



Proceso de estimación estocástico para la selección de fuentes de energía en una microrred eléctrica

Stochastic estimation for energy selection sources in microgrids

Ignacio Castañeda Fandiño¹, Elvis Gaona García², César Trujillo Rodríguez³

Fecha de recepción: Agosto 28 de 2015

Fecha de aceptación: Septiembre 25 de 2015

Como citar: Castañeda, I., Gaona, E., & Trujillo, C. (2015). Proceso de estimación estocástico para la selección de fuentes de energía en una microrred eléctrica. Revista Tecnura, 19 (CITIE), 137-144. doi: <http://dx.doi.org/10.14483/udistrital.jour.tecnura.2015.ICE.a??>

Resumen

En este artículo se muestran los parámetros a considerar en un algoritmo de estimación estocástico que hace uso de sistemas markovianos orientado a la predicción del estado futuro del sistema de generación de energía en una microrred, con el propósito de inferir la mejor opción que permita la selección de la fuente que genere energía a un grupo de cargas teniendo como parámetros de selección la curva de carga e indicadores que ponderan efectos ecológicos, económicos, disponibilidad y de la capacidad de suministro sobre un determinado valor de carga.

Palabras Claves: Estimación Estocástica, Sistemas Markovianos, Microrredes, Gestión energética.

Abstract

This paper shows several parameters to consider in a stochastic estimation algorithm uses Markov systems aimed at predicting the future state of the power generation system in a microgrid, in order to infer the best option that allows for selection the most appropriate source of energy from the load curve, this selection includes additionally weighted indicators ecological, economic, availability and supply capacity for a given value of load effects.

Keywords: Stochastic Stimulation, Markov Systems, Microgrids, Energy Management.

¹ Ingeniero Electrónico, Magister en Ciencias de la Información y las comunicaciones. Docente de planta Facultad Ingeniería, Universidad Distrital Francisco José de Caldas. Bogotá D.C., Colombia. Contacto: jicnacio@udistrital.edu.co.

² Ingeniero Electrónico, Magister en Ciencias de la Información y las comunicaciones, Doctor (c) en Ingeniería. Docente de planta Facultad Ingeniería, Universidad Distrital Francisco José de Caldas. Bogotá D.C., Colombia. Contacto: egaona@udistrital.edu.co.

³ Ingeniero Electrónico, Magíster en Ingeniería Eléctrica, Doctor en Ingeniería Electrónica. Docente de planta Facultad Ingeniería, Universidad Distrital Francisco José de Caldas. Bogotá D.C., Colombia. Contacto: cltrujillo@udistrital.edu.co.

INTRODUCCIÓN

El análisis de eficiencia energética y de perfiles de carga que presentan los usuarios se enfoca en dos aspectos. El primero trata de definir y modelar los perfiles que presenta la demanda de energía en diferentes contextos, tratando de identificar regularidades y tendencias en los comportamientos. Frecuentemente enfocado a la creación de cambios en los horarios de consumo (Bakker, Bosman, Molderink, Hurink, & Smit, 2010; Ibars, Navarro, & Giupponi, 2010; Kishore & Snyder, 2010; Mohsenian-Rad & Leon-Garcia, 2010; Mohsenian-Rad, Wong, Jatskevich, Schober, & Leon-Garcia, 2010). En un segundo modelo se plantea el análisis de la eficiencia energética y los perfiles de demanda en los usuarios (Ochoa & Harrison, 2011), (Atwa, El-Saadany, Salama, & Seethapathy, 2010). Se ha intentado incrementar la utilidad y el rendimiento de los sistemas, reduciendo a la vez los costos (Bu, Yu, & Liu, 2011), (Conejo, Morales, & Baringo, 2010), el incremento de utilidad de un grupo de usuarios (Hatami & Pedram, 2010), (Samadi, Mohsenian-Rad, Schober, Wong, & Jatskevich, 2010) y el costo versus la utilidad a nivel de producción eléctrica en aplicaciones industriales (Guan, Xu, & Jia, 2010; Liu, 2010).

Los modelos de demanda de energía utilizando procesos estocásticos markovianos y distribuciones de Poisson se han desarrollado por (Bu et al., 2011), quien incluye la asignación mediante fuentes de energía a partir de procesos de decisión markovianos, logrando la reducción de las emisiones de CO₂ al ajustar los costos de emisión de contaminantes. Por otro lado la gestión de energía en redes inteligentes ha hecho uso de métodos de optimización, aprendizaje automático y teoría de juegos. Para optimizar procesos se usan herramientas matemáticas como la programación convexa (Kallitsis, Michailidis, & Devetsikiotis, 2010), (Sortomme, Hindi, MacPherson, & Venkata, 2011) y programación dinámica (Anderson, Boulanger, Powell, & Scott, 2011), (Han, Soo, & Sezaki, 2010). En fuentes de energía renovable se emplea

la programación estocástica, por las fluctuaciones en las fuentes (Clement-Nyngs, Haesen, & Driesen, 2010), (Neely, Tehrani, & Dimakis, 2010) y programación robusta (Conejo et al., 2010). La teoría de juegos ha aportado técnicas de modelamiento para la administración de microrredes cuando los usuarios no son colaborativos. De esta teoría es posible inferir esquemas de comportamiento grupal caracterizadas por tendencias globales en el suministro efectivo.

FUENTES DE GENERACIÓN RENOVABLE

El algoritmo de selección opera tanto sobre las fuentes de generación de energía, como de la carga en una microrred, permitiendo observar el comportamiento de las diferentes variables implicadas. La microrred utilizada como caso de estudio se caracteriza por tener un conjunto de fuentes de energía renovable tales como fotovoltaica, eólica, hidroeléctrica y biomasa; adicionalmente, tiene la opción de incluir generación diésel, baterías, y una carga que pondera el consumo total. Dadas las pequeñas distancias las pérdidas de potencia se consideran mínimas.

Los datos iniciales de las fuentes se toman a intervalos de una hora, sin embargo, para desarrollar un modelo estadístico que pueda aplicarse a un conjunto amplio de datos se hace necesario contar con más muestras de la señal. Mediante una interpolación entre los datos existentes, logrando inferir 5 datos que se encontraban dentro de la tendencia estadística normal de la señal observada. De aquí resultan 144 muestras para cada una de las señales provenientes de las fuentes y carga.

La figura 1 muestra el comportamiento de las fuentes a seleccionar para la generación de energía a intervalo de 10 minutos en la microrred. Para el caso de las baterías y los generadores Diésel, el comportamiento es similar al de la fuente de generación biomasa e hidroeléctrica, debido a que entregan una potencia constante.

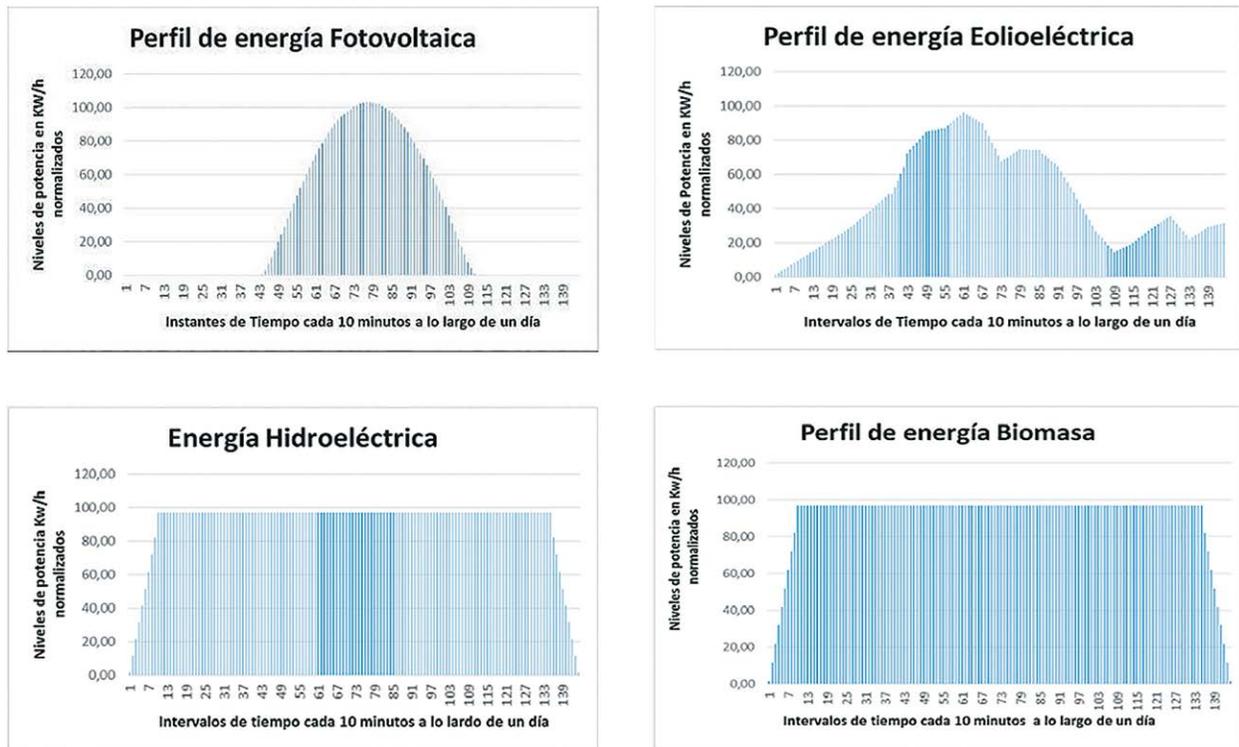


Figura 1. Muestreo del comportamiento de las fuentes renovables.

Fuente: Autoría propia.

Curvas de Carga

La curva de carga se normaliza a una escala de 100, para poder realizar las ponderaciones, lo cual permite mostrar las fluctuaciones que presenta la

carga e incorporarla en el esquema de ponderación general donde todas las variables se consideran dentro del mismo rango de valor. La figura 2 muestra un perfil de carga típico normalizado.



Figura 2. Perfil de carga normalizado para usuario residencial

Fuente: Adaptación de (Public Service Enterprise Group Incorporated, 2013)

Indicadores de Sostenibilidad

El *Índice de Ponderación General para Fuentes y Carga (IPFC)*, se forma a partir de la suma de los índices de cada una de las características definidas para cada fuente. Se tienen ponderaciones entre 0 y 100 para los indicadores de sostenibilidad (Tabla 1). El valor M de la señal de la fuente n en el instante t corresponde a $M(n, t)$. El resultado de tomar el valor $M(n, t)$ y ponderarlo por los índices de ponderación se representa como $MP(n, t)$.

$$MP(n, t) =$$

Muestra Ponderada de la fuente n en instante t (1)

$$= M(n, t)(i_e + i_d + i_c + i_l + i_{vc}) \quad (2)$$

$$IPFC = (i_e + i_d + i_c + i_l + i_{vc}) \quad (3)$$

Donde $M(n, t)$ es el nivel de la señal vista en la fuente n en el instante t , i_e es el efecto ecológico positivo de la fuente, (100 es el máximo nivel de producción limpia y 0 el mínimo); i_d dala disponibilidad de las fuentes de energía en función del porcentaje de tiempo de funcionamiento, (100 máxima y 0 mínima); i_c pondera los costos de producción del tipo de generación (100 es muy económica y 0 muy costosa), i_l da la capacidad de la fuente para soportar la demanda de la carga

Tabla 1. Índices de Ponderación de las Característica de las Fuentes.

Tipo fuente/Indicador ponderación	Ecológico i_e	Disponibilidad i_d	Costos de producción i_c	Carga que soporta i_l
Fotovoltaica	47.06	50	3	10
Eólica	85.3	50	70.83	10
Biomasa	66.6	60	77.6	70
Hidroeléctrica	75.89	90	79.17	90
Baterías	0	70	2	90

Fuente: Autoría propia

Tabla 2. Ponderación Estándar de las Fuentes según Rango de la Carga, icv.

Umbral	Potencia entregada a la carga	Fotovoltaica	Eólica	Biomasa	Diesel	Hidro eléctrica	Batería
		Fuente 1	Fuente 2	Fuente 3	Fuente 4	Fuente 5	Fuente 6
10	De 0 a 10	0,35450268	0,37999586	0,20339713	0,054364747	0,00725599	0,0004836
20	10,1–20	0,45149678	0,36658664	0,14862957	0,030091264	0,00304216	0,00015358
30	20,1–30	0,30673734	0,37778496	0,23234284	0,071354362	0,01094255	0,00083796
40	30,1–40	0,17749672	0,33160753	0,30936063	0,144116039	0,0335248	0,00389428
50	40,1–50	0,08435638	0,2390606	0,3383021	0,239060596	0,08435638	0,01486396
60	50,1–60	0,0321258	0,13810201	0,29645087	0,317769401	0,1700897	0,04546221
70	60,1–70	0,00973947	0,0635093	0,20679788	0,336249353	0,27301307	0,11069093
80	70,1–80	0,0023813	0,02355438	0,11634199	0,286951106	0,35341577	0,21735546
90	80,1–90	0,0004836	0,00725599	0,05436475	0,203397127	0,37999586	0,35450268
100	90,1–100	8,476E-05	0,00192913	0,02192491	0,124428914	0,35262362	0,49900867

Fuente: Autoría propia

(100 es un suministro alto de potencia; 0 indica poca capacidad) e i_{cv} es la ponderación que posee cada fuente para el tipo de carga (cargas de bajo consumo se alimentan por fuentes de bajo nivel de potencia; cargas de alta demanda deben alimentarse por fuentes de alto nivel de suministro de potencia).

Los valores usados en los índices de ponderación son tomados de [11], con el propósito de probar el algoritmo. En la tabla se observa para fuentes fotovoltaicas el efecto ecológico (47.06 %), la disponibilidad (50%), los costos de producción (3%) y un soporte de carga bajo(10%). La carga se selecciona de acuerdo a los niveles de potencia requerida, estos niveles se restringen a un conjunto de 10 rangos que cubren el total normalizado de exigencia de la carga. Las ponderaciones para cada uno de los rangos de la carga se muestran en la Tabla 2.

Se emplea una distribución normal Gaussiana, para describir el espacio de probabilidad requerido en función de parámetros como la media (μ) y la desviación estándar (σ), que son ajustables a los requerimientos del sistema. De esta manera se definen los cambios de selección de un rango de la carga a otro, y da valores de probabilidad de asignación para las fuentes. Se observa un máximo de probabilidad para el punto central, que corresponde a la fuente a seleccionar y da las probabilidades de selección para las fuentes aledañas. En la Figura 3 se muestra un caso particular de la curva Gaussiana al asignar valores de probabilidad a las fuentes aledañas en función de la proximidad que estas presenten al punto central de la distribución. Esta figura presenta para el caso particular $\mu = 3$ y $\sigma = 0.012$, la tercera fuente de energía (biomasa) con una probabilidad máxima de 0.338302 en el intervalo 40.1 a 50, que debe alimentarse con mayor probabilidad por la fuente de energía No. 3. La selección de la fuente más adecuada para la alimentación de la carga en el instante t , donde la selección central corresponde a la fuente de energía No. 3 (máxima probabilidad).

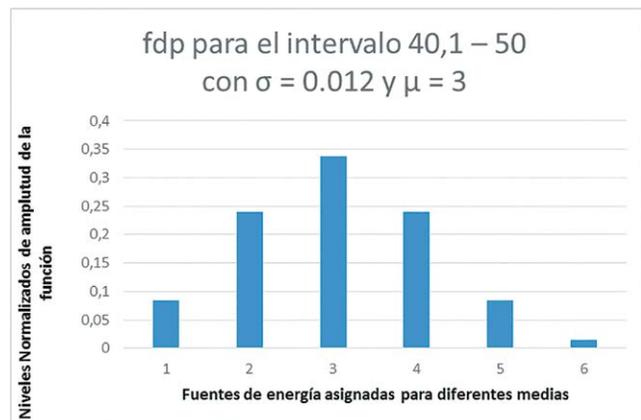


Figura 3. Distribución de probabilidad Gaussiana

Fuente: Autoría propia

Cadena de Markov

En la construcción de la cadena de Markov se usaron los registros estadísticos típicos de cada una de las fuentes. Se seleccionaron 10 intervalos para las señales producidas por cada fuente. Cada uno de los intervalos se caracterizó en función de una probabilidad de ocurrencia P_i , que define la frecuencia relativa con la que un evento se da. De esta manera cada intervalo de señal individual se le asigna una probabilidad estacionaria $P(S_i)$ de los estados S_1, S_2, \dots, S_{10} .

Con estas probabilidades, se estiman las probabilidades condicionales $P(S_i/S_j)$ para los cambios de estado del sistema. Así, $P(S_i/S_j)$ representa la probabilidad de que el sistema cambie a un estado particular S_i en el instante t_i , dada la condición previa de encontrarse en el estado S_j en el instante t_0 . Este es un modelo de inferencia probabilística condicional a partir de un único salto definido desde el estado inmediatamente anterior. Así se obtiene la matriz de inferencia probabilística (Markoviana), dando como resultado una matriz estocástica para cada una de las fuentes y la carga.

RESULTADOS

La matriz markoviana obtenida da la probabilidad a un salto ($T_0 = 10$ minutos) a partir de un estado (nivel) de entrada. Si el nivel de entrada (Valor actual) está, por ejemplo, en el intervalo (60.1 a 70), la probabilidad de que en el siguiente intervalo de tiempo (10 minutos después) la señal cambie a cualquiera de los intervalos, estará dada por la columna de valores de probabilidad que se muestran bajo el intervalo inicial (60.1 a 70). En la tabla 3 se muestran las probabilidades a un salto desde cualquier intervalo. Para obtener inferencias a intervalos de tiempo mayores $t_2, t_3, t_4, \dots, t_n$, se eleva la matriz markoviana a la potencia correspondiente al número de tiempos t contados a partir del estado de tiempo actual. De esta forma para un caso de inferencia a 40 minutos a partir del estado actual se tomaría la potencia cuarta de la matriz markoviana.

CONCLUSIONES

El algoritmo desarrollado permite que se lleven a cabo procesos de optimización de suministro de energía sin alterar las condiciones de uso

tradicionales de los usuarios, ya que considera solo un proceso estadístico de comportamiento típico de variables. Se han encontrado respuestas estadísticas estacionarias de las señales provenientes de las fuentes analizadas del sistema, que permiten inferencias markovianas coincidentes con los valores reales de las muestras de la señal.

Aunque en el sistema se ha considerado una Cadena de Markov de primer orden, se han obtenido resultados de inferencia acertados, principalmente para los puntos de estacionalidad estadística. Sin embargo, en los puntos de inicio y final de la secuencia, se presentan problemas debido a que las fuentes de energía constante como Batería, Biomasa, Hidroeléctrica, deben ajustarse para cubrir todos los valores posibles en el rango considerado. De lo contrario, la Cadena de Markov para estas fuentes daría origen a una matriz con columnas en cero, que indicarían una imposibilidad total de selección para ese valor.

El algoritmo puede perder capacidad de predicción al considerar grandes saltos de tiempo ya que los comportamientos estadísticos de las variables pueden cambiar drásticamente y de manera impredecible. Para mantener un nivel de predicción

Tabla 3. Matriz Markoviana para la Carga $P(S_i/S_j) = P(S_i, S_j)/P(S_j)$ para $T = 10$ minutos

	Rangos de entrada									
	0,0–10	10,1–20	20,1–30	30,1–40	40,1–50	50,1–60	60,1–70	70,1–80	80,1–90	90,1–100
0,0–10	0,62	0	0	0	0	0	0	0	0,04	0,19
10,1–20	0,28	0,48	0	0	0	0	0	0	0	0,03
20,1–30	0,08	0,42	0,62	0	0	0	0	0	0	0
30,1–40	0,0	0,08	0,34	0,79	0	0	0	0	0	0
40,1–50	0	0,	0,03	0,18	0,75	0	0	0	0	0
50,1–60	0	0	0	0,01	0,20	0,68	0	0	0	0
60,1–70	0	0	0	0	0,02	0,22	0,40	0	0	0
70,1–80	0	0	0	0	0	0,07	0,40	0,40	0	0
80,1–90	0	0	0	0	0	0,01	0,15	0,43	0,48	0
90,1–100	0	0	0	0	0	0	0,02	0,14	0,46	0,7
	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00

Fuente: Autoría propia

adecuado es necesario hacer una observación del comportamiento de las variables a una escala de tiempo mayor.

REFERENCIAS

- Anderson, R. N., Boulanger, A., Powell, W. B., & Scott, W. (2011). Adaptive stochastic control for the smart grid. *Proceedings of the IEEE*, 99(6), 1098–1115. doi:10.1109/JPROC.2011.2109671
- Atwa, Y. M., El-Saadany, E. F., Salama, M. M. a., & Seethapathy, R. (2010). Optimal Renewable Resources Mix for Distribution System Energy Loss Minimization. *Power Systems, IEEE Transactions on*, 25(1), 360–370. doi:10.1109/TPWRS.2009.2030276
- Bakker, V., Bosman, M. G. C., Molderink, a., Hurink, J. L., & Smit, G. J. M. (2010). Demand Side Load Management Using a Three Step Optimization Methodology. *Smart Grid Communications (SmartGridComm), 2010 First IEEE International Conference on*, 431–436. doi:10.1109/SMARTGRID.2010.5622082
- Bu, S., Yu, F. R., & Liu, P. X. (2011). Stochastic Unit Commitment in Smart Grid Communications. *IEEE INFOCOM 2011 Workshop on Green Communications and Networking*, 307–312. doi:10.1109/INFCOMW.2011.5928828
- Clement-Nyns, K., Haesen, E., & Driesen, J. (2010). The impact of Charging plug-in hybrid electric vehicles on a residential distribution grid. *IEEE Transactions on Power Systems*, 25(1), 371–380. doi:10.1109/TPWRS.2009.2036481
- Conejo, a J., Morales, J. M., & Baringo, L. (2010). Real-Time Demand Response Model. *Smart Grid, IEEE Transactions on*, 1(3), 236–242. doi:10.1109/tsg.2010.2078843
- Guan, X., Xu, Z., & Jia, Q. S. (2010). Energy-efficient buildings facilitated by microgrid. *IEEE Transactions on Smart Grid*, 1(3), 243–252. doi:10.1109/TSG.2010.2083705
- Han, S., Soo, H. H., & Sezaki, K. (2010). Design of an optimal aggregator for vehicle-to-grid regulation service. *Innovative Smart Grid Technologies Conference, ISGT 2010*, 1(1), 65–72. doi:10.1109/ISGT.2010.5434773
- Hatami, S., & Pedram, M. (2010). Minimizing the Electricity Bill of Cooperative Users under a Quasi-Dynamic Pricing Model. *Smart Grid Communications (SmartGridComm), 2010 First IEEE International Conference on*, 421–426. doi:10.1109/SMARTGRID.2010.5622080
- Ibars, C., Navarro, M., & Giupponi, L. (2010). Distributed Demand Management in Smart Grid with a Congestion Game. *Smart Grid Communications (SmartGridComm), 2010 First IEEE International Conference on*. doi:10.1109/SMARTGRID.2010.5622091
- Kallitsis, M. G., Michailidis, G., & Devetsikiotis, M. (2010). A Framework for Optimizing Measurement-Based Power Distribution under Communication Network Constraints. *2010 First IEEE International Conference on Smart Grid Communications*, 185–190. doi:10.1109/SMARTGRID.2010.5622039
- Kishore, S., & Snyder, L. V. (2010). Control Mechanisms for Residential Electricity Demand in SmartGrids. *Smart Grid Communications (SmartGridComm), 2010 First IEEE International Conference on*, 443–448. doi:10.1109/smartgrid.2010.5622084
- Liu, X. (2010). Economic load dispatch constrained by wind power availability: A wait-and-see approach. *IEEE Transactions on Smart Grid*, 1(3), 347–355. doi:10.1109/TSG.2010.2057458
- Mohsenian-Rad, A. H., & Leon-Garcia, A. (2010). Optimal residential load control with price prediction in real-time electricity pricing environments. *IEEE Transactions on Smart Grid*, 1(2), 120–133. doi:10.1109/TSG.2010.2055903
- Mohsenian-Rad, A. H., Wong, V. W. S., Jatskevich, J., Schober, R., & Leon-Garcia, A. (2010). Autonomous demand-side management based on game-theoretic energy consumption scheduling for the future smart grid. *IEEE Transactions on Smart Grid*, 1(3), 320–331. doi:10.1109/TSG.2010.2089069
- Neely, M. J., Tehrani, a. S., & Dimakis, a. G. (2010). Efficient Algorithms for Renewable Energy Allocation to Delay Tolerant Consumers. *Smart Grid*

Communications (SmartGridComm), 2010 First IEEE International Conference on, 1–10. doi:10.1109/SMARTGRID.2010.5621993

Ochoa, L. F., & Harrison, G. P. (2011). Minimizing energy losses: Optimal accommodation and smart operation of renewable distributed generation. *IEEE Transactions on Power Systems*, 26(1), 198–205. doi:10.1109/TPWRS.2010.2049036

Public Service Enterprise Group Incorporated. (2013). Historical Load Profiles Public Service Electric and Gas (PSE&G) of New Jersey United State. Retrieved from https://www.pseg.com/business/energy_choice/third_party/historical.jsp

Samadi, P., Mohsenian-Rad, A.-H., Schober, R., Wong, V. W. S., & Jatskevich, J. (2010). Optimal Real-Time Pricing Algorithm Based on Utility Maximization for Smart Grid. *2010 First IEEE International Conference on Smart Grid Communications*, 415–420. doi:10.1109/SMARTGRID.2010.5622077

Sortomme, E., Hindi, M. M., MacPherson, S. D. J., & Venkata, S. S. (2011). Coordinated charging of plug-in hybrid electric vehicles to minimize distribution system losses. *IEEE Transactions on Smart Grid*, 2(1), 186–193. doi:10.1109/TSG.2010.2090913

