable power generation*, vol. 6, no. 2, pp. 67-78, 2012, doi: <https://doi.org/10.1049/iet-rpg.2011.0028>.
- [19] M. M. Elnashar, R. El Shatshat, and M. M. Salama, "Optimum siting and sizing of a large distributed generator in a mesh connected system," *Electric Power Systems Research*, vol. 80, no. 6, pp. 690-697, 2010, doi: <https://doi.org/10.1016/j.epr.2009.10.034>.
- [20] H. Hedayati, S. Nabaviniaki, Akbarimajd, and A. Akbarimajd, "A method for placement of DG units in distribution networks," *IEEE transactions on power delivery*, vol. 23, no. 3, pp. 1620-1628, 2008, doi: <https://doi.org/10.1109/TPWRD.2007.916106>.
- [21] S. Fan and L. Chen, "Short-term load forecasting based on an adaptive hybrid method," *IEEE Transactions on Power Systems*, vol. 21, no. 1, pp. 392-401, 2006, doi: <https://doi.org/10.1109/TPWRS.2005.860944>.
- [22] D. Xinhui, W. Liang, S. Jiancheng, and Z. Yan, "Application of neural network and support vector machines to power system short-term load forecasting," in *2010 International Conference on Computational Aspects of Social Networks*, 2010: IEEE, pp. 729-732, doi: <https://doi.org/10.1109/CASoN.2010.167>.
- [23] J. Yin, L. Huo, L. Guo, and J. Hu, "Short-term load forecasting based on improved gene expression programming," in *2008 7th World Congress on Intelligent Control and Automation*, 2008: IEEE, pp. 5647-5650, doi: <https://doi.org/10.1109/WCICA.2008.4593850>.
- [24] M. Gitizadeh, A. A. Vahed, and J. Aghaei, "Multistage distribution system expansion planning considering distributed generation using hybrid evolutionary algorithms," *Applied energy*, vol. 101, pp. 655-666, 2013, doi: <https://doi.org/10.1016/j.apenergy.2012.07.010>.
- [25] D. Q. Hung and N. Mithulananthan, "Multiple distributed generator placement in primary distribution networks for loss reduction," *IEEE Transactions on industrial electronics*, vol. 60, no. 4, pp. 1700-1708, 2011, doi: <https://doi.org/10.1109/TIE.2011.2112316>.
- [26] K. Nekooei, M. M. Farsangi, H. Nezamabadi-Pour, and K. Y. Lee, "An improved multi-objective harmony search for optimal placement of DGs in distribution systems," *IEEE Transactions on smart grid*, vol. 4, no. 1, pp. 557-567, 2013, doi: <https://doi.org/10.1109/TSG.2012.2237420>.
- [27] M. Kowsalya, "Optimal size and siting of multiple distributed generators in distribution system using bacterial foraging optimization," *Swarm and Evolutionary computation*, vol. 15, pp. 58-65, 2014, doi: <https://doi.org/10.1016/j.swevo.2013.12.001>.
- [28] W. Sheng, K.-Y. Liu, Y. Liu, X. Meng, and Y. Li, "Optimal placement and sizing of distributed generation via an improved nondominated sorting genetic algorithm II," *IEEE Transactions on power Delivery*, vol. 30, no. 2, pp. 569-578, 2014, doi: <https://doi.org/10.1109/TPWRD.2014.2325938>.
- [29] S. Katoch, S. S. Chauhan, and V. Kumar, "A review on genetic algorithm: past, present, and future," *Multimedia tools and applications*, vol. 80, no. 5, pp. 8091-8126, 2021, doi: <https://doi.org/10.1109/APP.2021.2244567>.

- [30] A. G. Gad, "Particle swarm optimization algorithm and its applications: A systematic review," *Archives of computational methods in engineering*, vol. 29, no. 5, 2022, doi: <https://doi.org/10.1007/s11831-021-09694-4>.
- [31] A. S. Joshi, O. Kulkarni, G. M. Kakandikar, and V. M. Nandedkar, "Cuckoo search optimization-a review," *Materials Today: Proceedings*, vol. 4, no. 8, pp. 7262-7269, 2017, doi: <https://doi.org/10.1016/j.matpr.2017.07.055>.
- [32] F. Karbalaee and S. Abasi, "Quick and accurate computation of voltage stability Margin," *Journal of Electrical Engineering & Technology*, vol. 11, no. 1, pp. 1-8, 2016, doi: <https://doi.org/10.1016/JAKO.2016.12.454993.211>.
- [33] B. Genêt and J.-C. Maun, "Voltage-stability monitoring using wide-area measurement systems," in *2007 IEEE Lausanne Power Tech*, 2007: IEEE, pp. 1712-1717, doi: <https://doi.org/10.1109/PCT.2007.4538573>.
- [34] F. Karbalaee and S. Abbasi, "L-index based contingency filtering for voltage stability constrained reactive power planning," *Turkish Journal of Electrical Engineering and Computer Sciences*, vol. 26, no. 6, pp. 3156-3167, 2018, doi: <https://doi.org/10.3906/elk-1805-11>.
- [35] L. Zhang, Y. Yu, Y. Luo, and S. Zhang, "Improved cuckoo search algorithm and its application to permutation flow shop scheduling problem," *Journal of Algorithms & Computational Technology*, vol. 14, p. 1748302620962403, 2020, doi: <https://doi.org/10.1177/1748302620962403>.
- [36] T. M. Kodinariya and P. R. Makwana, "Review on determining number of Cluster in K-Means Clustering," *International Journal*, vol. 1, no. 6, pp. 90-95, 2013, doi: <https://doi.org/10.1144/int-2013-11>.
- [37] "Dabbagchi, I., & Christie, R. (1993, August). 30 Bus Power Flow Test Case. Power Systems Test Case Archive. University of Washington. Retrieved from " http://www.ee.washington.edu/research/pstca/pf30/pg_tca30bus.htm. (accessed).