
Informe Final de la Estadía de Investigación Becas BAYLAT - Alemania

Asesor de Investigación en Baviera	: prof. Dr. Markus U. Mock
Becario	: Br. Fidel Indalecio Mamani Maquera
Universidad Asociada en Baviera	: University of Applied Sciences Landshut
Periodo de Estadía	: Invierno 2019/2020
Fecha de Inicio de la Investigación	: 15 de Septiembre del 2019
Fecha de Finalización de la Investigación	: 15 de Febrero del 2020

Lima - Perú, 24 de Septiembre del 2020

Sistema Inteligente para la Predicción Cuantificada de Generación de Energía de un Sistema Fotovoltaico

Resumen

En este documento se presenta el informe de investigación realizado en Baviera, Alemania gracias a una beca otorgada por el Centro Universitario de Baviera para América Latina (BAYLAT) al estudiante universitario de Perú, Fidel Indalecio Mamani Maquera. La investigación realizada en Baviera, Alemania ha tenido una duración de cinco meses y se ha llevado a cabo durante el invierno 2019/2020 en la universidad, University Applied of Sciences Landshut (Hochschule Landshut). El objetivo principal de dicha investigación fue diseñar e implementar un sistema inteligente, tolerante a fallas y eficiente en la predicción de la generación cuantificada de energía en un sistema fotovoltaico. El sistema inteligente también cuenta con un sistema de alertas y monitoreo junto a la integración de otros dos sistemas, una integración con el sistema existente actual de gestión de energía (EMS) y otra integración con el sistema meteorológico local, Deutscher Wetterdienst (DWD). El propósito principal de construir un sistema como tal es para mejorar la administración de la energía eléctrica. En el documento también se describe las experiencias adquiridas y comentarios sobre el desarrollo profesional y personal alcanzado por parte del becario.

Índice de contenido

Resumen	2
Introducción	4
Objetivos	4
Objetivo General	4
Objetivos Específicos	4
Ejecución de la Investigación	5
Recolección de Datos	5
Análisis y Procesamiento de Datos	5
Diseño e Implementación de Modelos Neuronales para la Predicción de Energía Fotovoltaica	5
Discusión de los Resultados Obtenidos	6
Estado Actual del Proyecto	7
Conocimientos Obtenidos y Experiencias Adquiridas	7
Desarrollo Profesional	7
Desarrollo Personal	8
Conclusiones y Recomendaciones	8
Referencias	9

Introducción

Siendo Alemania uno de los países desarrollados y enfocados en hacer uso de energías renovables para el uso cotidiano y siendo la energía fotovoltaica el tercer tipo de energía más utilizado en Alemania, con un 14% de la energía total utilizada en el país [6], es muy importante poder cuantificar la producción y el consumo de esta energía mediante el uso de sistemas inteligentes que hagan uso de dispositivos de medición de datos en tiempo real y la implementación de sistemas inteligentes que hagan uso de estos datos de medición y que proporcionen información confiable para una mejor distribución de la energía. El profesor y doctor en ciencias de la computación, Markus Mock, es un especialista en dispositivos IoT, manejo y análisis de enormes cantidades de información en un sistema computacional que a su vez viene trabajando en este proyecto desde hace algún tiempo. El problema que se quiere resolver me motivó a ser parte del proyecto ya que en Perú se está incrementado el uso de paneles solares en algunas regiones. Así como también, el adquirir conocimiento para desarrollar nuevas técnicas de procesamiento de datos a gran escala y utilizar este conocimiento en la tesis que vengo realizando en el Perú. El procedimiento que se desarrolló para la ejecución del proyecto se describe y organiza en el documento de la siguiente manera. En la primera parte, se presentan los objetivos planteados al inicio de la investigación. En la segunda parte, se presenta la ejecución del proyecto junto a los métodos utilizados y una discusión de los resultados alcanzados, así como también el estado actual de la investigación. En la tercera parte, se describen los conocimientos obtenidos, las experiencias adquiridas y recomendaciones para los futuros becarios. Finalmente, en la última parte se presentan las conclusiones y recomendaciones para futuros becarios.

1. Objetivos

A continuación se describen el objetivo principal y los objetivos secundarios para esta investigación.

1.1. Objetivo General

Diseñar e implementar un sistema inteligente para la predicción cuantificada de generación de energía de un sistema fotovoltaico procesando datos del centro meteorológico local en tiempo real.

1.2. Objetivos Específicos

- Preparar, analizar y evaluar los datos proporcionados por los centros meteorológicos locales, factores del clima e irradiación local.
- Diseñar e implementar un modelo matemático de redes neuronales para la predicción de generación de energía fotovoltaica.
- Evaluar resultados experimentales del modelo propuesto.
- Evaluar la mejora en la gestión de energía con el uso del sistema inteligente.
- Publicar un artículo de investigación con los resultados obtenidos.

2. Ejecución de la Investigación

En esta sección se describen los procedimientos, métodos y técnicas utilizadas durante la investigación, así como también los resultados obtenidos en cada una de las etapas.

2.1 Recolección de Datos

El proyecto contó con 3 estaciones de paneles solares, la primera y la más grande ubicada en Passau, Baviera, la segunda ubicada en Dingolfing, Baviera y la tercera estación ubicada en Universidad de Landshut, Landshut, Baviera, hermoso lugar donde se llevó a cabo la investigación. Los datos recolectados provienen de estas tres estaciones y se capturan mediante el uso de sensores meteorológicos en dispositivos IoT, así como se emplean en los trabajos relacionados [1, 2, 3]. El valor de estos datos corresponden a factores meteorológicos muy importantes que determinan la producción de energía fotovoltaica; temperatura del aire ($^{\circ}\text{C}$), temperatura del panel solar ($^{\circ}\text{C}$), radiación (W/s^2), velocidad del viento (m/s), presión atmosférica (hPa), precipitación (mm), humedad (%) y energía producida (watts). A diferencia de otras investigaciones que capturan los datos en intervalos de 5, 10, 30, 60 minutos, en el proyecto se hizo la captura de datos en intervalos de 1 segundo, lo cual proporciona 86400 capturas por día y por cada uno de los factores meteorológicos. Así mismo, esto se resume en abundante cantidad de información por día. Por otro lado, también se recolectó datos del centro meteorológico local, Deutscher Wetterdienst (DWD), los datos que este centro proporciona son en intervalos de 30 minutos y se ponen a disposición del público y de manera gratuita después de 3 horas de haber sido registrados, lo que limita la integración de los datos con nuestro sistema de tiempo real, pero fue muy importante para realizar comparaciones.

2.2 Análisis y Procesamiento de Datos

La abundante cantidad de información con la que se ha tenido en el proyecto presenta muchos retos antes de poder ser analizados. Los problemas encontrados fueron; datos que no se registraron por fallas en los dispositivos IoT (especialmente en invierno), también debido a los errores de conexión. Así mismo, se encontró problemas de duplicidad de información para un mismo tiempo y muchos otros problemas. Los problemas fueron resueltos mediante la aplicación de un modelo de machine learning [5] lo que facilitó el análisis y durante esta etapa se observó claramente la relación y dependencia existente entre los datos, lo cual facilitó la creación y evaluación de los diferentes modelos de redes neuronales implementados en el proyecto.

2.3 Diseño e Implementación de Modelos Neuronales para la Predicción de Energía Fotovoltaica

Durante la etapa de creación de los modelos neuronales se diseñaron e implementaron múltiples modelos de machine learning y deep learning tomando en cuenta experimentos existentes en el estado del arte [8, 9, 10, 11, 12] y también las observaciones del equipo de trabajo; entre ellos se puede nombrar: regresión lineal, regresión lineal múltiple, regresión lineal con diferentes variaciones, random forest, Long Short Term Memory (LSTM), Convolutional Neural Network (CNN) y otras Redes Neuronales Recurrentes (RNN). Los modelos de machine learning fueron fáciles de

implementar pero también presentan un alto grado de error a diferencia de los modelos de deep learning que fueron muy complejos de implementar e integrar en el sistema, pero también ofrecen un menor grado de error.

A continuación se presenta un cuadro comparativo, Cuadro 1, indicando la efectividad en la predicción de energía para el día siguiente (24 horas) de cada modelo implementado, haciendo uso de datos recolectados durante el invierno 2019/2020 y utilizando métricas conocidas para este tipo de experimentos; Relative Absolute Error (RAE) y Mean Absolute Error (MAE).

Modelos	RAE	MAE(watts)
Modelos Machine Learning		
Regresión Lineal	26.12%	941.24
Regresión Múltiple Lineal	24.32%	923.56
Regresión Múltiple Lineal con variaciones y mejoras	22.04%	891.34
Modelos Deep Learning		
Convolutional Neural Networks (CNN)	23.14%	905.56
Long Short Term Memory (LSTM)	18.78%	776.84
Otras Recurrent Neural Networks (RNN)	20.34%	814.23

Cuadro 1.

Cuadro comparativo de los modelos de machine learning y deep learning desarrollados e implementados en el proyecto de investigación para la predicción de generación de energía fotovoltaica, haciendo uso de datos meteorológicos capturados en invierno.

2.4 Discusión de los Resultados Obtenidos

Durante los experimentos se ha observado que de las 4 estaciones del año, los datos capturados en invierno presentan una mayor dificultad para elaborar un modelo de red neuronal que sea capaz de predecir la generación de energía fotovoltaica de manera fiable, ya que en esta temporada se presenta un mayor número de problemas comparado a otras estaciones, entre los que se puede mencionar; pérdida de datos durante la captura y almacenamiento de estos (hasta en un 800% comparado a la temporada de verano), y los modelos neuronales necesitan un reajuste para esta temporada y un análisis mucho más profundo de otros factores ambientales que influyen directamente en la variación de la efectividad de los modelos neuronales, así como se muestra en el cuadro, Cuadro 1.

En la siguiente figura, Figura 1, se presenta la arquitectura del sistema implementado durante la investigación. Este sistema está basado en una arquitectura serverless (serverless computing) en AWS [15, 16, 17].

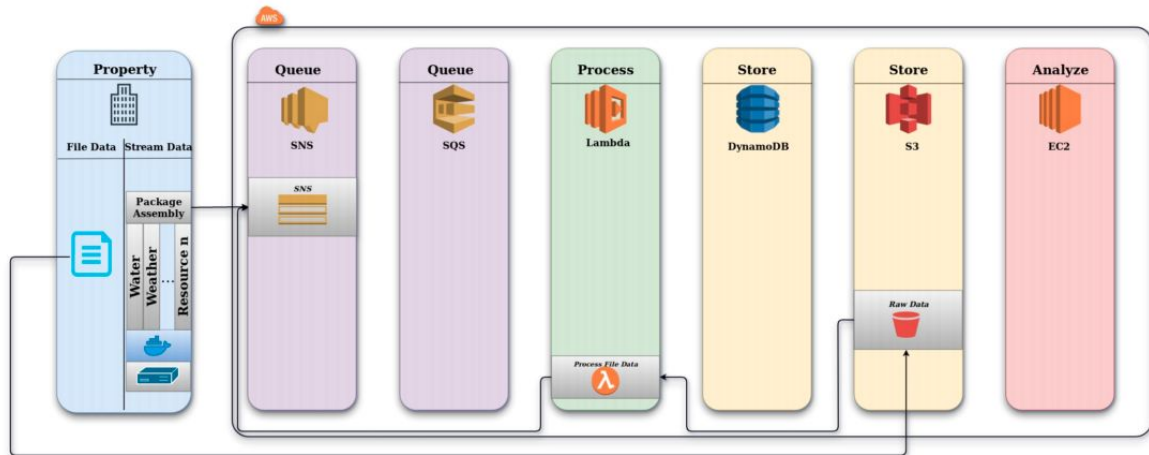


Figura 1.

Arquitectura del sistema implementado para la captura de los datos en tiempo real de las diferentes estaciones de paneles solares, implementado en Amazon AWS (computación sin servidor).

2.5 Estado Actual del Proyecto

El sistema fue implementado e integrado con los modelos de redes neuronales para la captura, procesamiento de datos y predicción futura acerca de la generación de energía fotovoltaica para las estaciones de verano, primavera, otoño e invierno. En esta última se presenta el mayor porcentaje de error en cuanto a la predicción y puede ser mejorado mediante el estudio de otros factores ambientales que afecten a la producción de energía. Así mismo, la pérdida en la captura de información durante esta temporada puede ser mejorada mediante el uso de dispositivos IoT específicamente diseñados para esta temporada.

3. Conocimientos Obtenidos y Experiencias Adquiridas

Quedo profundamente agradecido a BAYLAT por haberme otorgado esta estadía de investigación porque aprendí muchas cosas para mi desarrollo profesional como investigador y también para mi desarrollo personal. Entre los que puedo enumerar en las dos categorías:

3.1 Desarrollo Profesional

1. Los problemas y retos encontrados durante la investigación fueron de motivación a descubrir y crear nuevos modelos neuronales capaces de predecir la generación de energía, especialmente durante el invierno.
2. Utilizar datos con intervalos de medición de 1 segundo ha facilitado poder identificar las diferencias de manera rápida y establecer los retos de manera inmediata, algo que muchas investigaciones en el estado del arte no lo hacen. De esto aprendí que capturar la información de manera confiable es la etapa más importante en un sistema inteligente.
3. Construir un sistema confiable tolerante a fallas y con un sistema de alertas y monitoreo se puede lograr utilizando la suite de AWS en una arquitectura serverless, de esto aprendí que los sistemas que requieran de un alto grado de efectividad en la tolerancia a fallos, una

arquitectura sin servidor (serverless) puede ser una solución muy efectiva y desde la estadía de investigación hasta el presente mejoré mis habilidades utilizando AWS y la arquitectura serverless.

4. Las diferentes técnicas, modelos, métricas que se hicieron uso en el proyecto, me ayudaron a ver claramente la aplicación exacta y precisa de estos en los diferentes problemas de redes neuronales. Despertando una de mis habilidades que no era capaz de ver claramente antes de la investigación, tanto que quiero hacer una maestría como Científico de Datos.

3.2 Desarrollo Personal

1. Aprendí a que podía encontrar personas muy distintas a mí y con pensamientos muy distintos a los míos, pero si entre todos nosotros trabajamos en una misma idea y con un objetivo en común, la diferencia llega a desvanecerse con el tiempo.
2. Aprendí una nueva forma de vida, una que es muy tranquila y relajada basada en la solidaridad, reciprocidad, compromiso y trabajo mutuo.
3. Aprendí a conocerme mejor y que soy más fuerte de lo que pensaba, teniendo siempre en mente acerca de quién quiero ser.
4. Aprendí que realizar investigación es tan vital e importante para el desarrollo de una persona y también para la sociedad y que esta debe ser hecha de manera muy comprometida y siempre buscando la verdad.

4. Conclusiones y Recomendaciones

La investigación realizada en Baviera, Alemania fue una experiencia muy enriquecedora para mi desarrollo profesional y personal que me han comprometido aún más en el área de la investigación. Entre algunas observaciones mejorables puedo citar que durante la investigación solo se tenía un computador de gran desempeño para desarrollar los modelos neuronales con un poder de cálculo limitado, por lo que para desarrollar un modelo neuronal se necesitaba más horas de cómputo y trabajo, pero no fue un problema tan grave. Por otro lado, la universidad no cuenta con afiliación a revistas indizadas por alumno y de manera directa, por lo que sí se requiere de un artículo de investigación o libro en específico, se tiene que solicitar a la biblioteca con anticipación para poder adquirirlos. Por el lado positivo, las primeras semanas fui invitado a realizar un tour por toda Baviera, en diferentes paseos por la región, una experiencia inolvidable junto a hermosos paisajes. Una recomendación que puedo hacer para los futuros becarios es que es muy importante poder aprender el idioma Alemán para tener una integración en la cultura y sociedad alemana de manera inmediata y placentera ya que la experiencia no es la misma cuando se sabe hablar inglés, a pesar de que 8 de cada 10 alemanes hablan Inglés. La universidad fue muy considerada con mi persona, que me ofrecieron aprender Alemán junto a un grupo multicultural del mundo, el idioma es desafiante e interesante, estoy muy agradecido con ellos por tan bonito desafío y por muchas otras cosas que me brindaron, ayuda para el trámite de documentos, visado, alquiler del departamento de estudiantes, etc. Finalmente quiero expresar mi enorme gratitud al Centro Universitario de Baviera para América Latina (BAYLAT) por haberme otorgado tan provechosa experiencia en Baviera, Alemania, de igual forma estoy muy agradecido a mi asesor de investigación, Dr. Markus Mock y al equipo de trabajo quienes siempre me otorgaron su ayuda incondicional tanto para el trabajo y para la relación con la sociedad y de quienes aprendí ideas y costumbres muy valiosas. También quiero agradecer a la

universidad, University of Applied Sciences Landshut (Hochschule Landshut) por los paseos y también por darme toda la facilidad para que el trabajo de investigación fuera productiva y placentera al mismo tiempo. ¡Muchas gracias a todos!

Referencias

- [1]. Das, Utpal Kumar, et al. "Forecasting of photovoltaic power generation and model optimization: A review." *Renewable and Sustainable Energy Reviews* 81 (2018): 912-928.
- [2]. Antonanzas, Javier, et al. "Review of photovoltaic power forecasting." *Solar Energy* 136 (2016): 78-111.
- [3]. Zhang, Jianyuan, et al. "A critical review of the models used to estimate solar radiation." *Renewable and Sustainable Energy Reviews* 70 (2017): 314-329.
- [4]. Means Daniel, et al. "MCutie Weather Based, Irradiance Prediction", (UC Santa Barbara).
- [5]. GÉRON, Aurélien. *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, 2019.
- [6]. IRENA; <https://www.irena.org/Statistics/View-Data-by-Topic/Capacity-and-Generation/Country-Rankings>
- [7]. DWD; https://www.dwd.de/EN/Home/home_node.html
- [8]. SAMPAIO, Priscila Gonçalves Vasconcelos; GONZÁLEZ, Mario Orestes Aguirre. Photovoltaic solar energy: Conceptual framework. *Renewable and Sustainable Energy Reviews*, 2017, vol. 74, p. 590-601.
- [9] ABEDINIA, Oveis; AMJADY, Nima; GHADIMI, Noradin. Solar energy forecasting based on hybrid neural network and improved metaheuristic algorithm. *Computational Intelligence*, 2018, vol. 34, no 1, p. 241-260.
- [10] WANG, Huaizhi, et al. A review of deep learning for renewable energy forecasting. *Energy Conversion and Management*, 2019, vol. 198, p. 111799.
- [11] RODRÍGUEZ, Fermín, et al. Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control. *Renewable energy*, 2018, vol. 126, p. 855-864.
- [12] Yona, Atsushi, et al. "Application of neural network to 24-hour-ahead generating power forecasting for PV system." *2008 IEEE Power and Energy Society General Meeting-Conversion and Delivery of Electrical Energy in the 21st Century*. IEEE, 2008.
- [13] Wang, Kejun, Xiaoxia Qi, and Hongda Liu. "A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network." *Applied Energy* 251 (2019): 113315.
- [14] Sivaneasan, B., C. Y. Yu, and K. P. Goh. "Solar forecasting using ANN with fuzzy logic pre-processing." *Energy procedia* 143 (2017): 727-732.
- [15] McGrath, Garrett, and Paul R. Brenner. "Serverless computing: Design, implementation, and performance." *2017 IEEE 37th International Conference on Distributed Computing Systems Workshops (ICDCSW)*. IEEE, 2017.
- [16] Lloyd, Wes, et al. "Serverless computing: An investigation of factors influencing microservice performance." *2018 IEEE International Conference on Cloud Engineering (IC2E)*. IEEE, 2018.
- [17] Adzic, Gojko, and Robert Chatley. "Serverless computing: economic and architectural impact." *Proceedings of the 2017 11th Joint Meeting on Foundations of Software Engineering*. 2017.