

# NUFJ


NARESUAN

UNIVERSITY ENGINEERING JOURNAL

January-June 2025 Vol.20, No.1

ISSN : 2651-1568

Faculty of Engineering, Naresuan



## Editorial Team

### Editorial Advisory Board

Prof. Dr. Somchai Wongwises	Faculty of Engineering, King Mongkut's University of Technology Thonburi
Assoc. Prof. Dr. Sarintip Tantane	President of Naresuan University
Assoc. Prof. Dr. Uraya Weesakul	Faculty of Engineering, Thammasat University
Asst. Prof. Dr. Kumpon Subsomboon	Faculty of Engineering, Naresuan University

### Editor-in-Chief

Asst. Prof. Dr. Ananchai U-kaew	Faculty of Engineering, Naresuan University
---------------------------------	---

### Associate Editor

Assoc. Prof. Dr. Thawatchai Mayteevarunyoo	Faculty of Engineering, Naresuan University
Asst. Prof. Dr. Korakod Nusit	Faculty of Engineering, Naresuan University
Asst. Prof. Dr. Jirawadee Polprasert	Faculty of Engineering, Naresuan University

### Editorial Board

Prof. Dr. Kosin Chamnongthai	Faculty of Engineering, King Mongkut's University of Technology Thonburi
Prof. Dr. Juntaraporn Palagongun	Faculty of Engineering, King Mongkut's University of Technology North Bangkok
Prof. Dr. Pradit Terdtoon	Faculty of Engineering, Chiang Mai University
Prof. Dr. Songphol Kanjanachuchai	Faculty of Engineering, Chulalongkorn University
Prof. Dr. Puangrat Kajitvichyanukul	Faculty of Engineering, Chiang Mai University
Prof. Dr. Paisarn Muneesawang	Faculty of Engineering, Naresuan University
Prof. Dr. Wanida Jinsart	Faculty of Science, Chulalongkorn University
Prof. Dr. Vatanavongs Ratanavaraha	Institute of Engineering, Suranaree University of Technology
Prof. Dr. Virote Boonamnuyvitaya	Faculty of Engineering, King Mongkut's University of Technology Thonburi
Prof. Dr. Sampan Rittidej	Faculty of Engineering, Mahasarakham University
Prof. Dr. Sumrerng Jugjai	Faculty of Engineering, King Mongkut's University of Technology Thonburi
Prof. Dr. Apinunt Thanachayanont	Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang
Prof. Dr. Issarachai Ngamroo	Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang

## Editorial Board

Prof. Christian Hicks

Assoc. Prof. Dr. Kamchai Nuithitikul

Assoc. Prof. Dr. Koonlaya Kanokjaruvijit

Assoc. Prof. Dr. Chalermraj Wantawin

Assoc. Prof. Dr. Tanyada Pannachet

Assoc. Prof. Dr. Nipon Theeraumpon

Assoc. Prof. Dr. Ninlawan Choomrit

Assoc. Prof. Dr. Nivit Charoenchai

Assoc. Prof. Dr. Panus Nattharith

Assoc. Prof. Dr. P pong Pongcharoen

Assoc. Prof. Dr. Mathanee Sanguansermisri

Assoc. Prof. Dr. Yodchanan Wongsawat

Assoc. Prof. Dr. Lunchakorn Wuttisittikulki

Assoc. Prof. Dr. Watcharin Pongaen

Assoc. Prof. Dr. Wassanai Wattanutchariya,

Assoc. Prof. Dr. Virasit Imtawil

Assoc. Prof. Sanguan Patamatamkul

Assoc. Prof. Dr. Sdhabhon Bhokha

Assoc. Prof. Dr. Sombat Chuenhooklin

Assoc. Prof. Dr. Samorn Hirunpraditkoon

Assoc. Prof. Dr. Suchart Yammen

Assoc. Prof. Dr. Suwit Kiravittaya

Assoc. Prof. Dr. Athikom Roeksabutr

Assoc. Prof. Dr. Apichai Ritvirool

Assoc. Prof. Maetee Boonpichetvong

Assoc. Prof. Dr. Vo Ngoc Dieu

Asst. Prof. Dr. Kaokanya Sudaprasert

Asst. Prof. Dr. Tanikan Thongchai

Asst. Prof. Dr. Narumon Seeponkai

Asst. Prof. Dr. Pajaree Thongsanit

Asst. Prof. Dr. Panu Buranajakorn

Asst. Prof. Dr. Supawan Ponpitakchai

Asst. Prof. Dr. Somlak Wannarumon Kienlarova

Newcastle University, United Kingdom

Faculty of Engineering, Walailak University

Faculty of Engineering, Naresuan University

Faculty of Engineering, King Mongkut's

University of Technology Thonburi

Faculty of Engineering, Khon Kaen University

Faculty of Engineering, Chiang Mai University

Faculty of Engineering, Srinakharinwirot University

Faculty of Engineering, Chiang Mai University

Faculty of Engineering, Naresuan University

Faculty of Engineering, Naresuan University

Faculty of Engineering, Naresuan University

Faculty of Engineering, Mahidol University

Faculty of Engineering, Chulalongkorn University

Department of Teacher Training in Mechanical

Engineering, King Mongkut's

University of Technology North Bangkok

Faculty of Engineering, Chiang Mai University

Faculty of Engineering, Khon Kaen University

Faculty of Engineering, Khon Kaen University

Faculty of Engineering, Ubon Ratchathani

Faculty of Engineering, Naresuan University

Faculty of Engineering, Naresuan University

Faculty of Engineering, Naresuan University

Faculty of Engineering, Chulalongkorn University

Faculty of Engineering, Mahanakorn University of

Technology

Faculty of Engineering, Naresuan University

Faculty of Engineering, Khon Kaen University

Ho Chi Minh City University of

Faculty of Engineering, King Mongkut's

University of Technology Thonburi

Faculty of Engineering, Naresuan University

Faculty of Engineering, Naresuan University

Faculty of Engineering, Naresuan University

Faculty of Engineering, Naresuan University

Faculty of Engineering, Naresuan University

Faculty of Engineering, Naresuan University

## Editorial Board

Asst. Prof. Dr. Sasikorn Leungvichcharoen	Faculty of Engineering, Naresuan University
Asst. Prof.Dr. Sutanit Puttapanom	Faculty of Engineering, Naresuan University
Dr. Salisa Veerapun	Faculty of Engineering, Naresuan University
Dr. Ivan Lee	School of Information Technology and Mathematical Sciences, University of South Australia, Australia
Dr. Sasidharan Sreedharan	University of Hawaii, USA

## **Aims and Objectives**

The primary objective of the Naresuan University Engineering Journal (NUEJ) is to publish high-quality research articles presenting contemporary developments in theory, design, and applications in all areas of Engineering, Science, and Technology, including research in Civil, Environmental, Mechanical, Electrical, Computer, Industrial, Chemical, and Material Engineerings. NUEJ covers all multidisciplinary research in associated areas, such as Mechatronics, Energy, Industrial and Engineering Design, Manufacturing Technology, Engineering Management, and Medical Engineering.

## **Journal Policies**

Naresuan University Engineering Journal (NUEJ) is open access system which uses Double-blind peer review journal, According to broaden the Engineering and Technology develop the NUEJ has for Thai society and global. “No Charge policy of any publication fee”, regularly published with 2 issues per year (January – June, and July – December). Submissions must be original, unpublished works, and not currently under review by other journals. NUEJ will consider only submitted works which respect research ethics, including confidentiality, consent, and the special requirements for human and animal research. All research articles dealing with human or animal subjects must attach an approval certificate from the appropriate Ethics Committee. Additionally, the research articles dealing with human subjects must provide evidence of informed consent

Editorial board of NUEJ reserves the right to decide whether the submitted manuscript should be accepted for publication. The final decision of the editorial board cannot be appealed.

The submitted manuscript has to be written in English only, and can be in Microsoft Word (doc or docx) or PDF file format. The corresponding author is required to register and submit the manuscript at <https://ph01.tci-thaijo.org/index.php/nuej>

ISSN : 2651-1568 (Online)

Electronic journal Has been service since issue number 13, issue 2, July - December 2018 henceforward

Editorial board of Naresuan University Engineering Journal (NUEJ)  
Faculty of Engineering, Naresuan University  
Phitsanuloke, 65000 Thailand  
Tel. +66(0)55 963951  
Fax. +66(0)55 964000  
Email: [nuej@nu.ac.th](mailto:nuej@nu.ac.th)

## **Editor's Note**

### **Editorial: Advancing Engineering for Entrepreneurial Society**

#### **Greetings to all our readers,**

As the editor of the academic journal of the Faculty of Engineering, Naresuan University, I am delighted to present the latest issue of our journal, which serves as a vital platform for the exchange of knowledge and experiences in the ever-evolving and forward-moving field of engineering.

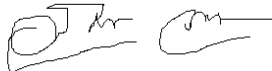
In this issue, we have compiled research articles that are both challenging and exciting. They reflect not only the advancements in various engineering disciplines but also the pursuit of sustainable and environmentally responsible methods. From the development of new materials to the application of advanced technologies in solving engineering problems, this issue covers a broad spectrum.

We also emphasize supporting new researchers by providing opportunities for them to publish high-quality work that presents new directions in the field of engineering. These works are not only valuable sources of information for academics but also an inspiration for the next generation of researchers.

The connection to society and industry is equally important. Hence, our journal is not just an academic forum but also a bridge linking engineering knowledge to its real-world applications.

Finally, I would like to express my gratitude to our editorial team, peer reviewers, and all members who contribute to the creation and maintenance of the quality of this journal. It is our hope that our journal will continue to be a source of high-quality knowledge and benefit the field of engineering and entrepreneurial society

With respect,



[Assist Prof. Dr. Ananchai Ukaew]  
Editor, Academic Journal of the Faculty of Engineering  
Naresuan University Engineering Journal

## Research Articles

### Enhancing Flood Susceptibility Mapping using Statistical and Machine Learning Approaches: A Case Study of the Wang River Basin, Thailand

*Gen Long, Sarintip Tantanee,, Korakod Nusit and Pitikhate Sooraksad.....1*

### Concrete Mix Design Based on Spherical Shape Concept

*Parnuhmesr Sirinananun.....12*

### The Study of Performance and Efficiency in a Solar Photovoltaic System Under Partial Shading

*Sarochoa Deevijit, Phaphat Rattanaklangmueang and Somporn Ruangsinchaiwanich.....21*

# Enhancing Flood Susceptibility Mapping using Statistical and Machine Learning Approaches: A Case Study of the Wang River Basin, Thailand

Gen Long<sup>1</sup>, Sarintip Tantane<sup>2,\*</sup>, Korakod Nusi<sup>3</sup> and Pitikhate Sooraksad<sup>4</sup>

<sup>1,3</sup> Civil of Engineering Department, Faculty of Engineering, Naresuan University, Phitsanulok 65000, Thailand

<sup>2</sup> Center of Excellence on Energy Technology and Environment, Faculty of Engineering, Naresuan University, Phitsanulok 65000, Thailand

<sup>4</sup> Department of Robotics and AI, School of Engineering, King Mongkut's Institute of Technology, Ladkrabang, 1 Chalongkrung 1, Ladkrabang, Bangkok 10520, Thailand

\* Corresponding author e-mail: sarintipt@nu.ac.th

(Received: 2 February 2025, Revised: 20 April 2025, Accepted: 20 April 2025)

## Abstract

In flood-vulnerable regions like the Wang River Basin, Thailand, flood susceptibility mapping (FSM) plays a key role in flood disaster risk management. However, the comparative performance between traditional statistical methods and machine learning (ML) algorithms for FSM under identical conditions has not been thoroughly explored. This research investigates the performance of Shannon's Entropy (SE), a statistical model, and Random Forest (RF), a ML algorithm for the prediction of flood-potential areas. Multicollinearity analysis together with SE-based weighting identified a total of seven significant flood conditioning factors (FCFs) which are curvature, slope, elevation, geology, soil permeability, precipitation, and stream power index (SPI). The models were trained and validated using 3,000 flood and 3,000 non-flood points with a ratio of 70:30. Results showed that the RF model outperformed SE with AUC-ROC values of 0.929 (training) and 0.931 (verification), compared to SE of which are 0.874 and 0.870, indicating the superiority of ML in handling complex environmental data, which can offer advantages in flood risk prediction. This study also presents the promise of ML in enhancing FSM accuracy and confidence, enabling risk mitigation strategies in the Wang River Basin and similar areas.

**Keywords:** Flood susceptibility mapping, Machine learning (ML), Random Forest (RF), Shannon's Entropy (SE), Wang River Basin.

## 1. INTRODUCTION

Floods are one of the most severe natural disasters worldwide, responsible for massive socio-economic losses and environmental losses (Bhattarai et al., 2024). The Wang River Basin in Thailand, a critical tributary of the Chao Phraya River, is subject to frequent flooding driven by climatic and anthropogenic change (Charoenlerkthawin et al., 2021). Extreme events like 2011 floods highlighted an immediate need to develop reliable flood sustainability modelling to undertake mitigating measures. The use of common statistical methods such as SE for FSM remained prevalent due to their relative straightforwardness and interpretability (Haghizadeh et al., 2017). On the other hand, improvements in ML algorithms, especially RF, proved to be superior in their ability to be able to represent non-linearity in complex geospatial data sets (Kaya & Derin, 2023; Seydi et al., 2022).

Numerous recent studies emphasized the superiority of ML-based methods for FSM. For instance, Tehrani et al. (2019) demonstrated that ML models outperform conventional approaches in identifying flood-prone areas by leveraging multi-dimensional environmental variables. Similarly, Bhattarai et al. (2024) highlighted that RF was an efficient tool in assessment of transboundary river

basins with its fast, reliable and efficient capacity. Dey et al. (2024) compared different decision tree-based ML models such RF, Adaptive Boosting (AdaBoost), Gradient Boosting (GdBoost), and Extreme Gradient Boosting (XGBoost) against a classical Frequency Ratio (FR) model. The study results showed all the ML models performed better than the FR model, with the RF model producing an area under the curve (AUC) of 0.85. Furthermore, Wahba et al. (2024) investigated the efficacy of various ML approaches in generating FSMs, finding that artificial neural networks (ANN-MLP) and support vector regression (SVR) were highly accurate, giving AUC values of 95.23% and 95.83%, respectively. Nevertheless, challenges persist for ML, including limited data availability, model interpretability, and regional applicability (Wahba et al., 2024).

To fill these gaps, this study compared SE and RF models in the context of the Wang River Basin. Seven FCFs—validated through multicollinearity checks and SE-based FCF selection and weighting—were adopted to generate high-resolution susceptibility maps. The objectives were threefold: (1) to identify critical FCFs driving flood susceptibility in the study area, (2) to evaluate the predictive accuracy of SE and RF models, and (3) to provide spatially explicit insights for flood risk management. By leveraging recent methodological



innovations and empirical validations, this work contributed to the growing body of literature on ML-driven FSM, offering scalable solutions for flood-prone regions.

## 2. STUDY AREA

The Wang River Basin (Figure 1), located in northern Thailand, is the smallest sub-basin of the Upper Chao Phraya River system, covering approximately 10,800 km<sup>2</sup>. The basin lies between 17°05'N–19°30'N latitude and 98°54'E–99°58'E longitude, originating in the Phi Pan Nam Range and flowing 460 km southward to merge with the Ping River near Tak Province, 30 km downstream of the Bhumibol Dam (Bidorn et al., 2015;

Charoenlerkthawin et al., 2021). The river gradient varies between 1:60 and 1:4,000 (Bidorn et al., 2015).

The basin's land use is primarily forest (73.09%), followed by agricultural land (18.29%), and urban or built-up areas (3.98%) (Raveephinit et al., 2021). The average annual rainfall is 1,100 mm, with 88% occurring during the wet season (May–October) (Bidorn et al., 2015; Raveephinit et al., 2021). Despite its small size, the Wang River Basin is hydrologically significant, sharing sediment and flow characteristics with the neighboring Ping River Basin. Notably, extreme events like the 2011 flood highlighted its vulnerability to sediment transport and flooding (Bidorn et al., 2015).

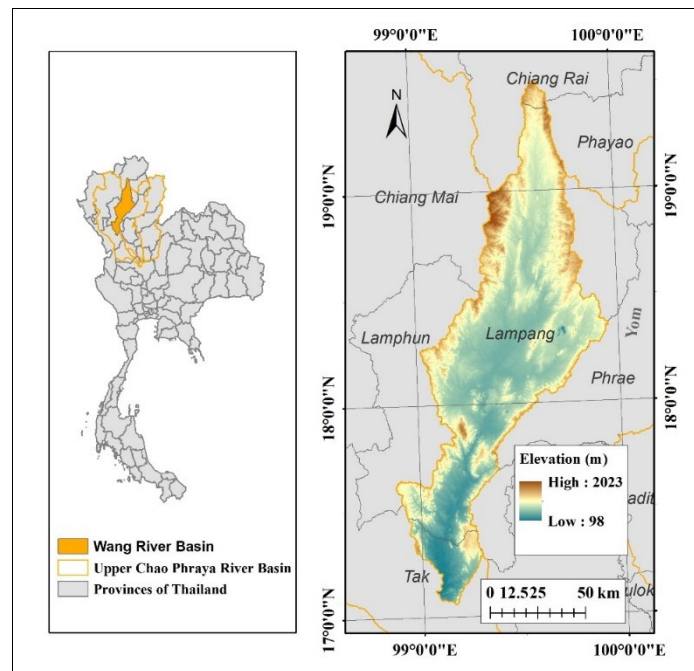


Figure 1 Study area

## 3. METHODOLOGY

As shown in Figure 2. The methodology involved four main steps: Data Preparation, Flood Conditioning Factors Selection, Flood Susceptibility Mapping, and Model Evaluation.

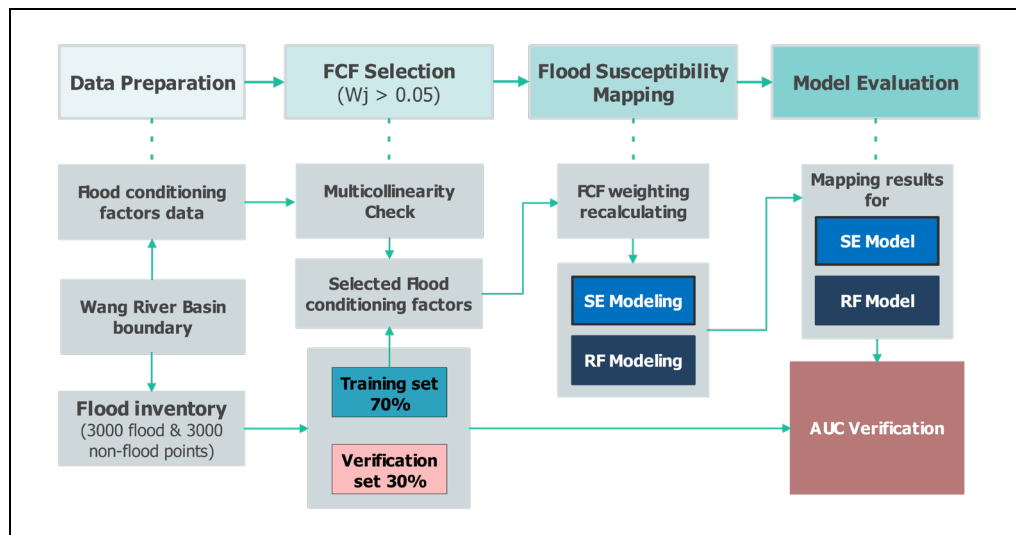
**Data Preparation:** The study began by collecting data on 13 flood conditioning factors, including aspect, curvature, distance from river, elevation, geology, land use/land cover (LULC), NDVI, precipitation, river density, slope, soil permeability, SPI, and TWI. These factors were clipped to the Wang River Basin boundary and were preprocessed into uniform raster formats. Flood inventory data, containing 3,000 flood and 3,000 non-flood points, was divided into a training set (70%) for model development and a verification set (30%) for independent evaluation.

**Flood Conditioning Factors Selection:** A multicollinearity check was performed using Pearson's

correlation coefficient to identify and eliminate redundant factors, ensuring that selected factors are statistically independent. Shannon Entropy was then applied to calculate the weight ( $W_i$ ) of each factor based on its contribution to past flood occurrences. Only factors with  $W_i > 0.05$  were retained for further analysis.

**Flood Susceptibility Mapping:** The selected factors were re-weighted using SE to enhance their contributions. Two modeling approaches were employed to generate flood susceptibility maps: SE modeling and RF modeling.

**Model Evaluation:** The flood susceptibility maps produced by both models were validated using training and verification datasets. Model performance was assessed based on AUC-ROC (Area Under Curve - Receiver Operating Characteristic) metrics, comparing the effectiveness of SE and RF models in predicting flood-prone areas.



**Figure 2** Methodology flowchart

### 3.1 Data preparation

Flood inventory refers to extensive database of historical floods in a region, including locations, extents, and frequencies. Such inventories are key components of FSM since they offer fundamental observations that enable identifying the flood risk areas which can inform subsequent assessment and mitigation (Wahba et al., 2024). In this study, flood inventory data obtained from Thailand's Geo-Informatics and Space Technology Development Agency (GISTDA) portal (<https://disaster.gistda.or.th/flood/repeat>) was adopted, which offers historical flood extents from 2006 to 2022. This dataset was adopted in the study of Long et al. (2025) and was verified to be effective in FSM study. A total of 3000 flood and 3000 non-flood points were randomly sampled from this dataset for developing and validating the flood susceptibility models.

FCFs are environmental factors affecting the frequency and magnitude of flooding events. These

include natural factors (such as the topography of the land and the amount of rainfall) and anthropogenic factors (such as land use and soil permeability). Since FCFs play an important role in the pre-disaster planning process by determining the areas that are more vulnerable to flooding to generate accurate flood susceptibility maps, FCFs should be well understood and assessed (Kaya & Derin, 2023). The examination of these factors allows researchers to analyze the extent to which variables of climate and human impact contribute to flood hazards and therefore implement strategies for flood risk management.

Thirteen commonly adopted FCFs were initially selected in this study: aspect, curvature, distance from river, elevation, geology, land use/land cover (LULC), NDVI, precipitation, river density, slope, soil permeability, SPI, and topographic wetness index (TWI). These FCFs were then tested and screened. The data sources of these FCFs are listed in Table 1.

**Table 1** FCFs data source

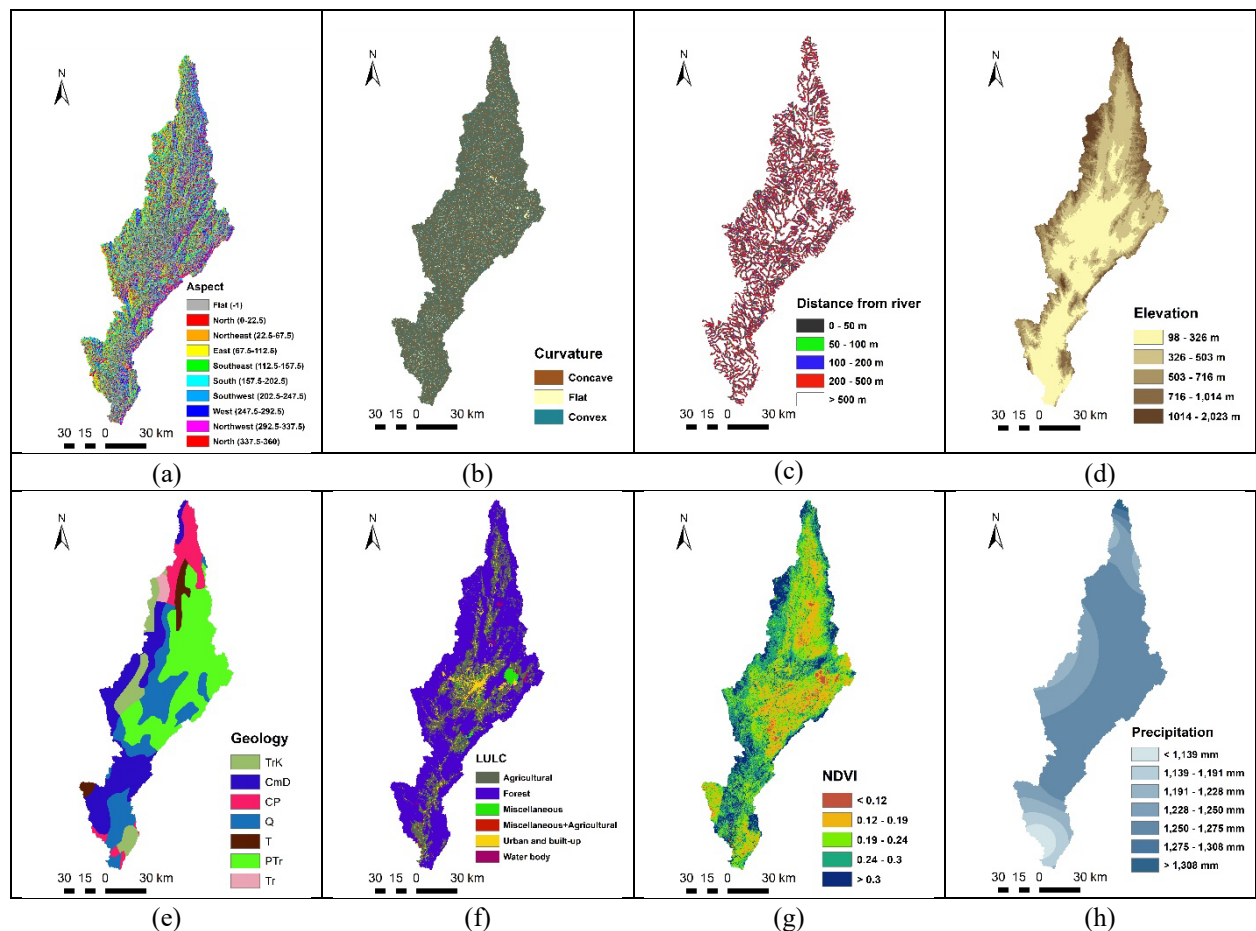
Factor(s)	Data Name	Time	Source	Resolution
Elevation, slope, aspect, curvature, TWI, SPI	SRTM DEM	-	United States Geological Survey (USGS) <a href="https://earthexplorer.usgs.gov/">https://earthexplorer.usgs.gov/</a>	30 m raster
LULC	Land use	2021	LDD <a href="https://tswc.idd.go.th/">https://tswc.idd.go.th/</a>	Vector
Precipitation	Rainfall	1981–2022	Northern Meteorological Center <a href="http://www.cmmet.tmd.go.th/">http://www.cmmet.tmd.go.th/</a>	Vector
Soil permeability	Soil group	2018	Land Development Department (LDD) <a href="https://tswc.idd.go.th/">https://tswc.idd.go.th/</a>	Vector
Distance from river and River density	River	2017	Water Analysis and Assessment Division, Thailand <a href="http://mekhala.dwr.go.th/">http://mekhala.dwr.go.th/</a>	Vector
Geology	Generalized Geology of Southeast Asia	-	USGS <a href="https://certmapper.cr.usgs.gov/data/apps">https://certmapper.cr.usgs.gov/data/apps</a>	Vector
NDVI	Landsat 8 OLI/TIRS Level-2 data	2022	USGS <a href="https://earthexplorer.usgs.gov/">https://earthexplorer.usgs.gov/</a>	30 m raster

The thematic layers for the 13 FCFs are shown in Figure 3, which included aspect (a), curvature (b), distance from the river (c), elevation (d), geology (e), LULC (f), NDVI (g), precipitation (h), river density (i), slope (j), soil permeability (k), SPI (l), and TWI (m). The


vector and raster datasets, obtained as explained in Table 1, were pre-processed to provide consistency over the study area. All of them were homogenized with a spatial resolution of 30 meters so that it can fit into the scale of modeling.

Aspect refers to the direction a slope faces, influencing sunlight exposure and vegetation growth, which can affect runoff patterns. It can modulate water flow direction and accumulation in certain terrains (Al-Kindi & Alabri, 2024). Curvature describes the shape of the terrain, with concave areas more prone to water accumulation and convex areas facilitating runoff. It is a critical morphological factor in flood modeling (Pham et al., 2021). Proximity to rivers is a primary factor in flood susceptibility, as areas closer to rivers are more likely to experience inundation during high-flow events. This factor is often used to define buffer zones for flood risk assessment (Dey et al., 2024). Elevation is a fundamental factor in flood modeling, as low-lying areas are more prone to flooding due to water accumulation. Higher elevations generally reduce flood risk but can influence downstream flow patterns (Riche et al., 2024). Geological composition affects water infiltration and runoff, with impermeable rocks increasing surface runoff and flood risk. Permeable rocks, such as sandstones, reduce flood susceptibility by allowing water infiltration (Gohil et al., 2024). LULC influences hydrological responses, with urban areas increasing impervious surfaces and runoff, while forests and wetlands promote water infiltration and storage. It is a key factor in FSM (Yu et al., 2023). NDVI measures vegetation density, which affects water

retention and runoff. Higher NDVI values indicate denser vegetation, reducing flood risk by enhancing infiltration and slowing surface flow (Rahmati et al., 2020). Precipitation is a direct driver of flooding, with higher rainfall amounts increasing the likelihood of flood events. It is a critical meteorological factor in flood susceptibility modeling (Akay, 2024). River density, defined as the length of drainage lines per unit area, is a key factor in flood susceptibility. Higher river density increases the likelihood of flooding due to greater water concentration (Pham et al., 2021). Slope influences runoff velocity and volume, with steeper slopes leading to faster runoff and increased flood risk downstream. It is a critical topographical factor in flood modeling (Al-Kindi & Alabri, 2024). Soil permeability determines the rate of water infiltration, with low permeability soils increasing surface runoff and flood risk. It is a key hydrological factor in flood susceptibility assessment (Dey et al., 2024). SPI measures the erosive power of flowing water, with higher values indicating greater flood potential. It is a key hydrometric factor in flood susceptibility mapping (Riche et al., 2024). TWI quantifies the tendency of water to accumulate in specific areas based on slope and flow accumulation. It is a critical factor in identifying flood-prone zones (Yu et al., 2023).



**Figure 3** The FCF thematic layers for aspect (a), curvature (b), distance from river (c), elevation (d), geology (e), LULC (f), NDVI (g), precipitation (h), river density (i), slope (j), soil permeability (k), SPI (l), and TWI (m)



**Figure 3** The FCF thematic layers for aspect (a), curvature (b), distance from river (c), elevation (d), geology (e), LULC (f), NDVI (g), precipitation (h), river density (i), slope (j), soil permeability (k), SPI (l), and TWI (m) (continued)

### 3.2 Shannon's Entropy

SE is a key information theoretical concept, first introduced by Claude Shannon in 1948 (Rahaman et al., 2021), which measures the level of uncertainty or disorder in a system. Specifically, SE is used in FSM to evaluate the relative contribution of factors which contribute to floods, thus helping in determining the prone areas. The SE model enhances traditional methods by quantifying system instability and uncertainties, allowing for the determination of the most influential factors in flood susceptibility (Haghizadeh et al., 2017).

The SE index, which links quantity with entropy, is particularly useful for modeling flood susceptibility and can be calculated using the following equations.

The Frequency Ratio ( $FR_{ij}$ ) is calculated as:

$$FR_{ij} = \frac{N_{ij}^f / N^f}{N_{ij} / N} \quad (1)$$

where  $i$  and  $j$  denotes the FCF number and class number,  $N_{ij}^f$  represents the number of pixels in each FCF class,  $N^f$  denotes the total number of pixels in the study area,  $N_{ij}$  is the number of flood pixels in each FCF class,  $N$  is the total number of all flooded pixels in the study area.

The probability density  $P_{ij}$  for each class is calculated as:

$$P_{ij} = \frac{FR_{ij}}{\sum_{j=1}^m FR_{ij}}, i = 1, \dots, m \quad (2)$$

where  $P_{ij}$  probability density of each class; followed by:

$$K_i = - \frac{1}{\ln(n_i)} \quad (3)$$

$$E_i = K_i \sum_{j=1}^i P_{ij} \ln(P_{ij}) \quad (4)$$

$$D_i = 1 - E_i \quad (5)$$

$$W_i = \frac{D_i}{\sum_{i=1}^m D_i}, i = 1, \dots, m \quad (6)$$

where  $K_i$  is the computed coefficient for FCF  $i$ ,  $n_i$  is the number of classes of FCF  $i$ , and  $m$  refers to the number of FCFs.  $E_i$  denotes the Entropy of FCF  $i$ ,  $D_i$  is the degree of divergence for FCF  $i$ .  $W_i$  is the weighting value of FCF  $i$ , of which range obtained is between 0 and 1. A value closer to 1 indicates higher inconsistency and imbalance.

To conduct FSM for the area using the SE method, the flood susceptibility index (FSI) must be defined; it is calculated using Eq. (8):



$$C_{ij} = P_{ij} \times 100 \quad (7)$$

$$FSI = \sum (W_i C_{ij}) \quad (8)$$

where  $C_{ij}$  is the weighting value for each class. A high  $FSI$  value implies a higher probability of flood occurrence, whereas a low  $FSI$  value indicates a lower likelihood of flood occurrence.

### 3.3 Flood Conditioning Factors Selection

#### Multicollinearity check

In this study, multicollinearity among the 13 FCFs was assessed using Pearson's correlation coefficient. A commonly accepted threshold for identifying significant collinearity is a Pearson's correlation coefficient greater than 0.7 (Tehrany et al., 2019). The correlation heatmap (Figure 4) visually represented these relationships, with each cell displaying the Pearson's correlation coefficient between a pair of FCFs. In this work, the highest correlation observed was between slope and elevation, with a coefficient of 0.57. This value is below the 0.7 threshold, indicating that multicollinearity among the FCFs was not a concern in this study.




Figure 4. Correlation heatmap of the FCFs

#### FCFs selection and weighting using SE

Figure 5 presents the calculated weight values ( $W_i$ ) for the 13 FCFs. Among these, certain factors such as aspect, curvature, and distance from river exhibited weight values close to or approximately 0, indicating

minimal contributions to flood susceptibility. Other factors, while exhibiting higher weights, remained below the threshold of 0.5. Factors with negligible or very low  $W_i$  values were marked in red in Figure 4 to highlight their limited relevance. Based on this analysis, only seven key FCFs were retained for further modeling: curvature (0.21), slope (0.14), elevation (0.19), geology (0.16), soil permeability (0.12), precipitation (0.09), and SPI (0.06).




Figure 5  $W_i$  values for the 13 FCFs

Table 2 summarizes the selected FCFs, their classification details, and respective weighting values. The table includes essential metrics for each FCF, such as class, area of each class in square kilometers and percentage to total area, number and percentage of flood points in each class, the Frequency Ratio ( $FR_{ij}$ ), probability density ( $P_{ij}$ ), and class weighting ( $C_{ij}$ ).

The  $W_i$  values represent the recalculated importance weights for the seven selected FCFs, highlighting their significance in flood susceptibility modeling. These weights represent the overall contribution of factors to flood spatial distribution, which are based on the relationship of each factor to past flood events.  $C_{ij}$  values, on the other hand, quantify the contribution of the classes in each FCF, representing their relative effect on flood occurrence. Collectively, these weights provide a strategic framework for understanding and prioritizing FCFs in the flood susceptibility analysis.

**Table 2** Selected FCFs and their classification details, and their respective weighing values

Factor	Class	Area (km <sup>2</sup> )	Area %	Flood points	Flood points %	$FR_{ij}$	$P_{ij}$	$C_{ij}$	$W_j$
Slope	0 - 5°	3183.66	29.87%	1450	69.00%	2.31	0.60	60	0.11
	5 - 9	2372.97	22.26%	539	26.00%	1.15	0.30	30	
	9 - 14°	1684.63	15.80%	85	4.00%	0.26	0.07	7	
	14 - 20°	1471.53	13.81%	18	1.00%	0.06	0.02	2	
	22- 26°	1066.91	10.01%	8	0.00%	0.04	0.01	1	
	26- 33°	644.87	6.05%	1	0.00%	0.01	0.00	0	
	33 - 66°	234.50	2.20%	0	0.00%	0.00	0.00	0	
Curvature	Concave	5102.20	47.87%	1004	48.00%	1.00	0.32	32	0.23
	Flat	584.53	5.48%	136	6.00%	1.18	0.37	37	
	Convex	4972.34	46.65%	961	46.00%	0.98	0.31	31	
Elevation	98 - 326 m	3889.76	36.49%	1950	93.00%	2.54	0.92	92	0.18
	326 - 503 m	3293.09	30.89%	150	7.00%	0.23	0.08	8	
	503 - 716 m	1926.30	18.07%	1	0.00%	0.00	0.00	0	
	716 - 1,014 m	1200.61	11.26%	0	0.00%	0.00	0.00	0	
	1014 - 2,023 m	349.32	3.28%	0	0.00%	0.00	0.00	0	
Geology	Triassic-Cretaceous	853.30	8.01%	70	3.00%	0.42	0.07	7	0.23
	Cambrian Dolomite	2398.53	22.50%	226	11.00%	0.48	0.08	8	
	Carboniferous-Permian	974.21	9.14%	132	6.00%	0.69	0.12	12	
	Quaternary	2316.11	21.73%	1133	54.00%	2.48	0.43	43	
	Tertiary	360.24	3.38%	76	4.00%	1.07	0.18	18	
	Permian-Triassic	3607.00	33.84%	464	22.00%	0.65	0.11	11	
	Triassic	149.68	1.40%	0	0.00%	0.00	0.00	0	
Precipitation	< 1,139 m	291.24	2.73%	282	13.00%	4.91	0.62	62	0.09
	1,139 - 1,191 m	479.02	4.49%	92	4.00%	0.97	0.12	12	
	1,191 - 1,228 m	806.94	7.57%	35	2.00%	0.22	0.03	3	
	1,228 - 1,250 m	2279.22	21.38%	375	18.00%	0.83	0.11	11	
	1,250 - 1,275 m	6686.93	62.73%	1317	63.00%	1.00	0.13	13	
	1,275 - 1,308 m	66.62	0.63%	0	0.00%	0.00	0.00	0	
	> 1,478 m	49.09	0.46%	0	0.00%	0.00	0.00	0	
Soil	Moderate	645.59	6.06%	153	7.00%	1.20	0.07	7	0.11
	Low-Moderate	8019.18	75.23%	1411	67.00%	0.89	0.05	5	
	Moderate-High	1151.06	10.80%	477	23.00%	2.10	0.12	12	
	Low	800.61	7.51%	52	2.00%	0.33	0.02	2	
	Other	39.05	0.37%	0	0.00%	0.00	0.00	0	
	High	3.20	0.03%	8	0.00%	12.70	0.74	74	
SPI	< -6.5	4094.50	38.41%	718	34.00%	0.89	0.13	13	0.05
	-6.5 - -2.38	864.72	8.11%	679	32.00%	3.98	0.56	56	
	-2.8 - 0	3064.52	28.75%	451	21.00%	0.75	0.11	11	
	0 - 2.83	2141.07	20.09%	146	7.00%	0.35	0.05	5	
	> 2.83	494.27	4.64%	107	5.00%	1.10	0.16	16	


### 3.4 Random Forest

RF is an ensemble-based machine learning algorithm which creates decision trees based on random data and feature samples and then aggregates the output to improve accuracy and reduce overfitting. In flood susceptibility mapping (FSM), RF is extremely useful to rank complex, high-dimensional environmental data in FSM (Dey et al., 2024; Seydi et al., 2022)—such as topography, precipitation, and land use—by effectively ranking the importance of these factors. RF model was built in R using the caret package. Hyperparameters were tuned via 10-fold cross-validation optimizing for AUC (“ROC”), and the number of trees was set to 1,000 (nmtree = 1000). The best mtry (by highest ROC) was selected for the final RF model.

## 4. RESULTS AND DISCUSSION

### 4.1 AUC evaluation results

ROC curves of SE and RF models on training and verification datasets were shown in Figure 6. The ROC curves provided visualization of models’ classification accuracy; the curves closer to the top-left corner indicate higher sensitivity and specificity.



**Figure 6** ROC curves of SE and RF models based on both training and verification dataset


In general, the performance of both two models was satisfactory, obtaining AUC higher than 0.870 in both two train and verification datasets. The SE model performed reasonably well with an AUC of 0.874 (training) and 0.870 (verification) but was outperformed by the RF model which achieved an AUC of 0.929 (training) and 0.931 (verification).

We observed the trade-off of generalizability between training and verification results. An important note was that the AUC values show consistency of training and verification datasets for both models, neither of which reflected overfitting but provided robust performance. This demonstrated that the models were both accurate with new data. In FSM, creating practical models that can be expected to make accurate predictions in the real world is the main objective; thus, this balance is critical. Both models showed relatively high AUC values confirming the appropriateness of the FCFs selection and preprocessing for the study area. Particularly, the SE feature selection and the combination with RF was remarkable in terms of predictive robustness and reliability.


Most notably, the RF model in our study significantly outperformed the SE model, reinforcing the superior predictive power of the state of art ML methods introduced. This finding was consistent with previous studies that ML models consistently perform better than traditional statistical methods. For example, Seydi et al. (2022) and Bhattarai et al. (2024) have both reported that single ML models lead to more FSM accuracy and robustness than traditional statistical approaches. The superior performance of RF was likely due to its ability to capture non-linear interactions among multiple flood conditioning factors, which SE—being based on independent weighting—could not fully exploit. RF’s ensemble of decision trees allowed it to model complex, high-dimensional relationships and automatically prioritize the most informative predictors, thereby enhancing discrimination between flood and non-flood points.

### 4.2 Flood susceptibility results

Figure 7 presents the flood susceptibility maps produced using the SE and RF models, categorizing the study area into five susceptibility levels: Very Low, Low, Moderate, High, and Very High. These maps represented the spatial variation of flood-prone areas across the study region, with noticeable differences in the distribution and extent of susceptibility levels.




(a)



(b)

**Figure 7** Floods susceptibility mapping results for SE (a) and RF (b) models

Figure 8 highlights the percentages and total areas of different flood susceptibility levels for the SE and RF models. The SE model predicted 41.58% of the area as "Very Low" susceptibility, while the RF model increased this proportion to 51.09%, suggesting that RF was more conservative in predicting higher susceptibility levels. On the contrary, SE identified larger proportions of "High" (16.64%) and "Very High" (11.20%) susceptibility areas compared to RF (9.87% and 10.62%, respectively). When examining the total area (in square kilometers) under each susceptibility level, the SE model classified 4432.07 km<sup>2</sup> as "Very Low," 2182.81 km<sup>2</sup> as "Low," 1076.52 km<sup>2</sup> as "Moderate," 1773.63 km<sup>2</sup> as "High," and 1193.66 km<sup>2</sup> as "Very High." Meanwhile, the RF model classified 5445.74 km<sup>2</sup> as "Very Low," 1775.14 km<sup>2</sup> as "Low," 1253.75 km<sup>2</sup> as "Moderate," 1051.92 km<sup>2</sup> as "High," and 1132.15 km<sup>2</sup> as "Very High." These results suggested that the RF model exhibited a tendency to assign a greater portion of the study area to "Very Low" and "Moderate" susceptibility levels, potentially underestimating higher susceptibility zones. Conversely, the SE model appeared to provide a more balanced and inclusive representation of flood susceptibility, identifying a larger area as "High" and "Very High" susceptibility.



**Figure 8** Floods susceptibility levels percentage and the areas for SE and RF models

The differences between the models may stem from their underlying methodologies. The SE model integrated multiple factors systematically, leading to a broader spread across all susceptibility levels. In contrast, the RF model's decision tree-based mechanism emphasized dominant factors, which could explain its conservative predictions for high-susceptibility areas.

The results emphasized the advantages of ML models in FSM. Their ability to delineate high-risk areas with greater accuracy can significantly enhance flood mitigation planning and risk management efforts. The variation in susceptibility distributions across models highlighted the importance of algorithm selection based on specific modeling objectives and the characteristics of the study area.



## 5. CONCLUSION

This study demonstrated that modern ML techniques significantly outperformed conventional statistical approaches—such as the Shannon Entropy method—in mapping flood susceptibility within Thailand's Wang River Basin. By integrating a comprehensive set of 13 flood conditioning factors (including aspect, curvature, elevation, geology, LULC, NDVI, precipitation, river density, slope, soil permeability, SPI, and TWI) with a robust flood inventory of 3000 flood and 3000 non-flood samples, we were able to build a well-balanced and informative dataset. Multicollinearity among the factors was carefully assessed using the Pearson correlation method, ensuring that the predictive models were not adversely affected by redundant information. The SE method was used to identify the contribution of each FCF to the occurrence of floods, by setting the importance weight threshold  $W_i$ , FCFs with  $W_i > 0.5$  including curvature, slope, elevation, geology, soil permeability, precipitation, and SPI were kept into the modeling process.

The performance of SE versus RF models was investigated in this study. The results consistently showed that the RF obtained higher AUC both on training and verification datasets than the SE model, indicating that advanced ML methods are suitable to manage the dynamic and heterogeneous nature of flood susceptibility, resulting in improvement of prediction accuracy and operational stability at Wang River Basin. In addition, the flood susceptibility maps produced in this study provide useful information that helps with flood management and risk reduction by identifying and quantifying areas with a high risk of flooding that should be targeted for interventions by local authorities. Despite these promising outcomes, challenges remain—particularly regarding model interpretability, data quality, and the need for improved generalization across diverse regions. Future studies could explore more elaborate hybrid schemes (i.e., physics-based deep learning and probabilistic), for further enhancing predictive power while ensuring that model outputs are both transparent and actionable for decision-makers.

Overall, this study highlighted the transformative potential of ML in FSM and underscored its critical role in developing rapid, accurate, and scalable flood forecasting systems to mitigate the adverse impacts of extreme weather events in the Wang River Basin and beyond.

## 6. ACKNOWLEDGMENTS

This work was supported and funded by Naresuan University Faculty of Engineering Scholarships.

## 7. REFERENCES

Akay, H. (2024). Flood Susceptibility Mapping Using Information Fusion Paradigm Integrated with

- Decision Trees. *Water Resources Management*, 38(13), 5365-5383. <https://doi.org/10.1007/s11269-024-03918-5>
- Al-Kindi, K. M., & Alabri, Z. (2024). Investigating the Role of the Key Conditioning Factors in Flood Susceptibility Mapping Through Machine Learning Approaches. *Earth Systems and Environment*, 8(1), 63-81. <https://doi.org/10.1007/s41748-023-00369-7>
- Bhattarai, Y., Duwal, S., Sharma, S., & Talchabhadel, R. (2024). Leveraging machine learning and open-source spatial datasets to enhance flood susceptibility mapping in transboundary river basin. *International Journal of Digital Earth*, 17(1). <https://doi.org/10.1080/17538947.2024.2313857>
- Bidorn, B., Chanyotha, S., Kish, S. A., Donoghue, J. F., Bidorn, K., & Mama, R. (2015). The effects of Thailand's Great Flood of 2011 on river sediment discharge in the upper Chao Phraya River basin, Thailand. *International Journal of Sediment Research*, 30(4), 328-337. <https://doi.org/10.1016/j.ijsrc.2015.10.001>
- Charoenlerkthawin, W., Namsai, M., Bidorn, K., Rukvichai, C., Panneerselvam, B., & Bidorn, B. (2021). Effects of Dam Construction in the Wang River on Sediment Regimes in the Chao Phraya River Basin. *Water*, 13(16). <https://doi.org/10.3390/w13162146>
- Dey, H., Shao, W., Moradkhani, H., Keim, B. D., & Peter, B. G. (2024). Urban flood susceptibility mapping using frequency ratio and multiple decision tree-based machine learning models. *Natural Hazards*, 120(11), 10365-10393. <https://doi.org/10.1007/s11069-024-06609-x>
- Gohil, M., Mehta, D., & Shaikh, M. (2024). An integration of geospatial and fuzzy-logic techniques for flood-hazard mapping. *Journal of Earth System Science*, 133(2). <https://doi.org/10.1007/s12040-024-02288-1>
- Haghizadeh, A., Siahkamari, S., Haghiabi, A. H., & Rahmati, O. (2017). Forecasting flood-prone areas using Shannon's entropy model. *Journal of Earth System Science*, 126(3). <https://doi.org/10.1007/s12040-017-0819-x>
- Kaya, C. M., & Derin, L. (2023). Parameters and methods used in flood susceptibility mapping: a review. *Journal of Water and Climate Change*, 14(6), 1935-1960. <https://doi.org/10.2166/wcc.2023.035>
- Long, G., Tantane, S., Nusit, K., & Sooraksa, P. (2025). Flood susceptibility mapping in the Yom River Basin, Thailand: stacking ensemble learning using multi-year flood inventory data. *Geocarto International*, 40(1). <https://doi.org/10.1080/10106049.2025.2461531>
- Pham, B. T., Jaafari, A., Phong, T. V., Yen, H. P. H., Tuyen, T. T., Luong, V. V., Nguyen, H. D., Le, H. V., & Foong, L. K. (2021). Improved flood susceptibility mapping using a best first decision tree integrated with ensemble learning techniques. *Geoscience Frontiers*, 12(3). <https://doi.org/10.1016/j.gsf.2020.11.003>
- Rahaman, A., Venkatesan, M. S., & Ayyamperumal, R. (2021). GIS-based landslide susceptibility mapping method and Shannon entropy model: a case study on Sakalesapur Taluk, Western Ghats, Karnataka, India. *Arabian Journal of Geosciences*, 14(20). <https://doi.org/10.1007/s12517-021-08422-3>
- Rahmati, O., Darabi, H., Panahi, M., Kalantari, Z., Naghibi, S. A., Ferreira, C. S. S., Kornejady, A., Karimidastenaie, Z., Mohammadi, F., Stefanidis, S., Tien Bui, D., & Haghighi, A. T. (2020). Development of novel

- hybridized models for urban flood susceptibility mapping. *Sci Rep*, 10(1), 12937. <https://doi.org/10.1038/s41598-020-69703-7>
- Raveephinit, D., Rittima, A., Phankamolsil, Y., Tabucanon, A. S., Sawangphol, W., Kraisaangka, J., Talaluxmana, Y., & Vudhivanich, a. V. (2021). *Assessment of Weap Model in Simulating Rainfall-Runoff Relation in The Ping and Wang River Basins, Thailand* The 8th National Conference on Water Resources Engineering & The 5th International Conference on Water Resources Engineering, Department of irrigation engineering, Faculty of engineering at kamphaeng saen, Kasetsart University.
- Riche, A., Drias, A., Guermoui, M., Gherib, T., Boulmaiz, T., Souissi, B., & Melgani, F. (2024). A Novel Hybrid Deep-Learning Approach for Flood-Susceptibility Mapping. *Remote Sensing*, 16(19). <https://doi.org/10.3390/rs16193673>
- Seydi, S. T., Kanani-Sadat, Y., Hasanlou, M., Sahraei, R., Chanussot, J., & Amani, M. (2022). Comparison of Machine Learning Algorithms for Flood Susceptibility Mapping. *Remote Sensing*, 15(1). <https://doi.org/10.3390/rs15010192>
- Tehrany, M. S., Jones, S., & Shabani, F. (2019). Identifying the essential flood conditioning factors for flood prone area mapping using machine learning techniques. *Catena*, 175, 174-192. <https://doi.org/10.1016/j.catena.2018.12.011>
- Wahba, M., Sharaan, M., Elsadek, W. M., Kanae, S., & Hassan, H. S. (2024). Examination of the efficacy of machine learning approaches in the generation of flood susceptibility maps. *Environmental Earth Sciences*, 83(14). <https://doi.org/10.1007/s12665-024-11696-x>
- Yu, H., Luo, Z., Wang, L., Ding, X., & Wang, S. (2023). Improving the Accuracy of Flood Susceptibility Prediction by Combining Machine Learning Models and the Expanded Flood Inventory Data. *Remote Sensing*, 15(14). <https://doi.org/10.3390/rs15143601>

# Concrete Mix Design Based on Spherical Shape Concept

Parnuhmesr Sirinaranun\*

Department of Civil Engineering, College of Engineering, Rangsit University, Pathumthani, Thailand

\* corresponding author e-mail: parnuhmesr.s@rsu.ac.th or sirinaranun.p@yahoo.com

(Received: 31 October 2024, Revised: 19 January 2025, Accepted: 27 March 2025)

## Abstract

The concepts of cement paste, mortar and concrete mix design have been important for products of concrete construction. Concrete mix designers almost always use the trial volume method which is based on absolute volume method or simple traditional mix design, to find the proportions of concrete components based on source of aggregates is different characteristics. The designer must use his experience to change the ratio of materials in concrete components and check concrete strength and workability of concrete to meet work requirements. The basic concepts of mix design, based on volume method, assume that the aggregate particle shape is spherical. The concept of mix design would be developed as an approximate method for civil engineers to modify the cement paste thickness or mortar thickness design to get the mix proportions of concrete to meet workability requirement while maintaining water cement ratio for any kind of characteristics of material, such as sizing and gradation. Using the spherical shape concept, civil engineers can apply these concrete mix design principles to durability-based or porous concrete mix designs.

**Keywords:** Cement Paste Mix Design, Mortar Mix Design, Concrete Mix Design.

## 1. NOMENCLATURE

Cement Paste (CP) is composed of cement (C) and water (W). Mortar (MT) is composed of cement paste and fine aggregate or sand (S). Concrete (CC) is composed of mortar and coarse aggregate or crush stone (CS) or gravel.

## 2. INTRODUCTION

Mortar and concrete mix design are important for concrete structure or reinforcement concrete structure. Concrete mix design can be calculated by absolute volume or ACI standard practice ACI211.1 (2022), which is worldwide and also used in academic units in Thailand. Almost, civil engineering designers always use the absolute volume method (Neville, 1995) and his experience in finding the trial mix design to meet project requirements due to characteristics of fine and coarse aggregate has different properties.

The selection of concrete mix proportions based on ACI211.1-22 can be used when the gradation of coarse aggregate and the fineness modulus of fine aggregate must be maintained in accordance with the criteria of standard practice (ASTM C33, 2023). Normally, each source of fine and coarse aggregate differs in sizing and gradation, which do not meet the same criteria as the standard specification. The standard practice provides only one solution for the water content in concrete mix components to meet the slump range requirement, based solely on the maximum size of coarse aggregate.

The absolute volume method (Neville, 1995) (Caltrans, 2013) (Goswami, 2018) is an easy way for designers to modify the parameters of the concrete mix components such as water cement ratio, cement per

aggregate ratio or paste to aggregate ratio (Sun & Zhu, 2012) and fine aggregate per coarse aggregate ratio based on his experience to get the best proper mix for any sources of aggregate and can apply for high volume fly ash concrete (Yao et al., 2023), high performance or durability concrete.

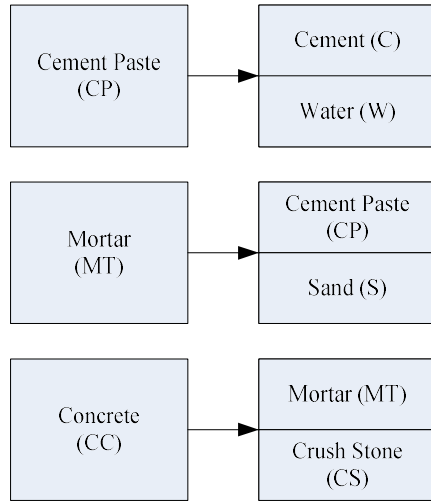
Sirinaranun (2014) developed the mortar mix design based on the concept that fine aggregate has a spherical shape. This study used the basic material testing parameters in a concrete laboratory, such as specific gravity of materials, void of fine aggregate and fineness modulus of fine aggregate. This study proposed an important parameter: the average cement paste thickness, which affects the minimum cement content in each mortar mix proportion. This study also proposed fulfilling cement paste in void of fine aggregate.

This research would like to continue to use Sirinaranun (2014) concepts for developing the concrete mix design which uses basic characteristics of materials such as fineness modulus of fine and coarse aggregate (Neville, 1995), specific gravity of fine aggregate (ASTM C128, 2022), specific gravity of coarse aggregate (ASTM C127, 2024), void and unit weight of aggregate (ASTM C29, 2023). These characteristics of material are the basic parameters that almost testing in academic units in Thailand. This research would like civil engineering designers to get the idea from this designing concepts of maintaining the water cement ratio to maintain concrete strength and varying the cement paste thickness or mortar thickness design to meet its workability. The advantage of these concepts is that they allow us to determine the proper amount of cement paste to combine with fine aggregate to form mortar, ensuring good properties of mortar. Additionally, they help us determine the proper

amount of mortar to combine with coarse aggregate to form concrete with good properties for normal concrete.

### 3. THEORIES AND CONCEPTUAL DESIGN

The conceptual mix design is based on the meaning of the terms cement paste, mortar and concrete, as shown in Figure 1. Cement paste (CP) is composed of cement (C) and water (W). Mortar (MT) is composed of cement paste (CP) and fine aggregate (S). Where, concrete (CC) is composed of mortar (MT) and coarse aggregate (CS).



**Figure 1** Conceptual Mix Design of Cement Paste, Mortar and Concrete.

#### 3.1 Cement Paste Mix Design Concept

The conceptual design of the cement paste mix design is based on the water cement ratio parameter which is related to the concrete strength. In this concept has been used the relationship between the cylindrical compressive strength of concrete and water cement or water cementitious material ratio of non-air-entrained concrete without water reducing admixtures of ACI 211.1 (2022) as based on a parameter which is transformed to Thai unit style in terms of formula by regression method as shown in Equation (1).

$$W_c = 2.73 - 0.88 \log f'_c, \quad (1)$$


where  $W_c$  is water cement ratio by weight, and  $f'_c$  is the cylindrical compressive strength of non-air-entrained concrete cured for 28 days in kilogram per square centimeter (ksc).

The conceptual design of the cement paste mix design uses the water cement ratio to transform the weight of cement and water to be its volume of cement and water by using specific gravity of cement and density of water. The total volume of cement and water is the volume of cement paste, which is not equal to one unit, then use the


total volume of cement paste to normalize the volume of cement and water to be one unit of the cement paste volume. This concept will be shown in Figure 2.

#### 3.2 Mortar Mix Design Concept

The conceptual design of mortar mix design (Sirinananun, 2014) is based on the spherical shape of fine aggregate, which uses the voids of fine aggregate as the main parameter that is related to the one-unit volume concept and spherical concept. Other concepts are in terms of mortar particle and cement paste functions. Mortar is composed of cement paste and fine aggregate or cement paste and sand. When mixing cement paste and sand together, it is found that some parts of cement paste will seize around the sand surface and form mortar particles. The concept of mortar particles will be shown in 3. Where other functions of cement paste will fill in voids of fine aggregate. It can be said that cement paste has two functions when mixing with sand. One is covered around the sand surface. The other is fulfilled in voids of sand. Sand particles which mix with cement paste that grasp around the surface will transform into mortar particles. The cement paste that seizes around the sand surface will be called covering cement paste, while the cement paste that fills in voids in the sand will be called fulfilling cement paste, as shown in Figure 4.



**Figure 2** Conceptual Mix Design of Cement Paste



**Figure 3** Mortar Particle Concept

The last concept of mortar mix design is the void of fine aggregate. Due to the idea of uniform aggregate, the bigger uniform aggregate or the smaller uniform aggregate also has the same volume of uniform aggregate

and the same voids of uniform aggregate. When a sand particle which is a small size is mixed with covered cement paste and formed to be a mortar particle which is a bigger size, the voids in sand and the voids in mortar should be the same, while the sand particle volume will be replaced by the mortar particle volume as shown in Figure 5.




Figure 4 Functions of Cement Paste Concept

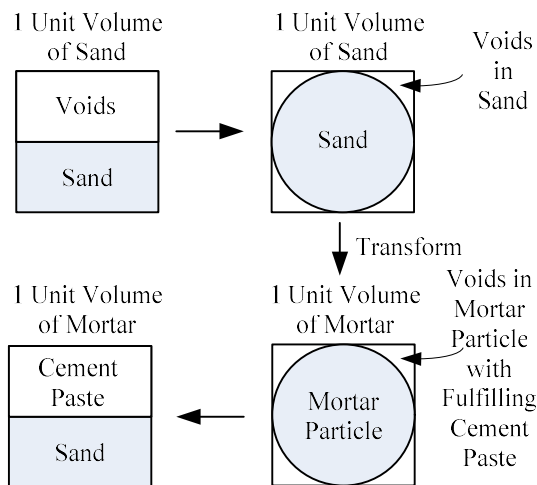


Figure 5 Concept of Voids in Mortar Particle

### 3.3 Concrete Mix Design Concept

The conceptual design of the concrete mix design, which looks like the conceptual design of a mortar mix design, is based on the void of coarse aggregate parameter which is related to the one-unit volume concept. The others are in terms of concrete particle and mortar functions. Concrete is composed of mortar and coarse aggregate or mortar and crush stone. When mixing mortar and crush stone together, it is found that some parts of mortar will seize around the crush stone surface and form to be concrete particles. The concept of concrete particles will be shown in Figure 6. Where other functions of

mortar will be filled in voids of coarse aggregate. It can be said that mortar has two functions when mixing with crush stone. One is covered by the crush stone surface. The other is fulfilled in voids of crush stone. Crush stone particles which are mixed with covered mortar that grasp around the surface will form into concrete particles. The mortar that seizes around the crush stone surface will be called covering mortar, while the mortar that filling in voids in crush stone will be called fulfilling mortar, as shown in Figure 7.




Figure 6 Concrete Particle Concept




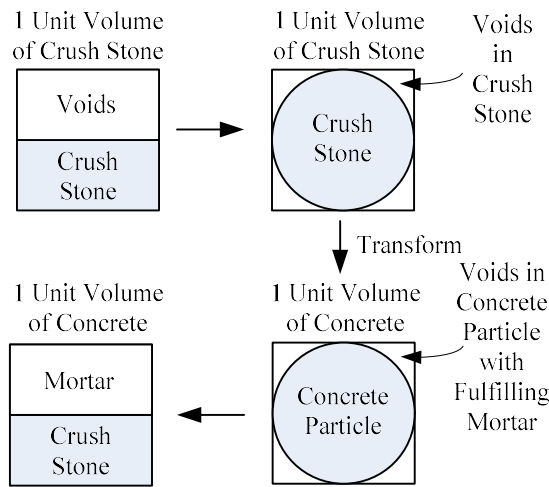
Figure 7 Functions of Mortar Concept

Void in coarse aggregate is the main concept of concrete mix design, which looks like a mortar mix design concept. Due to the idea of uniform aggregate, the bigger uniform aggregate or the smaller uniform aggregate also has the same volume of uniform aggregate and the same voids in uniform aggregate. When crush stone particles which are small mix with mortar and transform into concrete particles which are bigger. The voids in crush stone and the voids in concrete should be the same, while crush stone particle volume will be replaced by concrete particle volume as shown in Figure 8.

### 3.4 Aggregate Size

Grading of aggregate, which is the distribution of particles of granular materials of various sizes, in practice, will be represented in terms of fineness modulus, which is an index of the fineness of an aggregate and its voids. Fineness modulus (FM) is

computed from sieve analysis data by the technique of normalizing the summation of cumulative percentages of aggregate retained on each sieve by 100 (Neville, 1995) and is represented the index of average aggregate size. The ASTM E11 (2024) standard test sieves and the size used for determining the fineness modulus will be shown in Table 1 and have an increasing ratio of 2 to 1. If some uniform aggregate is retained only on one sieve such as No. 30, it is found that the fineness modulus of that uniform aggregate is 3. Then, for another uniform aggregate that is retained on another sieve, the fineness modulus of each uniform aggregate can be computed as shown in Table 1. For any fineness modulus value, you can find the average aggregate size by using the larger sieve size and its size.



**Figure 8** Concept of Voids in Concrete Particle

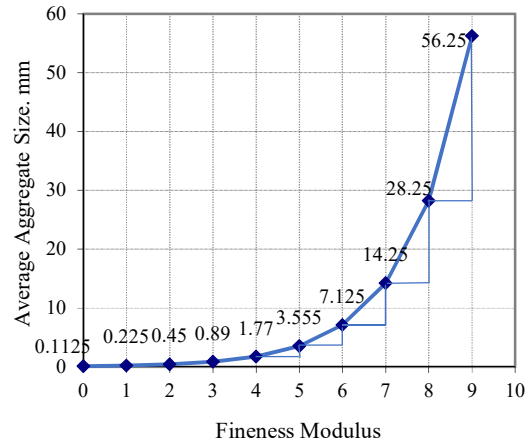
From the fineness modulus value and average aggregate size which are shown in Table 1, can be plotted this relative as graph shown in Figure 9 and this relationship can be found by the regression method as shown in Equation (2). In this paper, it prefer to use Table 1 and the linear interpolation method, which is most useful in engineering fields, to find the average aggregate size for any fineness modulus value by Equation (3).

**Table 1** ASTM Standard Sieve, Sieve Size, Average Aggregate Size and Fineness Modulus (FM)

ASTM Standard Sieve	Sieve Size (mm)	Average Aggregate Size (mm)	FM
1 1/2 "	37.5	56.25	9
3/4 "	19.0	28.25	8
3/8 "	9.50	14.25	7
No. 4	4.75	7.125	6
No. 8	2.36	3.555	5
No. 16	1.18	1.770	4
No. 30	0.600	0.890	3
No. 50	0.300	0.450	2
No. 100	0.150	0.225	1

$$d_a = 10^{(0.3FM - 0.95)}, \quad (2)$$

where  $d_a$  is average aggregate size in mm, and FM is the fineness modulus of aggregate.



**Figure 9** Average Aggregate Size and Fineness Modulus

$$d_a = d_L + \frac{(FM - FM_L)}{(FM_U - FM_L)}(d_U - d_L), \quad (3)$$

Where  $d_a$  is average aggregate size in mm,  $FM$  is the fineness modulus of aggregate that would like to find average aggregate size,  $FM_U$  is a larger fineness modulus or upper fineness modulus in Table 1,  $FM_L$  is smaller fineness modulus or lower fineness modulus in Table 1,  $d_L$  is a lower average aggregate size following that lower fineness modulus in Table 1 and  $d_U$  is an upper average aggregate size follow that upper fineness modulus in Table 1

For example, if the fineness modulus value is 2.75, it can determine the average aggregate size by using linear interpolation technique or Equation (3) as 0.780 mm.

### 3.5 Mortar Particle Size

From the ideal of the mortar particle concept shown in Figure 3, the mortar particle size is the look like the diameter of the mortar particle, which comes from the average fine aggregate size and the covering cement paste thickness around the fine aggregate, as shown in Figure 10 and can be shown in Equation (4).

$$d_{mt} = 2t_{cp} + d_s, \quad (4)$$

where  $d_{mt}$  is average mortar particle size in mm,  $d_s$  is the average fine aggregate size and  $t_{cp}$  is the cement paste thickness.






Figure 10 Mortar Particle Size

### 3.6 Cement Paste Thickness

Cement paste thickness is an important property of mortar and concrete mix design. How to know the proper cement paste thickness which makes workability mortar or performance concrete mix design. From knowledge of cement paste phenomena, cement paste thickness can be related to the cement particle size. From air permeability testing, the specific surface area which is almost reported by the manufactory plant is around 2,700 to 3,300 square centimeters per gram or 270 to 330 square meters per kilogram. If the specific gravity of cement is about 3.15 and the cement particles assume a spherical shape, the average size of the cement particle is about 6.3 microns, for 3,000 sq.cm. per gram of average specific surface area. It tells us that the minimum cement paste thickness should not be less than about 6.3 microns. The maximum cement paste thickness depends on the workability of mortar and concrete.

### 3.7 Concrete Particle Size

In the same concept related to mortar particle size, concrete particle size is the diameter of total coarse aggregate and covering mortar in terms of mortar thickness defined as  $d_{cc}$  as shown in Figure 11 and on Equation (5). Where, the diameter of a coarse aggregate can be obtained from its fineness modulus by using Equation (3).




Figure 11 Concrete Particle Size

$$d_{cc} = 2t_{mt} + d_{cs}, \quad (5)$$

where  $d_{cc}$  is average concrete particle size in mm,  $d_{cs}$  is the average coarse aggregate size and  $t_{mt}$  is the mortar thickness.

### 3.8 Mortar Thickness

Mortar thickness is the second parameter for concrete mix design where the first is cement paste thickness. How to use the proper mortar thickness, which makes it workable, or performance concrete mix design depends on the mortar particle size. The mortar thickness can be the layer of mortar particle size as shown in Equation (6).

$$t_{mt} = nd_{mt}, \quad (6)$$

where  $t_{mt}$  is mortar thickness in mm,  $n$  is positive real number of layer of mortar particle size and  $d_{mt}$  is the average mortar particle size.

The number of layers of mortar particle size can be any positive real number up to the proposal of the designer. Mortar thickness is related to the sand particle size and depends on cement paste thickness.

### 3.9 Specific Gravity

The specific gravity of a material is the density ratio or specific weight ratio of that material to water and is the main property for conversion between its volume and its weight. In the civil engineering field, normally the specific gravity of cement is about 3.15 where the specific gravity of sand and crush stone is about 2.6 and 2.7, respectively. The normal unit weight of water or water density is about 1,000 kilograms per cubic meter.

### 3.10 Procedure of Mix Design

The main steps of concrete mix design following conceptual design from item 3.1 to 3.3 and including the rest of the items together, can be separated into 4 parts as follows.

Part I is a cement paste 1 unit mix design by finding the components of cement and water in 1 unit volume of cement paste based on parameters: strength of concrete or water cement ratio, specific gravity of cement and unit weight of water.

Part II is a mortar 1 unit mix design by finding the components of cement paste and sand in 1 unit volume of mortar based on parameters: covering cement paste thickness, fineness modulus of sand and sand void.

Part III is a concrete 1 unit mix design by finding the components of mortar and crush stone in 1 unit volume of concrete based on parameters, covering mortar thickness, fineness modulus of crush stone and crush stone void.

Part IV is the combination of part I part II and part III to get components of cement, water, sand and crush stone in 1 unit volume of concrete mix design. After getting 1 unit volume of concrete mix design can be applied to all unit volumes, such as cubic meter, cubic centimeter, cubic foot or cubic yard, by using specific gravity of cement sand and crush stone and the unit weight of water on those units to transform its volume into its weight.

## 4. RESULTS AND CASE STUDY

The results of concrete mix design based on case study of material parameters, which are strength of concrete is 280 ksc at 28 days curing, specific gravity of cement is 3.15, fineness modulus of sand is 2.75, average sand void is 0.36 or 36%, cement paste thickness is 60 micron or 0.060 mm, specific gravity of sand is 2.60, fineness modulus of crush stone is 6.95, average crush stone void is 0.43 or 43%, mortar thickness design is 0.6 layer of normal mortar size and specific gravity of crush stone is 2.70 will be shown as following by procedure concepts in item 3.10.

### Part I Cement Paste 1 Unit Mix Design

The concrete strength is 280 ksc. After substitution into Equation (1), we will get a water cement ratio equal to 0.577. After that, using the water cement ratio by weight, which means water is 0.577 grams and cement is 1 gram, to find the volume of water is 0.577 cubic centimeters (cc.) and cement is 0.317 cc. Normalizing the cement paste volume, which is 0.894 cc. to 1 unit, will make the volume of cement and water equal to 0.355 and 0.645 units, respectively, as shown in Figure 12.




Figure 12 Component of 1 Unit Cement Paste

### Part II Mortar 1 Unit Mix Design

Since the fineness modulus of sand is 2.75, the average sand size will be 0.78 mm using Equation (3). Then the average mortar particle size is about 0.90 mm using Equation (4). After this step, find the volume of the sand particle and mortar particle by the spherical shape concept to know the sand mortar ratio, which is 0.651. From the concept that the void of the mortar particle is equal to the void of the sand particle volume, which is 0.36 units in Figure 5, then the mortar particle volume in 1 unit volume is equal to 0.64 units and the sand particle volume in 1 unit will be reduced by the sand mortar ratio which is 0.651 to get the sand particle volume equal to 0.417 unit. After that, the volume of covering cement paste volume in 1 unit is 0.223 units, which is the difference between mortar particle and sand particle volumes. For a good design of mortar, the cement paste

that fulfills in voids must be 100 percent, then the fulfilling cement paste in the void is 0.36 units. The total cement paste volume in 1 unit mortar is 0.583 units by the sum of covering and fulfilling cement paste, where the sand volume is 0.417 units, as shown in Figure 13.

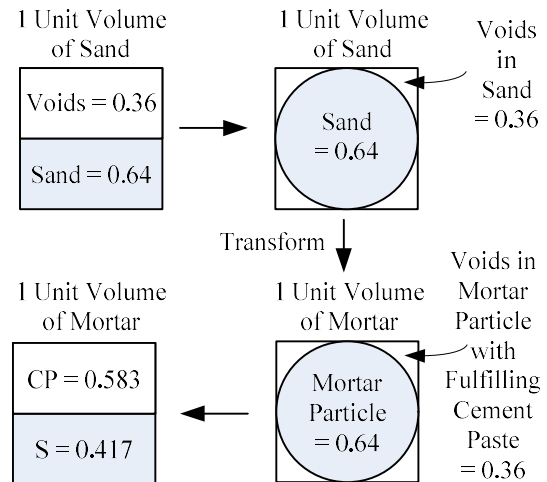


Figure 13 Component of 1 Unit Mortar

### Part III Concrete 1 Unit Mix Design

From fineness modulus of crush stone is 6.95, the average crush stone size is 13.89 mm using Equation (3). Because the mortar thickness design is 0.6 of the mortar particle size, which is 0.90 mm, the mortar thickness will be 0.54 mm. Then the average concrete particle size is 14.97 mm using Equation (5). After this step, find the volume of crush stone particles and concrete particles using the spherical shape concept to know the crush stone concrete ratio, which is 0.799. From the concept that the void of concrete particles is equal to the void of crush stone particles, which is 0.43 units in Figure 8, then the concrete particle volume in 1 unit volume is equal to 0.57 units, where the crush stone particle volume in 1 unit will be reduced by 0.799 ratio of the crush stone concrete to get the crush stone volume equal to 0.455 unit. After that, the volume of covered mortar volume in 1 unit is 0.115 units because of the difference between concrete particle volume and crush stone particle volume. For a good design of concrete, the mortar that fulfills in the void should be 100 percent, then the fulfilling mortar in the void is 0.43 units. The total mortar volume in 1 unit of concrete is 0.545 units by the sum of covering and fulfilling mortar, where the crush stone volume is 0.455 units, as shown in Figure 14.

### Part IV Final Concrete 1 Unit Mix Design

The last step is combining the mix design from part I part II and part III together with its meaning such as mortar is the component of cement paste and sand, where cement paste is the component of cement and water. When we would like to find the cement volume in 1 unit concrete volume, we use the ratio concept or



multiplication tool to get each component. For example, cement volume is 0.1128 units by the multiplication result of 0.545 units of mortar in concrete and 0.583 units of cement paste in mortar and 0.355 units of cement in cement paste, as shown in Figure 15. After getting the volume of each component in 1 unit of concrete, the standard volume unit of concrete in Thailand, which is a cubic meter, will be applied to 1 unit of concrete to be 1 cubic meter of concrete. The last step is the transformation of its volume in terms of cubic meters to be its weight in terms of kilograms by its specific gravity and water unit weight, as shown in Figure 16.

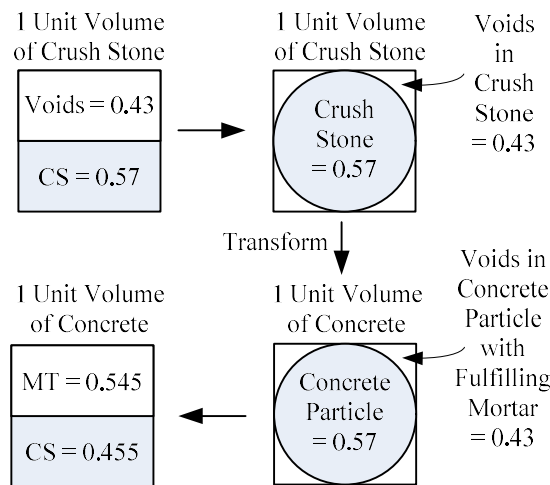


Figure 14 Component of 1 Unit Concrete

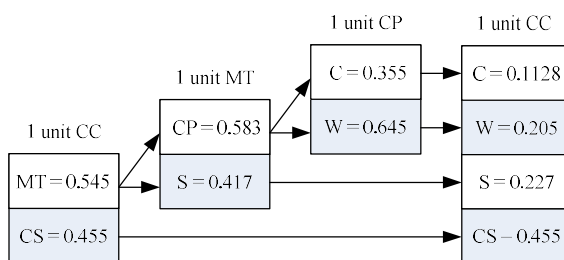


Figure 15 All Components of 1 Unit Concrete

## 5. CONCLUSIONS

The concrete mix design is an important tool for civil engineers used to find the mix proportions to meet proper work. The important keys or parameters that affect the mix design are many factors, such as fineness of cement powder, fineness modulus of fine aggregate and coarse aggregate, voids of fine aggregate and coarse aggregate, cement paste thickness, mortar thickness, the required concrete strength and workability of fresh concrete.




Figure 16 All Components of 1 cubic meter of Concrete

The results of the concrete mix design shown in Figure 16 are only one solution to meet the concrete strength requirement based on water cement ratio and may not meet the workability requirement. From this research concept, the designer can have two ways to find the proper mix to meet workability requirements. The first way is to maintain the mortar thickness design and vary the cement thickness design. For example, if the workability of the first mix is above the requirement, the designer can reduce the cement paste thickness in the design lower than the first time, such as 15, 30 or 45 microns, to check its workability. Vice versa, if the first mix has poor workability, the designer can increase the cement paste thickness such as 75, 90 or 120 microns to check its workability again. After that, the designer will know the relationship between workability of fresh concrete and cement paste thickness and can find the cement paste thickness using regression method for workability requirement. The second way is to maintain the cement paste thickness and vary the mortar thickness design in terms of 0, 0.125, 0.25, 0.5, 1, 2, or 3 times the layer of mortar size. In the same way, designers can know the relationship between workability of fresh concrete and mortar thickness design and use regression method to find the mortar thickness for proposed workability. In future work on this concept, it has many points to study further. For example, designers can develop the relationship between cement paste thickness and water cement ratio and proper mortar thickness design as the first guidance for concrete mix design to quickly meet workability and strength requirements. The cement paste thickness for any type of cement is not the same, due to the compounds and fineness of Portland cement powder or hybrid cement powder. The other point is to study durability concrete mix design by changing the cement paste mix design concept to be a binder paste design concept which uses an absolute volume method based on water cement ratio, pozzolan to cement ratio and admixture to cement ratio while maintaining the mortar and concrete mix design concepts. The binder paste is not only the main part of the durability of concrete but also the durability of aggregate.

Normally, air voids can be in cement paste, mortar and concrete particles due to air voids in cement powder, fine aggregate and coarse aggregate. While mixing the concrete components, air voids in cement paste, mortar and concrete can be eliminated by vibration between mixing time and compaction time. Finally, it still has air voids in cement paste, mortar and concrete particles in real situations up to the water contents. Designers must first maintain or keep the fulfilling cement paste in the sand void and fulfilling mortar in crush stone void to perfectly 100 percent of its void in the concrete mix design concept to reduce air void in concrete due to void of aggregates first and can get minimum cement content from the design. Designers can use the standard method for air content of freshly mixed concrete by the pressure method (ASTM C231, 2009) to study the behavior of air in fresh concrete related to the mix design. The last point, designers must know that the water cement which is enough for chemical reactions, such as hydration reactions of calcium silicate hydrates, is about 0.21 to 0.24 (Neville, 1995), then the excess amount of water cement beyond reactions in mix design is used for workability. Hardened concrete can have air voids inside cement paste, mortar and concrete particles in later time, because the excess water can be evaporated by the environment, so the concrete may not have good permeability and durability.

The conceptual design of a concrete mix design based on a spherical shape looks like an approximate method or simple knowledge and is scientific that can be applied to use and to find satisfying mixes for various sizes and gradations of aggregates that meet workability and strength requirements based on important parameters, which are cement paste thickness or mortar thickness. The advantage of this mix design concept can also be used to find the minimum cement component by modification of cement paste thickness and mortar thickness. This concept mix design can be applied for durable concrete mix designs and also applied for designing porous mortar or porous concrete as well.

## 6. ACKNOWLEDGMENT

The author gratefully acknowledge the contributions of students in concrete technology class for their attention by using the concepts of mix design in this paper to change the cement paste thickness and mortar thickness to meet the concrete slump requirement for their workshop since 2016 where average aggregate size concept has been used since 2007.

## 7. REFERENCES

- American Concrete Institute (2022). *Standard Practice for Selecting Proportions for Normal, Heavyweight, and Mass Concrete* (ACI 211.1-22). ACI Manual of Concrete Practice, Part I. Detroit. Michigan.
- American Society for Testing and Materials (2023). *Standard Test Method for Unit Weight and Voids in Aggregate* (ASTM C29-23). Annual Book of ASTM Standard. West Conshohocken. Pennsylvania.
- American Society for Testing and Materials (2023). *Standard Specification for Concrete Aggregates* (ASTM C33-23). Annual Book of ASTM Standard. West Conshohocken. Pennsylvania.
- American Society for Testing and Materials (2024). *Standard Test Method for Specific Gravity and Absorption of Coarse Aggregate* (ASTM C127-24). Annual Book of ASTM Standard. West Conshohocken. Pennsylvania.
- American Society for Testing and Materials (2022). *Standard Test Method for Specific Gravity and Absorption of Fine Aggregate* (ASTM C128-22). Annual Book of ASTM Standard. West Conshohocken. Pennsylvania.
- American Society for Testing and Materials (2009). *Standard Test Method for Air Content of Freshly Mixed Concrete by the Pressure Method* (ASTM C231-09a). Annual Book of ASTM Standard. West Conshohocken. Pennsylvania.
- American Society for Testing and Materials (2024). *Standard Specification for Wire Cloth and Sieves for Testing Purpose* (ASTM E11-24). Annual Book of ASTM Standard. West Conshohocken. Pennsylvania.
- California Department of Transportation (2013). *Concrete Technology Manual*. (Caltrans, June 2013) Sacramento, California.  
<https://dot.ca.gov/-/media/dot-media/programs/engineering/documents/structureconstruction/ctm/sc-ctm-chpt3-a11y.pdf>
- Goswami, I. (2018). *Fundamentals of Engineering FE Civil All-in-One Exam Guide* (1<sup>st</sup> ed.). McGraw-Hill.
- Neville, A.M. (1995). *Properties of Concrete* (4<sup>th</sup> ed.). Addison Wesley Longman.
- Sirinaranun, P. (2014). *Mortar Mixed Design by the Concepts of Spherical Shape on Fine Aggregate and Case Study*. RSU JET, 17 (2), 1-8.  
[https://rsuJET.rsu.ac.th/files/issues/V17N2/15\\_20190627213018.pdf](https://rsuJET.rsu.ac.th/files/issues/V17N2/15_20190627213018.pdf)
- Sun, Q.W. and Zhu, H. (2012). *Design Method of Fly Ash Concrete Mix Proportion Based on Stable Paste-Aggregate Ratio*. Advanced Materials Research, 490/495(4), 2110-2114.  
<https://www.scientific.net/AMR.490-495.2110>
- Yao, J., Huang, S., Xu Y., Gu, C., Liu J., Yang, Y., Ni, T., Kong, D. (2023) *Mix Design of Equal Strength High Volume Fly Ash Concrete with Artificial Neural Network*. Case Studies in Construction Materials, 19.  
<https://doi.org/10.1016/j.cscm.2023.e02294> or  
<https://www.sciencedirect.com/science/article/pii/S2214509523004746>

## 8. BIOGRAPHIES



Sirinaranun, P.  
Asst. Prof. in Civil Engineering,  
Department of Civil Engineering,  
College of Engineering, Rangsit  
University, Pathumthani, Thailand,  
12000

## การศึกษาสมรรถนะและประสิทธิภาพของระบบเซลล์แสงอาทิตย์ภายใต้การบังแสงบางส่วน The Study of Performance and Efficiency in a Solar Photovoltaic System Under Partial Shading

สโรชา ดีวีจิตร<sup>1\*</sup>, ภาพัท รัตนกลางเมือง<sup>2</sup>, สมพร เรืองสินชัยวานิช

Sarochoa Deevijit<sup>1\*</sup>, Phaphat Rattanaklangmueang<sup>2</sup>, Somporn Ruangsinchaiwanich

ภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยนเรศวร

Department of Electrical and Computer Engineering, Faculty of Engineering, Naresuan University

\* Corresponding author e-mail: Sarochad912@gmail.com

(Received: 20 February 2025, Revised: 3 April 2025, Accepted: 18 April 2025)

### บทคัดย่อ

ในปัจจุบัน การแสวงหาแหล่งพลังงานทางเลือกที่ยั่งยืนเป็นสิ่งสำคัญ เพื่อทดแทนพลังงานจากเชื้อเพลิงฟอสซิลที่ลดลงและมีผลกระทบต่อสิ่งแวดล้อม พลังงานแสงอาทิตย์ได้รับการพัฒนาอย่างกว้างขวางผ่านเทคโนโลยีแผงเซลล์แสงอาทิตย์ (Solar Cell) ซึ่งแปลงพลังงานแสงเป็นพลังงานไฟฟ้า โดยเป็นพลังงานสะอาดที่ไม่ก่อมลภาวะและสามารถผลิตได้ต่อเนื่องในพื้นที่ที่มีแสงแดดเพียงพอ อย่างไรก็ตาม การบดบังแสงจากเศษใบไม้ ร่มเงาของต้นไม้ อาคารสูง หรือเมฆ สามารถลดประสิทธิภาพของโซลาร์เซลล์ได้ งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาผลกระทบของการบังแสงบางส่วนต่อประสิทธิภาพการผลิตไฟฟ้าจากแสงอาทิตย์ โดยทดสอบในสภาวะความเข้มแสงตั้งแต่ 200 – 1000 W/m<sup>2</sup> ด้วยเซลล์แสงอาทิตย์ขนาด 300 W จำนวน 8x6 ตัว เชื่อมต่อแบบข้ามสายทั้งหมด (Total Cross Tied, TCT) ทดสอบ 26 รูปแบบการบดบัง แบ่งเป็น 4 กลุ่ม ตามจำนวนเงาบังที่มีตั้งแต่ 3 ถึง 6 โมดูลในรูปแบบต่างๆ โดยใช้โปรแกรม MATLAB/Simulink เพื่อวิเคราะห์ผลการผลิตไฟฟ้า แรงดันไฟฟ้า กระแสไฟฟ้า และประสิทธิภาพการผลิต ผลการทดสอบพบว่า ระบบที่มีการบดบังหลายโมดูลในสตริงเดียวให้ประสิทธิภาพสูงกว่าระบบที่มีการกระจายโมดูลที่ถูกบดบังในหลายสตริง โดยในกรณีที่บดบัง 6 โมดูลในสตริงเดียว ประสิทธิภาพอยู่ในช่วง 87.55 – 97.02% ส่วนรูปแบบที่มีการกระจายโมดูลที่ถูกบดบังในแต่ละสตริง ประสิทธิภาพอยู่ในช่วง 80.88 – 95.56% ดังนั้น สามารถสรุปได้ว่า นอกจากความเข้มแสงแล้ว ลักษณะการบังแสงยังมีบทบาทสำคัญต่อประสิทธิภาพของระบบเซลล์แสงอาทิตย์

**คำสำคัญ:** การบังแสงบางส่วน, ระบบโฟโตโวลเทอิก (PV), ประสิทธิภาพ, รูปแบบการบังแสง

### Abstract

Currently, the search for sustainable alternative energy sources is crucial to replace the declining fossil fuel resources that negatively impact the environment. Solar energy has been widely developed through solar cell technology, which converts light energy into electrical power. As a clean energy source, solar power does not cause pollution and can be continuously generated in areas with sufficient sunlight. However, light obstruction caused by objects such as fallen leaves, tree shadows, tall buildings, or clouds can reduce the efficiency of solar cells. This research aims to investigate the impact of partial shading on the efficiency of solar energy production. The experiment was conducted under light intensities ranging from 200 to 1000 W/m<sup>2</sup>, using 300-watt solar cells,

with 8x6 units connected in a Total Cross Tied (TCT) configuration. A total of 26 shading patterns were tested, grouped into four categories based on the number of shaded modules, ranging from 3 to 6 modules in various configurations. MATLAB/Simulink software was used to analyze the results for electrical power, voltage, current, and production efficiency. The results showed that systems with multiple shaded modules in a single string performed better than systems where the shaded modules were distributed across multiple strings. In the case of shading 6 modules in a single string, the efficiency ranged from 87.55% to 97.02%, while the distributed shading model, where one module was shaded in each string, showed an efficiency range of 80.88% to 95.56%. Therefore, it can be concluded that, in addition to light intensity, the shading configuration also significantly affects the efficiency of solar power systems.

**Keywords:** Partial Shading, Photovoltaic (PV), Efficiency, Shading patterns

## 1. บทนำ

ประเทศไทยได้รับแสงแดดตลอดทั้งปี ซึ่งเป็นปัจจัยสำคัญที่ส่งเสริมให้พลังงานแสงอาทิตย์เป็นแหล่งพลังงานที่มีศักยภาพสูง ลดการพึ่งพาพลังงานฟอสซิลที่มีอยู่อย่างจำกัด อีกทั้งยังเป็นพลังงานสะอาดที่เป็นมิตรต่อสิ่งแวดล้อม ในปัจจุบันแนวโน้มการใช้พลังงานแสงอาทิตย์ในประเทศไทยขยายตัวอย่างรวดเร็ว เนื่องจากความคุ้มค่าทางเศรษฐกิจและประโยชน์ในระยะยาว จากการลดค่าใช้จ่ายด้านพลังงาน รัฐบาลไทยยังมีนโยบายสนับสนุนการใช้พลังงานทดแทนอย่างต่อเนื่อง เช่น โครงการ Solar Rooftop หรือ โซลาร์ภาคประชาชน ซึ่งเปิดโอกาสให้ประชาชนสามารถผลิตไฟฟ้าใช้เองและขายคืนให้กับภาครัฐ กระตุ้นให้มีการติดตั้งโซลาร์เซลล์อย่างแพร่หลาย นอกจากนี้ ยังมี การพัฒนา โซลาร์ฟาร์ม (Solar Farms) ขนาดใหญ่ เพื่อเสริมกำลังการผลิตไฟฟ้าสำหรับระบบโครงข่ายไฟฟ้าของประเทศ ความก้าวหน้าของเทคโนโลยีทำให้เซลล์แสงอาทิตย์มีประสิทธิภาพสูงขึ้นและต้นทุนลดลง ส่งผลให้ประชาชนสามารถเข้าถึงพลังงานแสงอาทิตย์ได้ง่ายขึ้นมากกว่าเดิม ในอนาคตพลังงานแสงอาทิตย์มีแนวโน้มเติบโตอย่างต่อเนื่อง และจะกลายเป็นหนึ่งในพลังงานหลักที่ช่วยเสริมสร้างความมั่นคงทางพลังงานและความยั่งยืนให้กับประเทศไทย

แม้ว่าประสิทธิภาพของเซลล์แสงอาทิตย์จะสูงเพียงใด ยังมีหลายปัจจัยที่ส่งผลต่อการผลิตพลังงานไฟฟ้า เช่น ตำแหน่งการติดตั้งแผง ความเข้มของแสง อุณหภูมิแวดล้อม สภาพอากาศ และความชื้นสัมพัทธ์ ปัจจัยสำคัญอย่างหนึ่งคือการลดลงของ

ความเข้มแสง เนื่องจากมีสิ่งกีดขวางอยู่บริเวณหน้าแผงรับแสง เช่น เศษใบไม้ ฝุ่นละออง ความสกปรก หรือเงาจากต้นไม้ อาคาร และสิ่งปลูกสร้างอื่น ๆ ซึ่งส่งผลต่อกำลังไฟฟ้าสูงสุดและกระแสไฟฟ้าที่ผลิตได้

วิธีการต่อบายพาสไดโอด (Bypass Diode) ขนานกับ PV สามารถช่วยปรับปรุงประสิทธิภาพการผลิตไฟฟ้าของระบบไฟฟ้าเซลล์แสงอาทิตย์ให้เพิ่มขึ้นได้ การศึกษาของ Giyantara et al. (2021) และ Djalab et al. (2018) พบว่าการใช้ Bypass Diode สามารถช่วยลดผลกระทบจากเงาบังได้อย่างมีประสิทธิภาพ และลดปัญหาการสูญเสียจากการไม่สอดคล้อง (Mismatch Loss) ได้ ประกอบกับการเลือกรูปแบบการเชื่อมต่อในระบบให้เหมาะสม ซึ่งรูปแบบการเชื่อมต่อแบบข้ามสายทั้งหมด (Total Cross Tied, TCT) เป็นรูปแบบการเชื่อมต่อเซลล์แสงอาทิตย์ที่สามารถช่วยปรับปรุงประสิทธิภาพของระบบได้มากกว่ารูปแบบการเชื่อมแบบอื่นๆ โดย Amin et al. (2016) และ Darussalam et al. (2017) ได้ทำการศึกษาการเชื่อมต่อรูปแบบต่างๆเปรียบเทียบกัน พบว่า รูปแบบ TCT สามารถช่วยลดปัญหาต่างๆในระบบได้ดีที่สุด


งานวิจัยนี้มุ่งศึกษาผลกระทบของการบดบังบางส่วนที่หน้าแผงรับแสง โดยพิจารณากำลังไฟฟ้า แรงดันไฟฟ้า และกระแสไฟฟ้าที่ผลิตได้ภายใต้เงื่อนไขต่าง ๆ มีการทดสอบการบังแสงรูปแบบที่แตกต่างกันทั้งหมด 26 รูปแบบ โดยใช้แบบจำลองระบบเซลล์แสงอาทิตย์ที่พัฒนาและจำลองผลผ่านโปรแกรม MATLAB/Simulink เพื่อวิเคราะห์ประสิทธิภาพของระบบภายใต้สถานะที่แตกต่างกัน

## 2. เอกสารและงานวิจัยที่เกี่ยวข้อง

### 2.1 แบบจำลองทางคณิตศาสตร์ของโมดูลเซลล์แสงอาทิตย์

วงจรไฟฟ้าของโมดูลเซลล์แสงอาทิตย์ทำหน้าที่แปลงพลังงานแสงอาทิตย์(แสงแดด) ให้เป็นพลังงานไฟฟ้ากระแสตรง (DC) ผ่านกระบวนการที่เรียกว่า ปรากฏการณ์โฟโตอิเล็กทริก (Photovoltaic Effect) ซึ่งเกิดขึ้นภายในเซลล์แสงอาทิตย์ที่ทำจากวัสดุเซมิคอนดักเตอร์ เช่น ซิลิคอน ซึ่งกระแสไฟฟ้าที่ผลิตได้ จะนำไปใช้ในการจ่ายไฟให้กับอุปกรณ์ไฟฟ้าหรือเก็บไว้ใน แบตเตอรี่เพื่อนำไปใช้งานภายหลัง นอกจากนี้ยังสามารถใช้ในการเชื่อมต่อกับอินเวอร์เตอร์เพื่อแปลงไฟฟ้ากระแสตรง (DC) เป็นไฟฟ้ากระแสสลับ (AC) ซึ่งเหมาะสมกับการใช้งานในบ้าน หรืออาคารต่าง ๆ

กระแสไฟฟ้าที่ผลิตได้จากโมดูล PV จะขึ้นอยู่กับความเข้มของแสงอาทิตย์ และอุณหภูมิเป็นหลัก วงจรไฟฟ้าของโมดูล PV แสดงดังรูปที่ 1 ประกอบด้วยแหล่งกำเนิดกระแสไฟฟ้าไดโอด และตัวต้านทานแบบอนุกรมและแบบขนาน ความสัมพันธ์ระหว่างกระแสกับแรงดันไฟฟ้าของโมดูลแสดงดังสมการที่ (1)



รูปที่ 1 วงจรสมมูลของเซลล์แสงอาทิตย์ (PV)

$$I_{pv} = I_{pg} - I_o - \left[ \exp \left( \frac{V + R_{se}I}{V_{ta}} - 1 \right) \right] - \frac{V + R_{se}I}{R_{sh}} \quad (1)$$

$$V_t = \frac{kT}{q} \quad (2)$$

โดยที่  $I_{pv}$  คือ กระแสที่ผลิตได้จาก PV,  $I_{pg}$  คือ กระแสที่เกิดจากแสงที่ตกกระทบบนเซลล์ (Photogenerated Current),  $I_o$  คือ กระแสย้อนกลับของไดโอด (Reverse Saturation Current),  $V$  คือ แรงดันไฟฟ้าขาออก,  $R_{se}$ ,  $R_{sh}$  คือ ตัวต้านทานแบบอนุกรมและแบบขนาน ตามลำดับ a คือ ค่าพารามิเตอร์ที่เกี่ยวข้องกับคุณสมบัติของวัสดุเซลล์,  $V_t$  คือ แรงดันไฟฟ้าเทอร์โมอิเล็กทริก (Thermal Voltage) ซึ่งคำนวณ

ได้จากสมการที่ (2) โดยที่  $k$  คือค่าคงที่ของโบลท์แมน,  $T$  คือ อุณหภูมิสัมบูรณ์ (Kelvin) และ  $q$  คือ ประจุของอิเล็กตรอน

### 2.2 ประสิทธิภาพของแผงเซลล์แสงอาทิตย์

อัตราส่วนระหว่างกำลังไฟฟ้าเอาต์พุต (Output Power) กับกำลังไฟฟ้าอินพุต (Input Power) โดยที่ กำลังไฟฟ้าเอาต์พุต คือพลังงานสูงสุดที่เกิดขึ้นในแต่ละเงื่อนไขการแสง (Global Maximum Power under each PSC) มี หน่วยเป็น วัตต์ (Watts), กำลังไฟฟ้าอินพุตคือการแผ่รังสีแสง (Insolation) มี หน่วยเป็นวัตต์/ตารางเมตร (Watts/m<sup>2</sup>) ซึ่งกระจายไปยังแผงเซลล์แสงอาทิตย์แต่ละแผง คูณกับพื้นที่ของแผงเซลล์ (Module Area) ตามสมการ (3)

$$\text{Efficiency} = \frac{P_{GMPP}}{I \times A} \quad (3)$$

โดยที่  $I$  คือการแผ่รังสีแสงที่ตกกระทบบนแต่ละแผงเซลล์อาทิตย์ และ  $A$  คือพื้นที่ของแผงเซลล์อาทิตย์

เมื่อแสงแดดตกกระทบบนแผงเซลล์แสงอาทิตย์อย่างไม่สม่ำเสมอ อาจทำให้เกิดจุดพลังงานสูงสุดหลายจุด (Multiple Maximum Power Points, MPPs) ซึ่งส่งผลให้ระบบติดตามจุดกำลังไฟฟ้าสูงสุด (Maximum Power Point Tracking, MPPT) ทำงานผิดพลาด และเลือกจุดกำลังไฟฟ้าที่ไม่เหมาะสม (Nandi et al., 2022) ขณะที่ Ibrahim & Anani (2019) พบว่าการบังเงาแบบไม่สมมาตร ทำให้เกิดพลังงานสูญเสียมากกว่าการบังเงาแบบสมมาตร

เพื่อลดปัญหาดังกล่าว Lousuwankun & Jantaramin (2022) ได้นำเสนอวิธีการ MPPT ที่สามารถตรวจจับการบังแสงบางส่วน ซึ่งช่วยลดขอบเขตการค้นหาจุดพลังงานสูงสุดทั่วโลก (Global Maximum Power Point, GMPP) ได้อย่างมีประสิทธิภาพ นอกจากนี้ Mariam et al. (2020) พบว่า เงาบังและฝุ่นสะสม สามารถลดกำลังไฟฟ้าของแผงโซลาร์เซลล์ได้ถึง 21.7% และส่งผลให้เกิด Mismatch Loss ซึ่งอาจนำไปสู่ปรากฏการณ์จุดร้อน (Hotspot Effect) และความเสียหายของเซลล์ PV ในระยะยาว

เพื่อแก้ไขปัญหา Partial Shading Condition (PSC) จึงมีการใช้บายพาสไดโอดเพื่อลดแรงดันย้อนกลับ (Reverse Voltage) ซึ่งเป็นสาเหตุของ Hotspot Effect การศึกษาของ Giyantara et al. (2021) พบว่าการบังเงาบางส่วนอาจลด

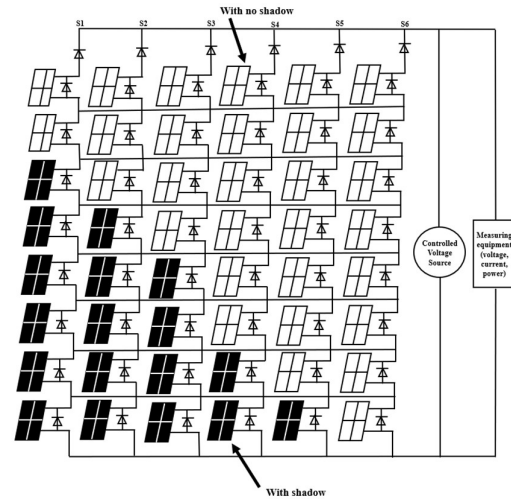
กำลังไฟฟ้าสูงสุดจาก 298.50W เหลือเพียง 141.13W และการใช้บายพาสไดโอดสามารถช่วยลดผลกระทบจากเงาบังได้อย่างมีประสิทธิภาพ เช่นเดียวกับ Djalab et al. (2018) ได้กล่าวว่า บายพาสไดโอดสามารถช่วยลดปัญหาการสูญเสียจากการไม่สอดคล้องได้อย่างมีประสิทธิภาพ

สำหรับโครงสร้างการเชื่อมต่อแบบข้ามสายทั้งหมด (Total Cross Tied, TCT) ได้รับการพัฒนาเพื่อเพิ่มประสิทธิภาพจากโครงสร้างอนุกรม-ขนาน (Series-Parallel) โดยการเพิ่มการเชื่อมโยงภายใน ทำให้กระแสสามารถไหลผ่านเส้นทางอื่นได้ ลด Mismatch Loss และเพิ่มประสิทธิภาพในการผลิตพลังงาน Amin et al. (2016) ศึกษาการจัดเรียงแผงโซลาร์เซลล์แบบต่างๆ เช่น อนุกรม (Series), อนุกรม-ขนาน (Series-Parallel) และแบบข้ามสายทั้งหมด (Total Cross Tied) พบว่า TCT ให้ประสิทธิภาพสูงสุดภายใต้ PSC เช่นเดียวกับ Darussalam et al. (2017) ที่พบว่า TCT ช่วยลดปัญหาแรงดันตกในบางโมดูล โดยการกระจายกระแสไฟฟ้าไปยังเส้นทางอื่น แทนที่โมดูลที่ได้รับแสงน้อยจะเป็นตัวจำกัดกระแส

นอกจากนี้ Abdulmawjood et al. (2022) ยังพบว่า โครงสร้าง TCT และการเชื่อมต่อแบบสะพานเชื่อม (Bridge Link) มีประสิทธิภาพสูงสุดภายใต้ PSC โดยช่วยลดการสูญเสียจากการไม่สอดคล้องได้ดีกว่าการใช้โครงสร้างอนุกรม หรือ อนุกรม-ขนาน อย่างไรก็ตาม แม้ว่าบายพาสไดโอดจะช่วยลดผลกระทบจากเงาบังได้ แต่จำเป็นต้องออกแบบอย่างเหมาะสม เพื่อลดการเกิดแรงดันตกและเพิ่มประสิทธิภาพของระบบ


### 3. วิธีการดำเนินการวิจัย

โมดูลเซลล์แสงอาทิตย์ (PV) จำนวนทั้งหมด 48 โมดูล แต่ละโมดูลมีขนาด 300 W ทำการเชื่อมต่อแบบข้ามสายทั้งหมด โดยต่อแบบขนาน 6 แถว และแต่ละแถวต่อแบบอนุกรม 8 ตัว กำลังผลิตรวม 14.4 kW แสดงดังรูปที่ 2 และมีการต่อบายพาสไดโอดอนุกรมที่ต้นสายและต่อขนานกับเซลล์แสงอาทิตย์ทุกตัว เพื่อป้องกันกระแสไหลย้อนกลับ ที่อาจทำให้อุปกรณ์อื่นๆ เสียหายได้




รูปที่ 2 ระบบเซลล์แสงอาทิตย์

รูปที่ 3 (ก), (ข) แสดงกราฟความสัมพันธ์ระหว่างกระแสไฟฟ้าต่อแรงดันไฟฟ้า (I-V) และกำลังไฟฟ้าต่อแรงดันไฟฟ้า (P-V) ของระบบเซลล์แสงอาทิตย์ ตามลำดับ ที่อุณหภูมิคงที่และแสงในระดับที่แตกต่างกัน ตั้งแต่ 200 – 1000 W/ m<sup>2</sup> สำหรับงานวิจัยนี้ใช้โมดูล PV ของ CS3K-300P ในการทดสอบ ซึ่งพารามิเตอร์ที่ใช้แสดงดัง ตารางที่ 1 และขั้นตอนการดำเนินการวิจัยแสดงดังรูปที่ 4



(ก)



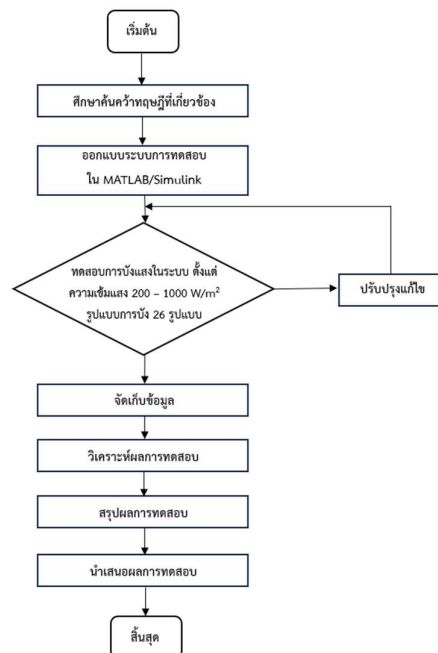
(ข)

รูปที่ 3 กราฟคุณลักษณะเฉพาะของ (ก) I-V (ข) P-V ของโมดูลเซลล์แสงอาทิตย์ภายใต้สภาวะการรับแสงที่แตกต่างกัน

ตารางที่ 1 ข้อมูลจำเพาะของโมดูลเซลล์แสงอาทิตย์

Parameter	Value
Maximum Power (W)	300.186
Open circuit voltage ( $V_{oc}$ )	39.3
Short-circuit current ( $I_{sc}$ )	9.65
Voltage at maximum power point $V_{mp}$ (V)	32.7
Current at maximum power point $I_{mp}$ (A)	9.18
Temperature coefficient of $V_{oc}$ (%deg.C)	- 0.28
Temperature coefficient of $I_{sc}$ (%deg.C)	0.05

W = watt, V = volt, A = ampere.



รูปที่ 4 แผนภาพขั้นตอนการดำเนินการวิจัย

## 4. ผลการทดสอบ

ผลการทดสอบระบบเซลล์แสงอาทิตย์ภายใต้สภาวะที่มีเงาบังบางส่วนแสดงในลักษณะของกราฟความสัมพันธ์ I-V และ P-V โดยพิจารณาค่าความเข้มแสงและรูปแบบการบังที่แตกต่างกัน ณ ที่อุณหภูมิคงที่ที่ 25 องศาเซลเซียส ซึ่งรูปแบบการบังทั้งหมด 26 รูปแบบ สามารถจัดกลุ่มการบังออกเป็น 4 กลุ่มตามจำนวนเซลล์ที่ถูกบังทั้งหมด ได้แก่ กลุ่มที่มีเงาบัง 3 โมดูล, 4 โมดูล, 5 โมดูล และ 6 โมดูล และตารางที่ 2 แสดงรายละเอียดของรูปแบบการบังแสงของโมดูลเซลล์แสงอาทิตย์ในระบบ

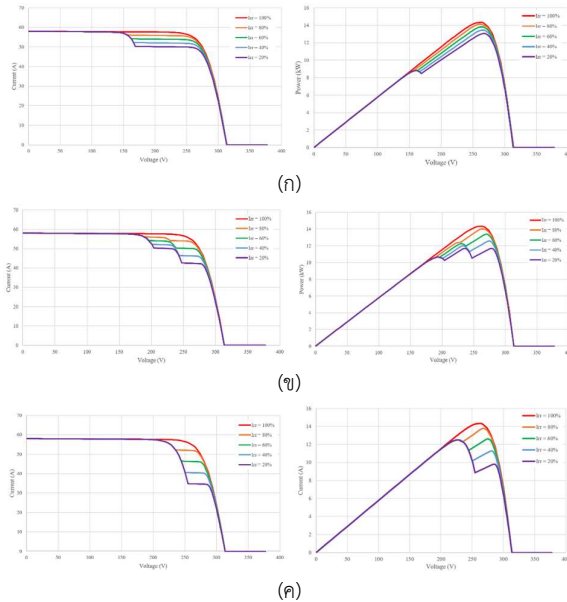
ตารางที่ 2 รูปแบบการบังแสงของระบบเซลล์แสงอาทิตย์

No. Shading pattern	Total Shading module	Number of Shading modules (Nm)					
		Assembly 1	Assembly 2	Assembly 3	Assembly 4	Assembly 5	Assembly 6
1	3	3	0	0	0	0	0
2	3	2	1	0	0	0	0
3	3	1	1	1	0	0	0
4	4	4	0	0	0	0	0
5	4	3	1	0	0	0	0
6	4	2	2	0	0	0	0
7	4	2	1	1	0	0	0
8	4	1	1	1	1	0	0
9	5	5	0	0	0	0	0
10	5	4	1	0	0	0	0
11	5	3	2	0	0	0	0
12	5	3	1	1	0	0	0
13	5	2	2	1	0	0	0
14	5	2	1	1	1	0	0
15	5	1	1	1	1	1	0
16	6	6	0	0	0	0	0
17	6	5	1	0	0	0	0
18	6	4	2	0	0	0	0
19	6	4	1	1	0	0	0
20	6	3	3	0	0	0	0
21	6	3	2	1	0	0	0
22	6	3	1	1	1	0	0
23	6	2	2	2	0	0	0
24	6	2	2	1	1	0	0
25	6	2	1	1	1	1	0
26	6	1	1	1	1	1	1

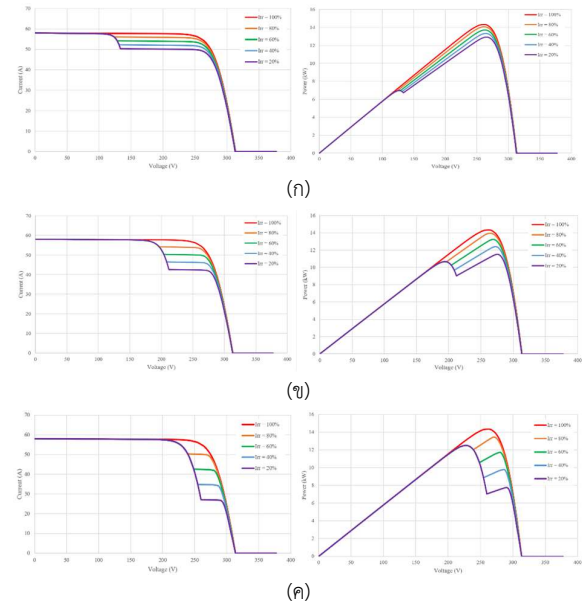
### 4.1 การทดสอบกลุ่มที่ 1

พิจารณารูปแบบกลุ่มที่ 1 มีเงาบัง ทั้งหมด 3 โมดูล ได้แก่ รูปแบบการบังที่ 1, 2, และ 3 กราฟความสัมพันธ์ I-V และ P-V แสดงดัง รูปที่ 5 (ก), (ข), และ (ค) ตามลำดับ จากการทดสอบพบว่า เมื่อเกิดเงาบังที่หน้าแผง ทำให้ความสามารถในการรับแสงลดลง ผลการผลิตกำลังไฟฟ้าและกระแสไฟฟ้าค่อยๆ ลดลง ในแรกเริ่มสามารถผลิตกระแสไฟฟ้าได้ประมาณ 57 A แต่เมื่อผ่านไปที่แรงดันประมาณ 150 V กระแสไฟฟ้าที่ความเข้มแสงต่างๆ เริ่มมีการเปลี่ยนแปลง พิจารณาที่ความเข้มแสง 200 W/m<sup>2</sup> กรณีการเกิดเงารูปแบบที่ 1 (มีเงาบังโมดูลในสตริงเดียวกัน 3 โมดูล) กระแสไฟฟ้าลดลงเหลือ 50 A ที่แรงดันไฟฟ้า 170 V ในขณะที่รูปแบบที่ 2 (โมดูลสตริงที่หนึ่งเงาบัง 2 โมดูล และสตริงที่สองเงาบัง 1 โมดูล) กระแสไฟฟ้าเริ่มลดลงที่ 50 A ที่ 205 V และลดลงอีกเหลือ 42 A ที่แรงดัน 250 V และรูปแบบที่ 3 (มีเงาบัง 1 โมดูลในสามสตริง) กระแสไฟฟ้าลดลงเหลือ 34 A ที่แรงดัน 255 V ทางฝั่งของกำลังไฟฟ้ารูปแบบที่ 3 กำลังไฟฟ้าที่ผลิตได้ลดลงอย่างมากเมื่อเทียบกับรูปแบบอื่นๆ โดยกำลังไฟฟ้าผลิตสูงสุดของรูปแบบที่ 3 วงจรสามารถผลิตกำลังไฟฟ้าได้เพียง 12.5 kW





**รูปที่ 5** กราฟคุณลักษณะเฉพาะของ I-V และ P-V  
(ก) รูปแบบที่ 1 (ข) รูปแบบที่ 2, (ค) รูปแบบที่ 3




**รูปที่ 6** กราฟคุณลักษณะเฉพาะของ I-V และ P-V (ก) รูปแบบที่ 4  
(ข) รูปแบบที่ 6, (ค) รูปแบบที่ 8

#### 4.2 การทดสอบกลุ่มที่ 2


พิจารณาแบบกลุ่มที่ 2 มีการบดบังบนหน้าแผงเซลล์แสงอาทิตย์ ทั้งหมด 4 โมดูล ได้แก่ รูปแบบการบดบังที่ 4, 6, และ 8 กราฟความสัมพันธ์ I-V และ P-V แสดงดัง รูปที่ 6 (ก), (ข), และ (ค) ตามลำดับ จากการทดสอบการมีเงาบังที่หน้าแผง 4 โมดูลในวงจรเซลล์แสงอาทิตย์ โดยพิจารณาที่ความเข้มแสง  $200 \text{ W/m}^2$  รูปแบบที่ 4 (เซลล์แสงอาทิตย์มีเงาบังสตรึงเดียวกัน 4 โมดูล) พบว่ากระแสไฟฟ้าลดลงเหลือประมาณ 50 A ที่แรงดัน 133 V , รูปแบบที่ 6 (เซลล์แสงอาทิตย์มีเงาบังสตรึงที่หนึ่ง 3 โมดูล และสตรึงที่สอง 1 โมดูล) กระแสไฟฟ้าลดลงเหลือประมาณ 42 A ที่แรงดัน 213.67 V และรูปแบบที่ 8 (เซลล์แสงอาทิตย์โมดูลมีเงาบัง 1 โมดูลในสี่สตรึง) กระแสไฟฟ้าลดลงเหลือประมาณ 27 A ที่แรงดัน 261 V เช่นเดียวกันกับกำลังไฟฟ้าที่ผลิตได้ รูปแบบที่ 4 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 12.9 kW รูปแบบที่ 6 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 11.5 kW และ รูปแบบที่ 8 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 12.5 kW และเมื่อมีเงาบังส่งผลให้กำลังไฟฟ้าลดลงไปที่ 7 kW ที่แรงดัน 260 V ทั้งนี้เมื่อแรงดันเพิ่มขึ้นแต่กระแสและกำลังไฟฟ้ากลับลดลง เป็นผลมาจากความเข้มแสงที่ลดลงและรูปแบบที่ถูกเงาบัง

#### 4.3 การทดสอบกลุ่มที่ 3


พิจารณาแบบกลุ่มที่ 3 มีการบดบังแสง ทั้งหมด 5 โมดูล ได้แก่ การบดบังที่ 9, 11, 13 และ 15 กราฟความสัมพันธ์ I-V และ P-V แสดงดัง รูปที่ 7 (ก), (ข), (ค) และ (ง) ตามลำดับ จากการบดบังแสงที่ 5 โมดูล พิจารณาที่ความเข้มแสง  $200 \text{ W/m}^2$  รูปแบบที่ 9 (มีการบังแสงในสตรึง 5 ตัว) กระแสไฟฟ้าลดลงเหลือ 50 A ที่แรงดัน 98 V, รูปแบบที่ 11 (มีการบังแสง 3 โมดูล และสตรึงที่สอง 2 โมดูล) กระแสไฟฟ้าลดลงเหลือประมาณ 42 A ที่แรงดัน 214 V, รูปแบบที่ 13 (เซลล์แสงอาทิตย์โมดูลสตรึงที่หนึ่งเงาบัง 2 โมดูล สตรึงที่สองเงาบัง 2 โมดูลและสตรึงที่สามเงาบัง 1 โมดูล) กระแสไฟฟ้าลดลงเหลือประมาณ 34 A ที่แรงดัน 255 V และรูปแบบที่ 15 (เซลล์แสงอาทิตย์โมดูลมีเงาบัง 1 โมดูลในห้าสตรึง) กระแสไฟฟ้าลดลงเหลือประมาณ 19 A ที่แรงดัน 265 V สำหรับกำลังไฟฟ้าที่ผลิตได้ รูปแบบที่ 9 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 12.77 kW รูปแบบที่ 11 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 11.45 kW รูปแบบที่ 13 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 10.65 kW และรูปแบบที่ 15 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 12.5 kW โดยที่แรงดันตั้งแต่ 260 V เป็นต้นไปกำลังไฟฟ้าลดลงเหลือประมาณ 5 kW




(ก)



(ข)



(ค)




(ง)


รูปที่ 7 กราฟคุณลักษณะเฉพาะของ I-V และ P-V (ก) รูปแบบที่ 9 (ข) รูปแบบที่ 11, (ค) รูปแบบที่ 13, (ง) รูปแบบที่ 15

#### 4.4 การทดสอบกลุ่มที่ 4


พิจารณารูปแบบกลุ่มที่ 4 การบัดบังบนหน้าแผงเซลล์แสงอาทิตย์ ทั้งหมด 6 โมดูล ได้แก่ รูปแบบการบัดบังที่ 16, 20, 23 และ 26 กราฟความสัมพันธ์ I-V และ P-V แสดงดัง รูปที่ 8 (ก), (ข), (ค) และ (ง) ตามลำดับ จากการทดสอบการมีเงาบังที่หน้าแผง 6 โมดูลในวงจร เซลล์แสงอาทิตย์ พิจารณาที่ความเข้มแสง  $200 \text{ W/m}^2$  รูปแบบที่ 16 (มีการบังแสง 6 โมดูลในหนึ่งสตริง) กระแสไฟฟ้ามีการลดลง 50 A ที่แรงดัน 65 V, รูปแบบที่ 20 (โมดูลสตริงที่หนึ่งเงาบัง 3 โมดูล และสตริงที่สองเงาบัง 3 โมดูล) กระแสไฟฟ้าลดลงเหลือ 42 A ที่แรงดัน 175 V, รูปแบบที่ 23 (โมดูลสตริงที่หนึ่งเงาบัง 2 โมดูล สตริงที่สองเงาบัง 2 โมดูลและสตริงที่สามเงาบัง 2 โมดูล) กระแสไฟฟ้าลดลงเหลือ 34 A ที่แรงดัน 219 V และรูปแบบที่ 26 (เซลล์แสงอาทิตย์โมดูลมีเงาบัง 1 โมดูลในหกสตริง) กระแสไฟฟ้าลดลงเหลือ 11 A ที่แรงดัน 270 V สำหรับกำลังไฟฟ้าที่ผลิตได้ รูปแบบที่ 16 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 12.6 kW, รูปแบบที่ 20 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 11.3 kW, รูปแบบที่ 23




(ก)



(ข)



(ค)




(ง)

รูปที่ 8 กราฟคุณลักษณะเฉพาะของ I-V และ P-V (ก) รูปแบบที่ 16 (ข) รูปแบบที่ 20, (ค) รูปแบบที่ 23, (ง) รูปแบบที่ 26


สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 10.6 kW ก่อนที่ กำลังไฟฟ้าตกลงเหลือประมาณ 9.5 kW และรูปแบบที่ 26 สามารถผลิตกำลังไฟฟ้าได้สูงสุดที่ 12.5 kW โดยที่แรงดันตั้งแต่ 270 V เป็นต้นไปกำลังไฟฟ้าลดลงเหลือประมาณ 3.2 kW

#### 4.5 ประสิทธิภาพของระบบเซลล์แสงอาทิตย์


ประสิทธิภาพการผลิตไฟฟ้าของวงจรเซลล์แสงอาทิตย์ที่มีรูปแบบเงาบังที่หน้าแผงและความเข้มแสงที่ต่างกันแสดงดัง รูปที่ 9 - 12




รูปที่ 9 ประสิทธิภาพระบบเซลล์แสงอาทิตย์ที่โมดูลถูกบัง 3 โมดูล



รูปที่ 10 ประสิทธิภาพระบบเซลล์แสงอาทิตย์ที่โมดูลถูกบดบัง 4 โมดูล



รูปที่ 11 ประสิทธิภาพระบบเซลล์แสงอาทิตย์ที่โมดูลถูกบดบัง 5 โมดูล



รูปที่ 12 ประสิทธิภาพระบบเซลล์แสงอาทิตย์ที่โมดูลถูกบดบัง 6 โมดูล

ทั้งนี้สามารถแบ่งกลุ่มข้อมูลตามจำนวนเซลล์แสงอาทิตย์ ที่มีเงาบังในระบบได้ 4 กลุ่ม ได้แก่ กลุ่มที่มีเงาบัง 3 โมดูล, 4 โมดูล, 5 โมดูล และ 6 โมดูลจากผลการทดสอบกลุ่มที่ 1 (เงาบัง 3 โมดูล) พบว่า รูปแบบที่ค่าประสิทธิภาพลดลงมากที่สุด คือ รูปแบบที่ 3 ที่ความเข้มแสง  $200 \text{ W/m}^2$  ประสิทธิภาพอยู่ที่

90.84% สำหรับการทดสอบกลุ่มที่ 2 (เงาบัง 4 โมดูล) พบว่า รูปแบบที่ค่าประสิทธิภาพลดลงมากที่สุด คือ รูปแบบที่ 8 ที่ความเข้มแสง  $200 \text{ W/m}^2$  ประสิทธิภาพอยู่ที่ 87.58% สำหรับการทดสอบกลุ่มที่ 3 (เงาบัง 5 โมดูล) พบว่า รูปแบบที่ค่าประสิทธิภาพลดลงมากที่สุด คือ รูปแบบที่ 8 ที่ความเข้มแสง  $200 \text{ W/m}^2$  ประสิทธิภาพอยู่ที่ 87.58% สำหรับการทดสอบกลุ่มที่ 3 (เงาบัง 5 โมดูล) พบว่า รูปแบบที่ค่าประสิทธิภาพลดลงมากที่สุด คือ รูปแบบที่ 15 ที่ความเข้มแสง  $200 \text{ W/m}^2$  ประสิทธิภาพอยู่ที่ 84.26% และการทดสอบกลุ่มที่ 4 (เงาบัง 6 โมดูล) พบว่า รูปแบบที่ค่าประสิทธิภาพลดลงมากที่สุด คือ รูปแบบที่ 26 โดยที่ความเข้มแสง  $200 \text{ W/m}^2$  ประสิทธิภาพอยู่ที่ 80.88% จากผลการทดสอบเห็นได้ชัดว่ารูปแบบที่ เซลล์แสงอาทิตย์ มีเงาบังแบบกระจายตัวในหลายสตรึงจะส่งผลให้ประสิทธิภาพของวงจรลดลงมากกว่าในรูปแบบเงาบังอื่นๆ และประสิทธิภาพจะยิ่งลดมากขึ้นอีกหากความเข้มแสงที่ได้รับมีค่าน้อยลง

## 5. สรุปผลการทดสอบ

การผลิตพลังงานไฟฟ้าจากเซลล์แสงอาทิตย์ขึ้นอยู่กับองค์ประกอบหลายอย่าง โดยมีองค์ประกอบที่สำคัญ คือ ความเข้มแสง และส่งผลโดยตรงต่อกระแสไฟฟ้าและแรงดันไฟฟ้าภายในระบบ หากความเข้มแสงลดลง ย่อมทำให้ประสิทธิภาพของระบบลดลงไปด้วย สาเหตุที่ทำให้ความเข้มแสงลดลงเกิดจากการบดบังของวัตถุต่างๆ เช่น เศษใบไม้ ฝุ่นละออง สิ่งสกปรก รวมถึงเงาจากต้นไม้ อาคาร หรือสิ่งปลูกสร้างอื่นๆ

ในการศึกษานี้ได้ทำการทดสอบการทำงานของวงจร เซลล์แสงอาทิตย์ ภายใต้เงื่อนไขที่แตกต่างกัน โดยออกแบบรูปแบบเงาบังจำนวน 26 รูปแบบ และแบ่งกลุ่มการทดสอบออกเป็น 4 กลุ่ม ตามจำนวนโมดูลที่ถูกบดบัง ได้แก่ 3 โมดูล, 4 โมดูล, 5 โมดูล และ 6 โมดูล ภายในระบบ จากนั้นทำการวิเคราะห์กราฟความสัมพันธ์ I-V และ P-V รวมถึงประสิทธิภาพในการผลิตไฟฟ้า ผลการทดสอบพบว่า ลักษณะการกระจายตัวของโมดูลที่ถูกบดบังส่งผลต่อประสิทธิภาพของระบบ โดยระบบที่มีการบดบังหลายโมดูลในสตรึงเดียวมีประสิทธิภาพสูงกว่าระบบที่มีการกระจายโมดูลที่ถูกบดบังออกไปยังหลายสตรึง แม้ว่าจำนวนโมดูลที่ถูกบดบังจะเท่ากัน โดยในกรณีที่บดบัง 6 โมดูลในสตรึง

เดียว ประสิทธิภาพอยู่ในช่วง 87.55 – 97.02% ส่วนรูปแบบที่มีการกระจายโมดูลที่ถูกบังในแต่ละสตริง ประสิทธิภาพอยู่ในช่วง 80.88 – 95.56% ดังนั้น สามารถสรุปได้ว่า นอกจากความเข้มแสงแล้ว ลักษณะการบังแสงยังมีบทบาทสำคัญต่อประสิทธิภาพของระบบเซลล์แสงอาทิตย์

## 6. กิตติกรรมประกาศ

คณะผู้เขียน ขอขอบคุณ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยนเรศวร สำหรับการสนับสนุน ทั้งบุคลากร เจ้าหน้าที่ เครื่องมือในการทำวิจัย ตลอดจนทุนการศึกษาระดับบัณฑิตศึกษา คณะวิศวกรรมศาสตร์ ประจำปี 2565 ของนางสาวสโรชา ตีวจิตโร

## 7. เอกสารอ้างอิง

- Abdulmawjood, K., Alsadi, S., Refaat, S. S., & Morsi, W. G. (2022). Characteristic Study of Solar Photovoltaic Array Under Different Partial Shading Conditions. IEEE Access.
- Aicha, D., Nouredine, B., Mohamed, M. R., & Imad, M. (2018). Study of the effects of partial shading on PV array. IEEE.
- Amin, M., Bailey, J., Tapia, C., & Thodimeladine, V. (2016). Comparison of PV Array Configuration Efficiency under Partial Shading Condition. IEEE Conference.
- Arindam, N., Abhranil, M., Alivarani, M., & Chidurala, S. (2022). Analysis of effect of partial shading on PV array and location of local maxima in PV characteristics. 2nd International Conference on Power Electronics & IoT Applications in Renewable Energy and Its Control (PARC), IEEE.
- Avijit, S., Naznin, N. N. (2019). Effect of Partial Shading on the Performance of Solar PV Module and Impact of Bypass Diode in Performance Enhancement. 5th International Conference on Advances in Electrical Engineering (ICAEE), Dhaka, Bangladesh. IEEE.
- Darussalam, R., Pramana, R. I., & Rajani, A. (2017). Experimental Investigation of Serial Parallel and Total-Cross-Tied Configuration Photovoltaic Under Partial Shading Conditions. 2017 International Conference on Sustainable Energy Engineering and Application (ICSEEA).
- Desai, A. A., & Mikkili, S. (2022). Modeling and Analysis of PV Configurations to Extract Maximum Power Under Partial Shading Conditions. CSEE Journal of Power and Energy Systems.
- Giyantara, A., Wisyahyadi, R. B. R., & Priyanto, Y. T. K. (2021). Analysis of Partial Shading Effect on Solar Panel Power Output. Journal of Physics: Conference Series, 1726(1), 012022.
- Haider, I., & Nader, A. (2019). Variation of the performance of a PV panel with the number of bypass diodes and partial shading patterns. 5th International Conference on Power Generation Systems and Renewable Energy Technologies (PGSRET), Turkey. IEEE.
- Ibrahim, H., & Anani, N. (2019). Variation of the performance of a PV panel with the number of bypass diodes and partial shading patterns. Proceedings of the 5th International Conference on Power Generation Systems and Renewable Energy Technologies (PGSRET), Turkey. IEEE.
- Lousuwankun, P., & Jantharamin, N. (2022). Maximum-power-point tracking for photovoltaic arrays with partial-shading detection. Naresuan University Engineering Journal, 17(1), 6-14.
- Maharana, S. M., Mohapatra, A., Saiprakash, C., & Kundu, A. (2020). Performance Analysis of Different PV Array Configurations under Partial Shading Condition. IEEE International Conference on Computational Intelligence for Smart Power System and Sustainable Energy (CISPSSE-2020).
- Mughees, M., Rasheed, A., Sadaf, M., Daniel, K., & Khan, S. (2020). Impact of Shading, Dust Accumulation, and Temperature Rise on the Performance of Solar PV: The Case of Pakistan. IEEE Conference.
- Pradhan, R., & Kar, S. (2020). A Comprehensive Study of Partial Shading Effect on the Performance of PV Array with Different Configuration. ICRESIG-2020, Bhubaneswar, India.